



AI4CSM – Automotive Intelligence for connected shared mobility

Schlussbericht

**zum Teilvorhaben der
Ostbayerischen Technischen Hochschule Amberg-Weiden**

**„Flottenrouting für Ridesharing: Virtual City Routing & Föderiertes Lernen
für die Reichweitenvorhersage von elektrischen Fahrzeugen“**

Förderkennzeichen 16MEE0172

Laufzeit des Vorhabens 01.05.2021 bis 28.02.2025

Autoren

Ostbayerische Technische Hochschule Amberg-Weiden

Fakultät Elektrotechnik, Medien, Informatik

Kaiser-Wilhelm-Ring 23

92224 Amberg

André Baldermann

Moritz Schaffenroth

Martin Fischer

Heike Lepke

Natalia Batcheller

Prof. Dr.-Ing. Alfred Höß

Ergebnisverbreitung

Öffentlich

BMBF

Projektträger

Projektpartner

Dateiname

BMBF_AI4CSM_OTH-AW_Schlussbericht.docx

Inhaltsverzeichnis

1	Zusammenfassung.....	8
2	Projektidee, Aufgabenstellung und Zielsetzung.....	10
2.1	Aufgabenstellung und Zielsetzung	10
	Details zur Aufgabenstellung.....	11
	Föderiertes Lernen	14
	Europäischer Green Deal.....	15
	EU AI Act.....	16
	Synergetische Implementierung	16
2.2	Voraussetzungen, unter denen das Vorhaben durchgeführt wurde	17
2.3	Wissenschaftlich-technischer Stand bei Projektstart.....	19
	Flottenrouting.....	19
	Reichweitenvorhersage für EVs.....	20
	Problemstellung.....	20
	Stand der Technik.....	20
	Verfügbare Trainingsdatensätze	21
	Föderiertes Lernen und Datenschutz	21
2.4	Bisherige Arbeiten des Antragstellers	22
2.5	Zusammenarbeit mit anderen Stellen.....	23
3	Durchgeführte Arbeiten und erreichte Ergebnisse	25
3.1	Arbeiten und Ergebnisse WP1: Requirements	27
3.2	Arbeiten und Ergebnisse WP2: System Design	29
3.3	Arbeiten und Ergebnisse WP3: Electronic Components	36
3.4	Arbeiten und Ergebnisse WP4: Embedded System Development.....	36

3.5	Arbeiten und Ergebnisse WP5: System Integration	44
	Integration des Roadside-Unit-Skripts	45
	Integration Robo-Taxi	45
3.6	Arbeiten und Ergebnisse WP6: Test, Validation and Demonstration	49
3.7	Ergebnisse WP7: Regulatory alignment, Standardisation, Exploitation, and Stakeholder Relations	57
3.8	Ergebnisse WP8: Project Management and Projects Clustering.....	57
4	Ergebnisverbreitung.....	58
4.1	Konferenzbeiträge und Publikationen	58
4.2	Erfindungen/Schutzrechtsanmeldungen.....	58
5	Planung und Ablauf des Projekts	59
5.1	Planung und Ablauf von AI4CSM.....	59
5.2	Während der Projektlaufzeit bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen.....	59
6	Änderungen in der Zielsetzung	60
7	Verwertungsplan und Erfolgsaussichten.....	61
8	Wichtigste Positionen des zahlenmäßigen Nachweises	62
9	Referenzen	63

Abbildungsverzeichnis

Abbildung 1: Bausteine des Virtual City Routings	12
Abbildung 2: Testfahrten fanden hauptsächlich in Amberg, Schwandorf und Regensburg statt.....	13
Abbildung 3: Klassisches KI-Training im Vergleich zu föderiertem Lernen.....	14
Abbildung 4: AI4CSM Struktur der Arbeitspakete.....	17
Abbildung 5: AI4CSM Matrixstruktur – Arbeitspakete (horizontal) und Supply Chains (vertikal)	18
Abbildung 6: Abhängigkeiten zwischen den Arbeitspaketen (PERT-Chart)	18
Abbildung 7: AI4CSM Balkenplan	19
Abbildung 8: Verkehrssimulation der Stadt Amberg	28
Abbildung 9: Algorithmus zur Bestimmung der Abholstationen	29
Abbildung 10: K-Means Algorithmus zur Stationsfindung	29
Abbildung 11: Abholstationen verteilt über Amberg.....	30
Abbildung 12: Foto des ausgeliehenen Tesla 3 Performance für die Sommertestfahrten 2022.....	31
Abbildung 13: Datenaufzeichnungspipeline	31
Abbildung 14: Auswertung mittels Grafana nach einer Testfahrt. Die aufgezeichneten Daten sind plausibel. 32	
Abbildung 15: Datenaufzeichnung mittel ScanMyTesla-App und der Teslalogger Software	34
Abbildung 16: Erster Schritt der Datenaufbereitung mit Datenkorrelation und Map-Matching. Die zusätzlich dargestellten Optimization Loops sind ein Vorgriff auf WP4 und zeigen die Fortführung der Datenverarbeitungspipeline.....	35
Abbildung 17: Beispiel zur Verwendung von Dimensionsreduktion zur Featureraumverkleinerung...37	
Abbildung 18: Energieverbrauch und Transportdauer für die gerouteten Strecken eines Fahrzeuges und unterschiedliche Anzahl an Kunden.....	38
Abbildung 19: Relevanter Codeausschnitt zur Generierung von Roadside Units	38
Abbildung 20: Roadside Einheiten platziert in der SUMO-Simulation von Amberg	39
Abbildung 21: Initiale Planung des Hardwaredemonstrators	41
Abbildung 22: Flower Framework Kommunikation und parallele, von der OTH Amberg-Weiden implementierte WebSocket-Kommunikation	42

Abbildung 23: Tablet auf Standfuß mit Akku	42
Abbildung 24: Google Material Light Design wurde auf den Tablets verwendet.....	43
Abbildung 25: Dauertests eines vollaufgeladenen Tablets mit zusätzlichem 10.000 mAh Akku bei maximaler Displayhelligkeit	44
Abbildung 26: Föderiertes Lernen "leaked" die Trainingsdaten über das Modellupdate	47
Abbildung 27: Das KI-Konzept der OTH Amberg-Weiden im Vergleich zum Stand der Wissenschaft...48	
Abbildung 28: Systematisierung der Reichweitenvorhersage auf Basis eines ML-trainierten Schätzbaums	48
Abbildung 29: Demonstrator und Roll-up auf dem AI4CSM-Abschlussevent vom 11. bis 13. Februar 2025 in Stuttgart	49
Abbildung 30: Heatmaps der Start- und Zielpositionen von Kunden: links basierend auf den durch OMOD generierten 832 Mobilitätsanfragen, rechts basierend auf zufällig initialisierten Positionen in SUMO (1080).....	50
Abbildung 31: Evaluierungs Setup.....	50
Abbildung 32: Gesamtdistanzen die für alle Fahrzeuge einer Modalität gefahren wurden um die Kunden zu bedienen.....	52
Abbildung 33: Gesamtzeit die eine Mobilitätsform erforderte um die Kundenanfrage zu erfüllen	52
Abbildung 34: Wartezeit der Mobilitätsform.....	53
Abbildung 35: Integration von Föderiertem Lernen über die ORA Box in den Mercedes EQC	55
Abbildung 36: Visualisierung der Trainings der KI-Parameter. Der Übersichtlichkeit halber werden zwei von vier Fahrzeugen dargestellt.....	56

Tabellenverzeichnis

Tabelle 1: AI4CSM Konsortium.....	23
-----------------------------------	----

1 Zusammenfassung

Elektrische Fahrzeuge (EV) sind derzeit in Europa noch wenig verbreitet, mit Ausnahme von Island und Skandinavien. Die Technologie entwickelt sich jedoch rasant und gilt als eine Schlüsseltechnologie, um die grüne europäische Wende voranzutreiben (European Green Deal). Dabei gilt es, die technologische Entwicklung auch auf gesellschaftlicher, regulatorisch-normativer und in Form von Geschäftsmodellen zu verankern.

Die Entwicklung von EVs muss von adäquaten Optimierungsarchitekturen begleitet werden, die die zuvor beschriebenen Fragestellungen adressieren. Dabei muss ein Ziel sein, den Energieverbrauch von EVs durch Konzepte von Vernetzung, geteilter Mobilität und KI weiter zu senken.

Im Jahr 2021 wurde das von der EU und nationalen Behörden geförderte Forschungsprojekt AI4CSM (Automotive Intelligence for Connected Shared Mobility) gestartet. Die OTH-AW bearbeitete dabei zwei Themengebiete. Zum einen wurde in der Supply Chain 1 im Rahmen des Demonstrators 1.3 „Virtual City Routing“ der Energieverbrauch von Fahrzeugflotten optimiert, die für den Personentransport mittels Ridesharing eingesetzt werden.

Für diesen Anwendungsfall wurde ein Digital Twin der Stadt Amberg entwickelt. Mit diesem wurden Algorithmen zum Fahrzeugrouting evaluiert und der Einfluss eines veränderten Mobility Splits analysiert. Der Digital Twin umfasst Mobilitätsdaten der Stadt Amberg, darunter Verkehrsmessungen verschiedener Verkehrsteilnehmer. Mithilfe eines statistischen Modells wurden Abholstationen in der Stadt platziert. Um Live-Verkehrsdaten einfließen zu lassen, wurden virtuelle Roadside Units eingesetzt, die den Verkehrsfluss in Echtzeit erfassen und eine dynamische Anpassung der Routen während der Simulation ermöglichen. Für die Erstellung von Flottenrouten wurden State-of-the-Art-Algorithmen auf Basis von Reinforcement Learning weiterentwickelt und an den Anwendungsfall des Ridesharings angepasst.

Des Weiteren verfolgt der Beitrag in Supply Chain 2 im Rahmen des Demonstrators 2.2 das Ziel, einen Beitrag zur Reduktion des Energieverbrauchs von Einzelfahrzeugen zu leisten.

Dies wird realisiert durch eine Reichweitenvorhersage von elektrischen Fahrzeugen in einer die Privatsphäre schützenden Weise. Konkret wird ein KI-Modell auf Basis von Testfahrten mit einem (noch) Nischenkonzept namens „Föderiertes Lernen“ trainiert. Dabei wird ein globales KI-Modell erstellt. Durch das Konzept des föderierten Lernens verbleiben die Trainingsdaten im Fahrzeug, werden also nicht mit einem zentralen Server geteilt. Die OTH-AW untersuchte Datenschutzaspekte im Kontext von föderiertem Lernen mit Hinblick auf den EU AI Act, entwickelte und implementierte einen Vorschlag, der den grünen Wandel und Datenschutz auf vielfältige Weise in einer Lösung verbindet und gegenseitig ergänzt.

Dafür entwickelte die OTH-AW ein Konzept zur Aufnahme von Trainingsdaten und fuhr ca. 13.000 Km Testfahrten in Amberg, Sulzbach-Rosenberg und Regensburg ein. Dies geschah mit einem diversen Fahrerteam aus OTH-AW Mitarbeiterinnen und Mitarbeitern sowie einer Reihe von Studierenden. Daraufhin erfolgte die Analyse der Daten auf ihre statistischen Eigenschaften sowie die Bereinigung unvollständiger Datenaufzeichnungen.

Auf Basis des Stands der Wissenschaft wurde ein KI-Konzept zum föderierten Lernen erarbeitet. Hierbei wurden insbesondere Aspekte des Datenschutzes von föderiertem Lernen untersucht und mit dem EU AI Act abgeglichen. Zusätzlich wurden ergänzende Datenschutzkonzepte untersucht und für das Projekt AI4CSM ein Konzept ausgearbeitet und implementiert.

Die Implementierung erfolgte in einem Tischdemonstrator bestehend aus einem diversen Set von Trainingshardware und Tablets zur Visualisierung und Untersuchung des KI-Trainings.

Das Gesamtkonsortium von AI4CSM war entlang der Wertschöpfungskette ausgerichtet. Es bestand aus insgesamt 41 Partnern aus 10 europäischen Ländern und umfasste führende Fahrzeughersteller/OEMs, Tier-1 Zulieferer, Halbleiterhersteller sowie weitere Partner der Wertschöpfungskette wie Technologie-Integratoren, Universitäten und Forschungseinrichtungen. Die im Projekt in allen Supply Chains erreichten Ergebnisse wurden beim Abschlussreview vom 11.02.2025 bis 13.02.2025 in Stuttgart demonstriert und erläutert. Die Projektziele wurden trotz Corona-Pandemie und einer weitgehend remote durchgeführten Integration der entwickelten Hardware- und Softwarekomponenten vollumfänglich erreicht.

2 Projektidee, Aufgabenstellung und Zielsetzung

2.1 Aufgabenstellung und Zielsetzung

Das Projekt AI4CSM (Automotive Intelligence for connected shared mobility) ist inspiriert durch die Vision eines klimaneutralen Europas bis zum Jahr 2050. Dies erfordert erhebliche technologische, ökonomische und soziale Transformationen innerhalb nur einer Generation. Um dies zu erreichen, ist die Entwicklung grüner Fahrzeuge und einer optimierten, vernetzten Mobilität unerlässlich. Dazu ist es notwendig, intelligente Unterstützungssysteme zu entwickeln. Dies kann durch modernste KI-Architekturen unterstützt werden. Das Projekt AI4CSM entwickelt eine große Bandbreite an Hard- und Softwarearchitekturen und entwickelt damit die grüne Zukunft der Mobilität Europas.

Die einleitend vorgestellte Transformation lässt sich in technische Begriffe übersetzen. Konkret geht es um die Entwicklung **Electric Connected Autonomous and Shared (ECAS)** – Fahrzeugen, also innovativer Mobilitätsplattformen, die den Wandel in eine grüne Zukunft ermöglichen. Der Begriff „**Electric**“ meint fortschrittliche Elektrofahrzeugtechnologie zur Verbesserung des Energieverbrauchs und der Nachhaltigkeit. Der Begriff „**Connected**“ bezieht sich auf die Erweiterung der Konnektivitätsfunktionen, wie Vehicle-to-Vehicle (V2V) oder Vehicle-to-Infrastructure (V2I) und cloudbasierte Dienste für den Echtzeitdatenaustausch. „**Autonomous**“ bezieht sich auf die Weiterentwicklung autonomer Fahrtechnologien mit KI, Sensoren und autonomen Entscheidungsprozessen. Der Begriff „**Shared**“ beinhaltet die Optimierung von Fahrzeugen für geteilte Mobilitätsdienste wie Carsharing, Rufbusse oder autonome Flottenbetriebe.

Neben der technologischen Innovation geht es auch um die Entwicklung und Implementierung adäquater Industriestandards und Regulierungen. Diese stellen die Sicherheit und Zuverlässigkeit der Innovationen sicher. Dabei wurden während des Projekts die Entwicklung von Standards- und Regulierungen aktiv begleitet und umgesetzt.

AI4CSM zielt darauf ab, adäquate Geschäftsmodelle zu entwickeln und fasst all dies in einer Vision, einer Mission und identifizierten Trends prägnant zusammen:

Vision: *Build Europe’s nano-electronic intelligence for electric, connected, automated vehicles for future mobility in the mass market.*

Mission: *Develop the functional architecture for EV 4.0 and EV 5.0 and implement ECS, embedded intelligence and functional virtualization for connected shared mobility using Artificial-Automotive Intelligence*

AI4CSM Trends: *To enable cooperative traffic the automatisisation of EV and digitalisation providing sharing of information, data and resources including the twinning of the real world for better strategies will allow to connect the urban traffic with the energy domain for synergies.*

Im europäischen Projekt AI4CSM arbeiten die notwendigen Partner zusammen, um die Ziele auf regulatorischer und technologischer Ebene anzugehen und auch den Fortschritt in angewandter Form demonstrieren können. Erst wenn die technischen Lösungen verfügbar sind, kann die grüne Transformation im Einklang mit der Gesellschaft, volkswirtschaftlichen, betriebswirtschaftlichen und regulatorischen Anforderungen gelingen.

Im Projekt AI4CSM widmete sich die OTH-AW in Supply Chain 1 dem Flottenrouting. Da CO₂-Emissionen im Verkehrsbereich ein großes Problem darstellen und rund 20 % der Gesamtemissionen in Deutschland ausmachen – ohne derzeit erkennbare Verbesserung –, sind Änderungen in der

Mobilität erforderlich. Eine Möglichkeit im Individualverkehr besteht darin, auf geteilte Mobilität umzusteigen. Da es sich beim Flottenrouting-Problem um eine herausfordernde und rechenintensive Aufgabe handelt, sind neuartige Algorithmen, beispielsweise auf Basis von Reinforcement Learning, erforderlich. Das Ziel der Forschung war es, die Auswirkungen des Mobility Splits zu bewerten und Algorithmen miteinander zu vergleichen. Der Demonstrator „Virtual City Routing“ vollzog dabei den Schritt vom Technologie-Reifegrad TRL 2 (Beschreibung der Anwendung einer Technologie) auf TRL 4 (Versuchsaufbau im Labor).

Darüber hinaus befasste sich die OTH-AW in der Supply Chain 2 der Reichweitenvorhersage von Elektrofahrzeugen mittels innovativer Ansätze. Im Vergleich zu Verbrennern leiden EV-Verkäufe durch das Phänomen der sogenannten Reichweitenangst. Aufgrund relativer kurzer Reichweiten, relativ langer Ladezyklen und begrenzt verfügbarer Ladeinfrastruktur entsteht Reichweitenangst und gilt als Kaufhindernis. Dieser Reichweitenangst kann durch eine adäquate Reichweiteschätzung begegnet werden. Die meisten Konzepte zur Reichweiteschätzung bemühen sich um eine besonders genaue Abschätzung, um die Reichweitenangst möglichst gut zu adressieren. Dazu werden immer komplexere KI-Systeme mit einem immer größeren Daten-Potpourri trainiert. Dies steht aber anderen europäischen Zielen wie dem Green Deal oder Datenschutzinteressen entgegen. Die OTH-AW entwickelt und untersucht ein anderes Konzept, das sich an europäischen Interessen orientiert und sich sogar synergetisch gegenseitig verstärken soll. Dies erfolgt im Hinblick auf den bereits erwähnten Green Deal in Verbindung mit Datenschutzaspekten aus regulatorischen Regelwerken wie dem EU AI Act, die zu Projektbeginn noch in Arbeit sind. Ziel ist die Implementierung des Konzepts anhand eines Tischdemonstrators, an dem die Aspekte untersucht und demonstriert werden können. Die Implementierung erfolgt auf einer diversen Hardwareauswahl, um die Versatilität der Implementierung zu demonstrieren. Die Supply Chain 2 strebt einen Technologiefortschritt von TRL 2 (Beschreibung der Anwendung einer Technologie) auf TRL 4 (Versuchsaufbau im Labor) an.

Die OTH-AW entwickelte den Demonstrator 2.2. In Abstimmung mit den teilvorhabenrelevanten Verbundpartnern, arbeitete die OTH-AW in Demonstrator 2.2 an der Umsetzung von Privatsphäre schützenden föderiertem Lernen für die Reichweiteschätzung von elektrischen Fahrzeugen (EV).

Zielsetzung: Durch die gleichzeitige Berücksichtigung des europäischen Green Deals, Datenschutzaspekten des EU AI Acts und wirtschaftlicher Interessen soll ein umfassendes Konzept entwickelt und im Demonstrator 2.2 implementiert, untersucht und demonstriert werden.

Details zur Aufgabenstellung

Um die Auswirkungen eines Mobility Splits bewerten zu können, benötigt man eine belastbare Datenbasis. In unserem Fall wurde diese Grundlage durch Simulationen erzeugt, die entsprechend parametrisiert werden müssen. Abbildung 1 zeigt das High-Level-Design der Umgebung.

Ein Digital Twin der Stadt Amberg bildet das Fundament. Dieser kommuniziert über virtuell platzierte Roadside Units die aktuelle Verkehrslage an einen Matrix Routing Query Service, der fortlaufend die kürzesten Wege zwischen allen Stationen berechnet.

Anhand einer Energiesimulation wird der Energieverbrauch der Routen bestimmt, sodass der Reinforcement-Learning-Solver die optimale Kombination kürzester Strecken wählen kann, um alle aktuellen Kundenanfragen effizient zu bedienen.

Im Live-Betrieb werden die Routinganfragen kontinuierlich an ein Robo-Taxi übermittelt, das die Aufträge direkt auf der Straße ausführt.

Dieser Demonstrator wurde in Kooperation mit Demonstrator 1.2 ‚Robo-Taxi‘ durchgeführt, bei dem die Trajektorienplanung eines Fahrzeugs optimiert und Szenarien wie das Abholen eines Passagiers

umgesetzt wurden. In der Kooperation wurde eine Schnittstelle zwischen dem Routingsystem und einem realen Fahrzeug entwickelt.

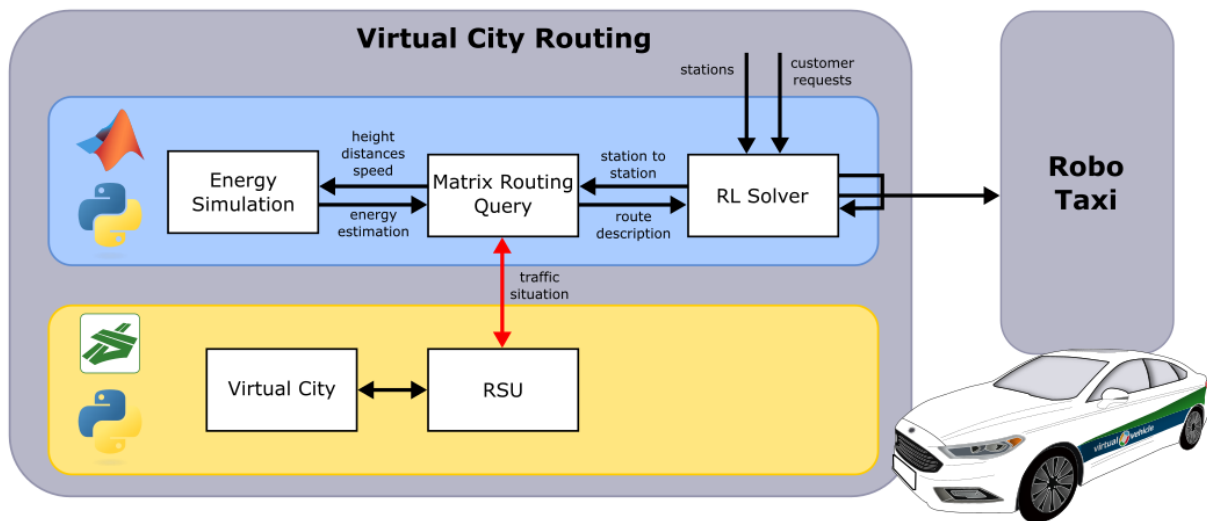


Abbildung 1: Bausteine des Virtual City Routings

Der Digital Twin wurde mithilfe der mikroskopischen Mobilitätssimulationssoftware SUMO realisiert. Die Erweiterungen für die virtuellen Roadside Units (RSU) wurden in Python implementiert, während das Matrix Routing Query durch eine Erweiterung der Routingsoftware Valhalla erfolgte. Die Energiesimulation wurde mit MATLAB-Code umgesetzt, der Reinforcement-Learning-Solver in Python entwickelt und die Schnittstelle zum Fahrzeug mittels Cellular-Kommunikation im 1-Hz-Takt sowie WebSockets realisiert.

Um ein KI-Modell zu trainieren, werden **Trainingsdaten** benötigt. Zunächst gilt es, öffentlich verfügbare real durchgeführte Daten von Testfahrten zu finden. Es ließen sich jedoch keine adäquaten Datensätze finden. Deshalb entschied sich die OTH-AW selbst Trainingsdaten einzufahren. Dazu müssen regulatorische Anforderungen erfüllt werden. Das bedeutet, ein EV muss gemietet werden und die notwendigen Daten abgegriffen werden dürfen. Darüber hinaus muss dies auch technisch ermöglicht werden z.B. durch Auslesen der ODB-Schnittstelle. Des Weiteren müssen Testfahrten geplant werden, ein diverser Pool an Testfahrern gefunden werden und auch hier die rechtlichen Voraussetzungen wie Versicherungen, die Erlaubnis zum Aufzeichnen der Daten etc. geschaffen sein. Erst dann können Testfahrten durchgeführt werden. Testfahrten wurden fast ausschließlich in folgendem Kartenabschnitt eingefahren. Ausnahmen sind einzelne Fahrten nach Nürnberg. Die Testfahrten sollten einen freien Anteil umfassen, das heißt die Testfahrer können nach eigenem Ermessen beliebige Strecken fahren. Es sollte aber eine Auswahl an vordefinierten Streckenabschnitten geben, die während der Testfahrten einmal abgefahren werden sollen. Dadurch sollte einerseits ein diverser Datensatz entstehen, der sehr viele unterschiedliche Verkehrssituationen beinhaltet. Aber auch sich wiederholende Verkehrsszenarien mit unterschiedlichen Fahrstilen unterschiedlicher Fahrer werden während der Testfahrten auf den vordefinierten Streckenabschnitten abgebildet.




Abbildung 2: Testfahrten fanden hauptsächlich in Amberg, Schwandorf und Regensburg statt.

Im Anschluss erfolgten **die Auswertung und Bereinigung der zuvor aufgezeichneten Daten**. Hier handelt es sich um einen aufwendigen Prozess, der nur teilweise standardisiert erfolgen kann. Beispielsweise kann der Datensatz relativ mühelos auf fehlende Daten oder fehlerhafte Datenfelder („NaN“ statt einer Zahl) untersucht werden. Erheblich aufwendiger ist die Untersuchung der Ursache und die Entscheidung, wie damit weiter verfahren werden kann. Entweder können die betreffenden Datenzeilen verworfen werden oder diese lassen sich nachträglich rekonstruieren. In Grenzen können fehlerhafte Daten auch nachträglich simuliert werden. Auch weiterführende Fragestellung wie die Korrelation von Datenfeldern geben einen begrenzten Eindruck, was durch Einsatz einer KI erreicht werden kann. Letztlich erkennt KI aber auch nicht offensichtliche Datenmuster und wird anhand dieser feinjustiert.

Es sollen nicht nur Fahrzeugdaten gesammelt werden. Es ist auch notwendig die Fahrzeugkoordinaten mit den gefahrenen Straßen und Umgebungsbedingungen zu vereinigen wie Ampeln oder Fußgängerüberwege. Darüber hinaus sollten auch Wetterdaten unterschiedlicher Quellen aufgezeichnet und bezüglich Ihrer Eignung zum KI-Training untersucht werden. Auch Quellen zu

Höhendaten wie dem Bayernatlas sollen mit den aufgezeichneten Fahrdaten synchronisiert und hinsichtlich ihrer Relevanz untersucht werden. Abschließend müssen die aufbereiteten Daten in einem geeigneten Format für das KI-Training aufbereitet werden.

Zur **algorithmischen Implementierung** werden zunächst vielversprechende Konzepte aus dem Stand der Wissenschaft so weit möglich und nötig implementiert. Dadurch entsteht ein tiefes und intuitiveres Verständnis des bereits vorhandenen Standes der Wissenschaft. Auch die Grenzen der Konzepte werden dadurch verdeutlicht.

Im nächsten Schritt erfolgten die Einarbeitung und Implementierung von Föderiertem Lernen. Dazu gibt es eine Auswahl an Bibliotheken, die föderiertes Lernen unterstützen. Hier kann auf Erfahrungen aus dem Projekt PowerizeD, das ebenfalls von der OTH-AW zeitgleich bearbeitet wird, zurückgegriffen werden. Die Wahl fiel auf das Flower Framework.

Um die Lösung intensiv testen zu können und die Ergebnisse adäquat zu demonstrieren sind die Planung und Entwicklung eines **Hardwaredemonstrators** notwendig. Föderiertes Lernen setzt eine Flotte von Fahrzeugen voraus. Das bedeutet, dass sich eine Anzahl von Fahrzeugen in einem Verbund mit einem Trainingsserver kommuniziert. Eine Reihe von zugrunde liegenden Geschäftsmodellen sind denkbar. Der KFZ-Hersteller selbst könnte einen Server bereitstellen, über den alle selbst produzierten Fahrzeuge trainiert werden. Es könnte sich auch um einen Flottenbetreiber handeln, der mehrere Marken unter seinem Dach vereint. Oder eine Stadt oder Landkreis stellen eine Robotaxis bereit. Um die prinzipielle Machbarkeit zu zeigen, soll ein Tischdemonstrator entwickelt werden, der ein diverses Set von Hardwarekomponenten nutzt, die Fahrzeuge simulieren. Die zuvor aufgezeichneten Testfahrten sollen auf diesen Hardwarekomponenten abgespielt werden. Es soll auch die Hardware des Servers für das Föderierte Learning bereitgestellt und programmiert werden. Das föderierte Lernen soll über Display oder Monitore visualisiert werden. Dies ist die Basis für Entwicklung, Test und Demonstration der Ergebnisse. Außerdem soll der Schritt zur Implementierung in einen Mercedes EQC möglichst nahe einer tatsächlichen Implementierung aufgezeigt werden.

Föderiertes Lernen

Die OTH-AW hat das Ziel, föderiertes Lernen einzusetzen. Dieses relativ neue Konzept soll hier zunächst vorgestellt werden. Dafür eignet sich ein Vergleich mit traditionellem KI-Training. Die folgende Abbildung zeigt auf der linken Seite dieses traditionelle KI-Training. Auf Kundengeräten wie Handys, Laptops, Elektroautos fallen Daten an. Diese werden mittels „Datenautobahn“ an einen großen Server übertragen. Auf dem Server erfolgt das KI-Training.

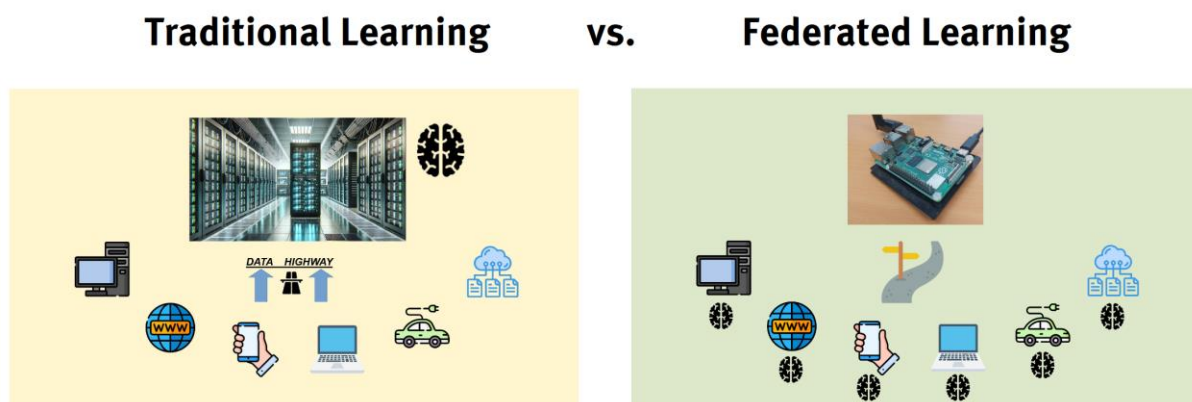


Abbildung 3: Klassisches KI-Training im Vergleich zu föderiertem Lernen

Das von der OTH-AW implementierte Konzept erfordert online Learning. Das bedeutet, dass KI-Modell während der Autofahrten weiter trainiert. Es müssten deshalb alle anfallenden Daten drahtlos an

den Server übertragen werden, was erheblich Bandbreite verbrauchen würde. Da sich die gesamte Intelligenz im zentralen Server befindet, ist diesem zur Verdeutlichung das Symbol eines Gehirns zugeordnet.

Im Gegensatz dazu steht das föderierte Lernen. Hier erfolgt das KI-Training direkt auf den Geräten. Dies ist möglich, da auf einem einzelnen Gerät in der Regel nur wenig Daten anfallen, mit denen die KI wenige Schritte trainiert wird. Nach einigen Rechenschritten ergibt sich ein leicht verändertes Modell. Das Modellupdate (nicht die Trainingsdaten) wird zum Server gesendet. Das Modellupdate von bspw. vielen hundert Fahrzeugen ergibt ein größeres Modellupdate. Der Server nimmt die Modellupdates aller Fahrzeuge entgegen und bildet den Mittelwert aller einzelnen Modellparameter. Mathematisch ähnelt dies Batch Learning. Nach der Mittelung der Modellparameter werden diese an alle Fahrzeuge verteilt. So erhält jedes einzelne Fahrzeug ein globales Modell, das mit Hilfe vieler einzelner Fahrzeuge trainiert wurde.

Es lässt sich auf folgende Weise über die Ansätze nachdenken. Bei traditionellem Lernen müssen die Trainingsdaten zum zentralen Server bewegt werden. Beim föderierten Lernen wird der Algorithmus zu den Daten bewegt. Hier wird die Unterschiedlichkeit der Ansätze deutlich. Die Anwendung von Föderiertem Lernen birgt eine ganze Reihe von Vorteilen. Die Anwendung dieses Konzeptes zur Reichweitenvorhersage für Elektrofahrzeuge war zu Projektbeginn nach Kenntnis der OTH-AW neu.

Europäischer Green Deal

Ein Ziel des Demonstrators 2.2 der Supply Chain 2 ist es, den europäischen Green Deal zu adressieren. Dies erfolgt konzeptionell auf mehreren Ebenen:

Technologisch durch Föderiertes Lernen: Durch Anwendung des KI-Trainings-Konzepts „Föderiertes Lernen“ kann der beim klassischen Training notwendige zentralisierte weitgehend Server eingespart werden. Hierdurch wird nicht nur Material und Energie zur Produktion der Server eingespart, auch Energie und Mitarbeiter zum Betrieb und zur Instandhaltung werden kaum gebraucht. Das KI-Training erfolgt auf den Elektrofahrzeugen. Lediglich ein Update des trainierten KI-Modells wird zwischen dem Elektrofahrzeug und dem reduzierten Server von Zeit zu Zeit ausgetauscht. Erfolgt dieser Austausch kabellos, so wird durch die minimierte Datenkommunikation zusätzlich das elektromagnetische Spektrum geschont. Die Kommunikation erfolgt mit geringen Bandbreiten über gegebenenfalls energiesparende und wartungsarme Hardware (z. B. LORAWAN). Stattdessen wird auf ohnehin vorhandener Hardware trainiert, die ansonsten zumindest einen Ruhestromverbrauch hätte. Auch wenn Trainingsserver bezüglich ihres Energieverbrauchs optimiert sind, ist zunehmend hocheffiziente KI-Hardware in vielen Leistungsklassen im Markt verfügbar, so dass der Vorteil eines zentralisierten Servers entlang der Zeitachse marginalisiert wird.

Technologisch durch ein minimales globales Modell: Das vorgeschlagene KI-Modell ist minimalistisch. Dies ist konträr zur Studienlage, die je nach Verfügbarkeit neuerer KI-Modelle diese auf das Problem der Reichweitschätzung überträgt. Je einfacher das Modell, desto leichter und energieärmer kann das Training verlaufen. Ein einfaches Modell richtet sich an wenigen aber relevanten Größen aus. Dieser Ansatz ist ebenfalls datengetrieben, aber erzwingt ein besseres Verständnis der Effekte der einzelnen Datenfelder, als es üblicherweise erfolgt. Es gibt zusätzlich eine ganze Reihe von Vorteilen, die sich durch Einfachheit und Übersichtlichkeit einstellen. KI-Systemen ist es inhärent, dass die Entscheidungen nicht gut nachvollziehbar sind. Aufgrund von Milliarden oder sogar Billionen von Einzelberechnungen lässt sich kein roter Faden nachvollziehen. Durch einen minimalistischen Ansatz wird die Entwicklung der KI erheblich systematisiert. Dadurch wird das Modell in gewissen Grenzen „erklärbar“ und robust. Auch die Skalierung auf erheblich größere Flotten mit schwächeren

Rechensystemen sollte sich einfacher gestalten. Darüber hinaus sollte es einfacher sein, regulatorische Anforderungen zu erfüllen und das Modell ist dadurch zukunftsfester und kosteneffizienter.

Psychologisch durch Nudging: Das von der OTH-AW implementierte Modell hat nicht den Anspruch, vorab eine präzise Schätzung zu liefern. Die OTH-AW hält es nicht für sinnvoll, eine sehr präzise Abschätzung zu geben, da dies sehr stark von der Verkehrssituation abhängt. Das Fahrverhalten, kann sich je nach Verkehrssituation, ändern. Nach einem Stau fährt der Fahrer eventuell viel sportlicher. Oder der Kofferraum ist beladen oder es sind auf dem Weg zur Arbeit ausnahmsweise 2 Beifahrer dabei. Es scheint nicht möglich zu sein, im Vorfeld adäquat den Energieverbrauch zu schätzen. Stattdessen soll das individuelle Fahrverhalten durch ein lokales Modell mit dem Energieverbrauch des globalen Modells verglichen werden. Dies soll zwei Effekte erreichen. Erstens wird der Fahrer durch aktive Feedbacks instantan zur Optimierung seines Fahrverhalten ermutigt, zweitens sollte dies mit der Zeit dazu führen, dass das globale Modell hin zu geringerem Energieverbrauch strebt. Denn wenn das instantane Feedback häufig zu einem energiesparenderen Energieverhalten führt, sollte sich dies im Mittel auf das globale Modell auswirken. Dadurch werden wiederum mehr Fahrer zu energiesparenderem Energieverhalten animiert.

EU AI Act

Im Hinblick auf regulatorische Anforderungen soll die Implementierung der OTH-AW den Datenschutz gewährleisten. Föderiertes Lernen scheint hier eine optimale Lösung zu sein, da die Trainingsdaten das Fahrzeug nicht verlassen. Lediglich Modellupdates werden zum Server gesendet. Dennoch gibt es eine Reihe von Datenschutzkonzepten, die speziell bei Föderiertem Lernen Anwendung zusätzlich finden und im Projektverlauf untersucht werden. Ziel des Projektes ist es den Datenschutz zu gewährleisten. Dies hat mehrere Hintergründe.

Einmal aus Sicht des Fahrers. Ein sportliches Fahrverhalten könnte gegen den Fahrer ausgelegt werden und zur Erhöhung der Beiträge der Versicherung führen. Es gilt dabei stets anzunehmen, dass nicht der Fahrer entscheidet, ob seine Daten wichtig sind und Konsequenzen haben, sondern der Besitzer der Daten. Datenschutz ist also unabhängig von der Kenntnis eines Bedrohungsszenarios relevant.

Aber auch aus Unternehmenssicht ist Datenschutz relevant. Federated Learning setzt voraus, dass viele Fahrzeuge Daten miteinander teilen. Hierbei könnte es sich um Flottenbetreiber handeln. Jedoch werden KFZ-Hersteller Fahrzeugdaten nur dann bereitwillig teilen, wenn der Schutz gegenüber Konkurrenzunternehmen, die sich ggfs. ebenfalls im Flottenverbund befinden, gewährleistet ist. Datenschutz ist auch hier wichtig, unabhängig von Kenntnis eines konkreten Bedrohungsszenarios. Es könnte beispielsweise sein, dass anhand der Flottendaten nachteilige Informationen zu bestimmten Marken in sozialen Netzwerken „viral“ gehen, selbst wenn diese sich bei genauerer Betrachtung als falsch interpretiert herausstellen. Es lässt sich vermuten, dass ein Flottenbusiness durch zuverlässige Geheimhaltung von Detailinformationen der Einzelfahrzeuge überhaupt erst möglich wird, da die KFZ-Hersteller sonst nicht bereit sind, ihre Daten zu teilen.

Es gibt also einen mehrdimensionalen Anreiz Datenschutz ernsthaft zu implementieren. Es lässt sich vermuten, dass Unternehmens- und Endkundeninteressen bezüglich Datenschutzes in Business-szenarien Hand in Hand gehen können.

Synergetische Implementierung

Die Implementierung der OTH-AW versucht in diesem Teilvorhaben, den europäischen Green Deal und Datenschutzkonzepte mit einem Businesskonzept so zu vereinigen, dass sich die unterschiedlichen und teils konträren Ziele gegenseitig ergänzen und bedingen. Es sollen also nachvollziehbare Synergieeffekte gefunden und technisch implementiert werden.

2.2 Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

In Abschnitt 2.1 wurde bereits kurz auf die Supply Chains (SC) eingegangen. Sämtliche Aktivitäten der Partner im Projekt wurden generischen Arbeitspaketen (WPs) zugeordnet. Jede SC-Entwicklung startet im Sinne eines typischen Automotive-V-Zyklus mit einer Anforderungsanalyse und endet mit Validierung und Test. Demzufolge wurde das Projekt in 6 technische Arbeitspakete untergliedert, die von einem Management-Arbeitspaket sowie einem eigenen Arbeitspaket für Ergebnisverbreitung, Verwertungsplanung, Rechtsvorschriften und Standardisierung flankiert werden. Die Gesamtstruktur zeigt Abbildung 4.

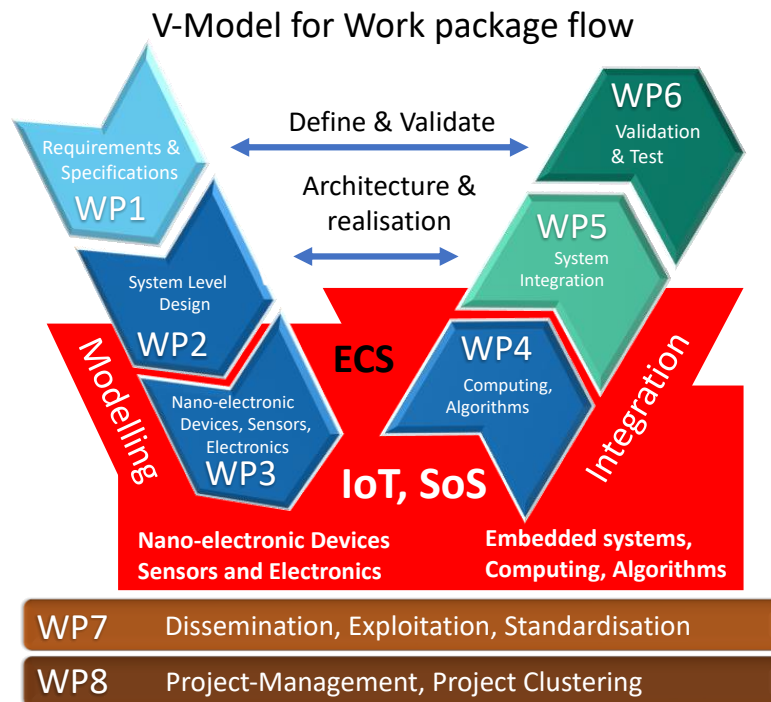


Abbildung 4: AI4CSM Struktur der Arbeitspakete

Eine sorgfältige Aufteilung der Arbeit und die Definition klarer Schnittstellen zwischen den verschiedenen Arbeitspaketen (WPs) waren für den Erfolg des AI4CSM-Projekts wichtig. AI4CSM hat sich für einen Ansatz entschieden, bei dem die Arbeitspakete die F&E-Bereiche mit Schwerpunkt auf Technologien und Methodik repräsentieren, während die Supply Chains inkl. den Objektives experimentelle Arbeiten und Implementierungsbemühungen repräsentierten, die zur Integration der Teilsysteme und ihrer Validierung führten. Auf diese Weise ergab sich die in Abbildung 5 gezeigte Matrixstruktur.

WP1 definierte die Systemanforderungen sowie die Anwendungsfälle und Validierungsmethoden. WP2 widmete sich dem Entwurf der Systeme und Subsysteme auf Architektur-, Funktions- und Komponentenebene. WP3 stellte die notwendigen Komponenten, einschließlich Halbleiterkomponenten und Hardware-Bauelemente, bereit und bewertete diese. WP4 befasste sich schließlich mit der Entwicklung von eingebetteten Systemen, einschließlich geeigneter Embedded, Computer- und IoT-Plattformen. Rückmeldungen von WP2, WP3 und WP4 wurden in die Ausarbeitung der Anforderungen und Spezifikationen entgegengenommen.

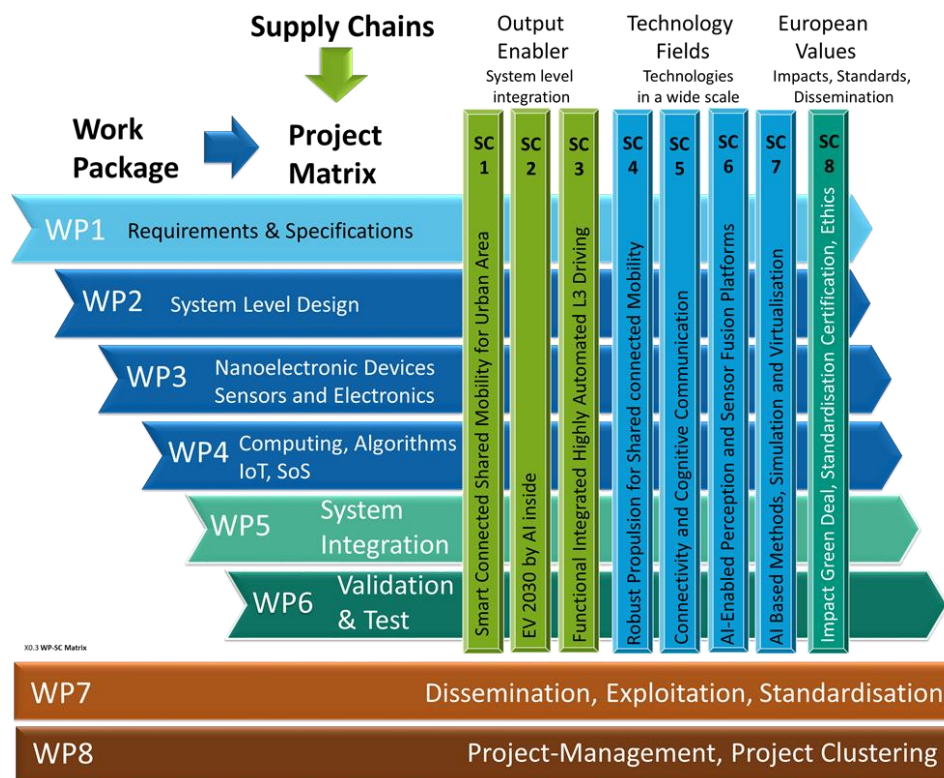


Abbildung 5: AI4CSM Matrixstruktur – Arbeitspakete (horizontal) und Supply Chains (vertikal)

Auf der rechten Seite des V erfolgte in WP5 die Systemintegration aller Supply Chains und den Proof of Concept für alle Demonstratoren. Im Rahmen von WP6 fand die Validierung und Prüfung der entwickelten Anwendungen statt. Der Schwerpunkt lag dabei auf der Zuverlässigkeitsvalidierung der entwickelten Systeme basierend auf den Demonstratoren. WP7 befasste sich mit der Nutzung, Verbreitung, Standardisierung und Beobachtung von Markttrends, um die von Wettbewerbern entwickelten Lösungen zu analysieren und die im Rahmen von AI4CSM gewonnen Erkenntnisse zu verbreiten. WP8 übernahm die Koordination und das Management des Gesamtprojekts, einschließlich aller finanziellen und vertraglichen Aspekte. Die Interaktion der Arbeitspakete ist im PERT-Chart (Abbildung 6) veranschaulicht.

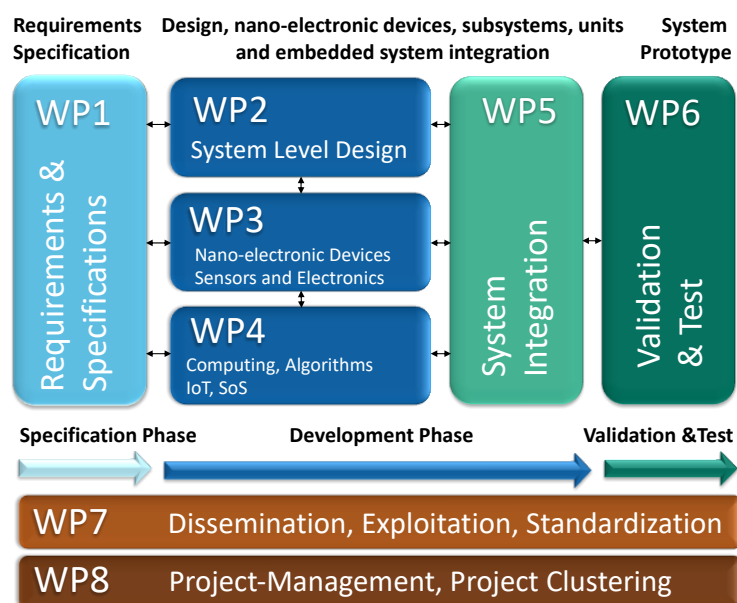


Abbildung 6: Abhängigkeiten zwischen den Arbeitspaketen (PERT-Chart)

Es gibt absichtlich erhebliche zeitliche Überschneidungen im Arbeitsplan (Abbildung 7), insbesondere zwischen WP2 bis WP5, um ein effizientes Feedback aus den einzelnen Phasen der Komponentenentwicklung, der Integration und des Testens zu ermöglichen. Damit konnte auf mögliche Schwierigkeiten rasch und adäquat reagiert werden. Gegebenenfalls auftretende unerwartete Probleme konnten durch eine Umgestaltung der Komponenten und der Softwareimplementierung gelöst werden.

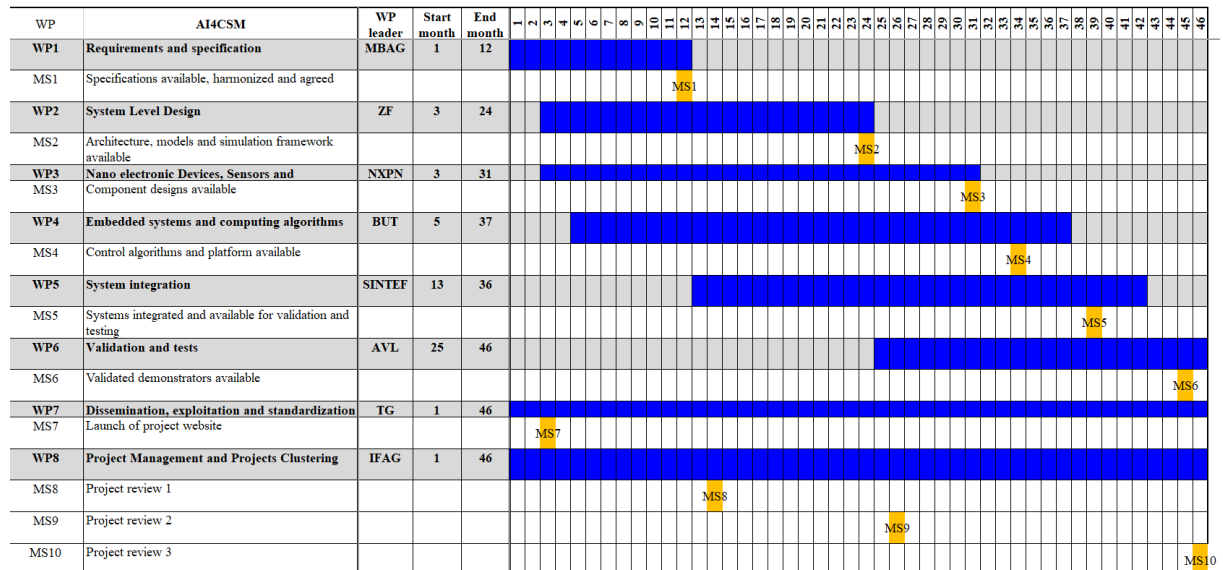


Abbildung 7: AI4CSM Balkenplan

Das auf eine Dauer von 3 Jahren ausgelegte Projekt AI4CSM startete Anfang Mai 2021. Dies erfolgte teils noch im Zeitraum der Ausbreitung der Corona-Pandemie, welche im Feb/März 2020 begann. Speziell den damit einher gehenden Lockdowns und Einschränkungen gerade im Laborumfeld und in Hinblick auf die eingeschränkte Reisefreiheit, welche die Zusammenarbeit mit den Projektpartner deutlich beeinträchtigte, ergaben sich bei mehreren Partnern Verzögerungen. Diese führten letztendlich zur Notwendigkeit einer Projektverlängerung um insgesamt 8 Monate, so dass das Projekt zum 28.02.2025 erfolgreich abgeschlossen wurde, wobei die Abschlussveranstaltung im Februar 2025 bei Mercedes in Stuttgart stattfand.

2.3 Wissenschaftlich-technischer Stand bei Projektstart

Flottenrouting

Zu Projektbeginn war Reinforcement Learning in verwandten Problemstellungen bereits etabliert, etwa im Bereich des Vehicle Routing Problems (VRP) sowie verwandter Varianten wie dem Electric Vehicle Routing Problem (EVRP). In der Domäne des Flottenroutings für Ridesharing fanden sich RL-Ansätze hauptsächlich in den Teilbereichen Pricing und Matching, jedoch kaum im Bereich des Routings. Inwieweit kommerzielle Anbieter Reinforcement Learning einsetzen, konnte nicht evaluiert werden. Der Stand der Technik in der Forschung basierte überwiegend auf Solvern, die auf Mixed-Integer Linear Programming (MILP) aufbauen und Lösungs-Methoden wie z.B. Ant Colony Optimization verwenden. Im Bereich der Potentialanalyse von Ridesharing gab es bereits Forschung, die darauf hindeutete, dass Ridesharing unter bestimmten Umständen die Anzahl von Parkplätzen reduzieren kann, als auch Lärm.

Reichweitenvorhersage für EVs

Zu Projektbeginn gab es bereits einen sehr großen Umfang in der Forschung. Hinzukommen Applikationen, die im Auto bereits die vermutete Reichweite anzeigen. Auch bei Google Maps gab es in der kostenlosen Variante bei Projektbeginn zumindest Vorschläge für Alternativrouten, die einen geringeren Verbrauch nahelegen.

Die Implementierungen der Unternehmen sind nicht öffentlich und können deshalb für eine Bewertung und Analyse nur sehr begrenzt herangezogen werden.

Aber auch die zugängliche Forschung in Form von Veröffentlichungen oder Artikeln ist extrem umfangreich. Im Folgenden werden die Vorarbeiten erläutert, die dem Teilvorhaben der OTH Amberg-Weiden im Projekt AI4CSM für die Supply Chain 2 relevant sind.

Problemstellung

Um den Klimawandel zu verlangsamen, muss der Ausstoß von Treibhausgasen weltweit in allen Sektoren reduziert werden. In der Europäischen Union schätzt beispielsweise die Europäische Umweltagentur, dass der Transportsektor im Jahr 2021 für 22 % der gesamten Emissionen verantwortlich war [1]. Dies bedeutet ein hohes Einsparpotenzial.

Laut der Strategie der Europäischen Union für einen emissionsarmen Verkehr ist der Einsatz von Elektrofahrzeugen anstelle von Fahrzeugen mit Verbrennungsmotoren als Personenkraftwagen eine bevorzugte Lösung, um CO₂-Emissionen und Schadstoffe effektiv zu reduzieren [2]. Daher muss der Marktanteil von Elektroautos erheblich steigen. In den letzten Jahren ist der Anteil von batterieelektrischen Fahrzeugen an den Neuzulassungen in der Europäischen Union deutlich gestiegen, liegt jedoch immer noch unter 10 % [3].

Ein Grund für die Zurückhaltung der Kunden beim Kauf von vollelektrischen Fahrzeugen ist die sogenannte Reichweitenangst (range anxiety) [4]. Dieses Problem könnte durch eine hochpräzise Vorhersage des Energieverbrauchs während der Fahrt gelöst werden. Dadurch könnten Routenplaner geeignete Lade- und Routenentscheidungen treffen. Unterschiedliche Routen könnten hinsichtlich ihres Energiebedarfs bewertet werden, und alternative Strecken mit geringerem Energieverbrauch könnten vorgeschlagen werden.

Stand der Technik

Zahlreiche verschiedene Parameter beeinflussen den Energieverbrauch von Elektrofahrzeugen im realen Betrieb – von Geschwindigkeitsprofilen über die Nutzung und Effizienz von Heizungs-, Lüftungs- und Klimasystemen (HVAC) bis hin zu Wetter- und Umweltbedingungen [5]. Aktuelle Elektrofahrzeuge verlassen sich oft auf historische Energieverbrauchsdaten, um die verbleibende Reichweite zu schätzen [6]. Der Renault Zoe berücksichtigt beispielsweise den durchschnittlichen Verbrauch der letzten 200 km [7]. Diese Methode ist jedoch ungenau, da sich die Faktoren, die den Energieverbrauch beeinflussen, oft erheblich über die Zeit verändern.

Ein besserer Ansatz, der in der Forschung ein zentrales Thema ist und bereits in einigen kommerziellen Anwendungen wie der App "A Better Routeplanner (ABRP)" [8] oder den Navigationssystemen der Tesla Model 3-Fahrzeuge [9] implementiert wurde, ist eine modellbasierte Vorhersage des Energieverbrauchs. Diese kann beispielsweise auf statistischen, probabilistischen oder physikalischen Modellen basieren und mehrere Einflussfaktoren berücksichtigen, wie z. B. Geschwindigkeitsbegrenzungen auf der gefahrenen Route und das Wetter [6].

Physikalische Modelle werden speziell für jeden Fahrzeugtyp entwickelt und simuliert, und können den Energieverbrauch nur auf Basis bekannter Geschwindigkeitsprofile berechnen [10]. Daher bleibt die

Herausforderung bestehen, die Geschwindigkeitsprofile vorherzusagen. Da Geschwindigkeit und Beschleunigung von vielen schwer zu modellierenden Faktoren abhängen, z. B. dem Fahrstil des Fahrers, eignen sich datenbasierte Methoden am besten für präzise Vorhersagen. Diese können statistische oder KI-basierte Methoden sein.

Auch die Vorhersage des Energieverbrauchs mit diesen Ansätzen bietet Vorteile gegenüber physikalischen Modellen. Erstens kann die Berechnung schneller durchgeführt werden [6]. Zweitens entfällt der Aufwand für die Kalibrierung und Validierung physikalischer Modelle für jeden einzelnen Fahrzeugtyp durch reale Tests oder Prüfstandtests [10]. Darüber hinaus berücksichtigt sie dynamische Veränderungen bestimmter Faktoren wie den Rollwiderstand, der sich im Laufe der Zeit ändern kann, beispielsweise durch den Wechsel oder Verschleiß der Reifen.

Für die Untersuchung der eingefahrenen Trainingsdaten soll, soweit möglich, ein physikalisches Modell verwendet werden. Das physikalische Modell berücksichtigt alle Kräfte, die von außen auf ein sich bewegendes Fahrzeug einwirken, sowie die Traktionskraft F_T , die vom Antriebsstrang des Fahrzeugs aufgebracht wird, um es in Bewegung zu setzen. Gemäß [11] und den Newtonschen Gesetzen gleichen sich die Kräfte wie folgt aus:

$$F_T = \underbrace{\frac{dv}{dt} * f * m}_{\text{Beschleunigung}} + \underbrace{m * g * \sin \alpha}_{\text{Steigung}} + \underbrace{m * g * \cos \alpha * c_{rr}}_{\text{Rollwiderstand}} + \underbrace{\frac{\rho * A * c_w}{2} * v^2}_{\text{Luftwiderstand}}$$

Verfügbare Trainingsdatensätze

Wie oben erwähnt, erfordert die Forschung zur datengetriebenen Vorhersage des Energieverbrauchs oder zur Prognose von Geschwindigkeits- und Beschleunigungsprofilen für Elektrofahrzeuge geeignete Trainingsdaten. Diese Daten müssen während der Fahrt von Elektrofahrzeugen auf öffentlichen Straßen unter vielfältigen Bedingungen aufgezeichnet werden, um aussagekräftig zu sein und Overfitting beim Trainieren eines Modells mit diesen Daten zu vermeiden. Informationen darüber, welcher Fahrer welche Fahrt durchgeführt hat, sind notwendig, um Fahrerprofile zu erstellen, die für die Vorhersage von Geschwindigkeit und Beschleunigung essenziell sind.

In den letzten fünf Jahren gab es mehrere Veröffentlichungen zu datengetriebenen Energieverbrauchsprognosen für Elektrofahrzeuge auf Basis realer Fahrdaten. Masikos et al. verwendeten ein allgemeines Regressions-Neuronales Netz (GRNN) für die Energieverbrauchsprognose und nutzten Modelltrainings- und Validierungsdaten, die von einem Elektrofahrzeug gesammelt wurden, das in der Stadt Chieri in Italien fuhr [12]. Dieser Datensatz umfasst jedoch nur 1826 km, und jede Fahrt wurde vom selben Fahrer durchgeführt [12]. Qi et al. verwendeten Fahrdaten eines Elektrofahrzeugs, das von verschiedenen Fahrern unter unterschiedlichen Wetter- und Verkehrsbedingungen in Südkalifornien gefahren wurde, um eine Dekompositionsanalyse des Energieverbrauchs durchzuführen [13]. Auf dieser Grundlage entwickelten die Forscher KI-basierte Modelle zur Schätzung des Energieverbrauchs [13]. Dieser Datensatz weist jedoch eine geringe Vielfalt auf, da er nur drei verschiedene Routen enthält, die jeweils mehrfach befahren wurden [13]. Zhang et al. entwickelten ein auf maschinellem Lernen basierendes Framework unter Verwendung von Fahrdaten von 55 Elektro-Taxis in Peking sowie Daten zu Umwelt- und Verkehrsbedingungen [14]. Die Fahrdaten wurden von Chinas nationaler Überwachungs- und Verwaltungsplattform für neue Energiefahrzeuge gesammelt [14].

Föderiertes Lernen und Datenschutz

Das Konzept von föderiertem Lernen wurde zuerst im Jahr 2016 [15] beschrieben, bei dem mehrere Geräte (z. B. Smartphones) gemeinsam ein Modell trainieren, ohne ihre Rohdaten mit einem zentralen

Server zu teilen. Stattdessen werden nur die Modellupdates (Gradienten) übermittelt, um Datenschutz und Effizienz zu gewährleisten.

Das Konzept der **Differential Privacy** [16] ist eine formale Methode zum Schutz individueller Daten in statistischen Analysen. Es zeigt, wie durch die Laplace-Mechanismus genannte Methode gezielt Rauschen an Datenbankabfragen angepasst wird, um die Privatsphäre zu wahren, während die statistische Genauigkeit weitgehend erhalten bleibt.

Das Konzept der **Secure Aggregation-Methode** [17] für Federated Learning vor, die sicherstellt, dass Modellupdates von einzelnen Clients verschlüsselt und nur als Gesamtsumme entschlüsselt werden können. Dadurch wird die Privatsphäre der Teilnehmer geschützt, indem verhindert wird, dass der Server einzelne Beiträge sieht, während trotzdem ein gemeinsames Modell trainiert werden kann.

Das Konzept von **Fully Homomorphic Encryption (FHE)** [18] stellt sicher, dass Modellupdates verschlüsselt bleiben und vom Server verarbeitet werden können, ohne sie zu entschlüsseln. Dadurch wird die Privatsphäre der Teilnehmer geschützt, während das Training effizient bleibt und Angriffe auf die Modellparameter durch den zentralen Server verhindert werden.

2.4 Bisherige Arbeiten des Antragstellers

Die Ostbayerische Technische Hochschule Amberg-Weiden brachte in die Arbeiten für AI4CSM umfangreiche Vorerfahrungen aus früheren Projekten in den Bereichen automatisiertes Fahren, Mobilfunkkommunikation, und sichere Software ein, z. B.

- (BMBF) AUTOSAFE (Verkehrszeichenerkennung, Signalverarbeitung für Nahbereichs-Radarsensoren, Fahrzeug-Server-Kommunikation zum Monitoring von Versuchsfahrzeugen). [19]
- (EU) HAVEit (Radarsignalverarbeitung und Datenfusion für ein Netzwerk aus Radarsensoren, ausgerichtet auf Sicherheitsanwendungen in Fahrzeugen) [20]
- (BMW) UR:BAN (Radarsignalverarbeitung für das urbane Umfeld, Parklückenerkennung und -vermessung) [21]
- (BMW) Ko-HAF Kooperatives hochautomatisiertes Fahren (Mobilfunkkommunikation zwischen Fahrzeugen und Backend v.a. für kooperative kollektive Perzeption)
- MotorBrain (Embedded Programmierung, Redundanzen und Sicherheit) [22]
- (EU) eDAS (Holistisches Energie-Management für E-Fahrzeuge der dritten und vierten Generation) [23]
- (ECSEL) 3Ccar (Fahrzeug-zu-Server Kommunikation für neue Dienste für E-Fahrzeuge) [24]
- (ECSEL) AutoDrive (Sichere auf Mobilfunk LTE basierende Fahrzeug-Server-Kommunikation) [25]
- (ECSEL) Prystine (Dynamisch geformte zuverlässige Mobilkommunikation für das automatisierte Fahren) [26]
- (ECSEL) AI4DI (KI-Algorithmen für die Optimierung von verteilten Datenverarbeitungsketten in heterogenen Rechnernetzen) [27]
- (BMW) KI-ASIC (Radarverarbeitung für gepulste neuronale Netze) [28]
- (H2020) 1000kmPLUS (Serverbasiertes Routing optimiert für E-Fahrzeuge) [29]
- (StMW) AUTBUS (Automatisierter Rufbus) [30]

Diese Projekte markieren den Stand der Technik bei Projektstart von AI4CSM.

2.5 Zusammenarbeit mit anderen Stellen

Zur Erreichung der ambitionierten Herausforderungen von AI4CSM war eine Zusammenarbeit auf verschiedenen Ebenen der Entwurfs- und Supply-Chains erforderlich. Auf europäischer Ebene arbeiten in AI4CSM 41 Stakeholder (s. Tabelle 1) auf allen beteiligten Ebenen der Wertschöpfungskette zusammen. Weitere Zusammenarbeit mit Dritten fand seitens OTH-AW nicht statt.

Tabelle 1: AI4CSM Konsortium

Teilnehmer Nr.	Teilnehmer	Kurzzeichen	Land
1 (Koord.)	Infineon Technologies AG	IFAG	DE
2	NXP Semiconductors Germany GmbH	NXPDE	DE
3	Mercedes-Benz AG	MBAG	DE
4	AI Digital solutions GmbH	AIDG	DE
5	Fraunhofer Gesellschaft zur Förderung der Angewandten Forschung e.V. (IISB & HHI)	FHG	DE
6	Hochschule Offenburg	HSO	DE
7	Institut für Digitalisierung der Dinge DIGITH GmbH	DIGITH	DE
8	Ostbayerische Technische Hochschule Amberg-Weiden	OTH	DE
9	Technische Universität Dresden	TUD	DE
10	ZF Friedrichshafen AG	ZF	DE
11	Technische Universität Dortmund	TUDO	DE
12	emo-bike GmbH & Co. KG	FEDDZ	DE
13	AVL List GmbH	AVL	AT
14	Infineon Technologies Austria AG	IFAT	AT
15	TTTAUTO Auto AG	TTTAUTO	AT
16	Virtual Vehicle Research GmbH	VIF	AT
17	AIT Austrian Institute of Technology GmbH	AIT	AT
18	TECHNISCHE UNIVERSITÄT GRAZ	TUGRAZ	AT
19	TECHNISCHE UNIVERSITÄT WIEN	TUWIEN	AT
20	SINTEF AS	SINTEF	NO
21	PAXSTER AS	PAXSTER	NO
22	NXTECH AS	NXTECH	NO
23	Interuniversitair Micro-Electronica Center	IMEC	BE
24	Vysoke Uceni Technicke V Brne	BUT	CZ
25	Institut Mikroelektronických Aplikací S.R.O.	IMA	CZ

26	Ideas & Motion SRL	I&M	IT
27	INFINEON Technologies Italy SRL	IFI	IT
28	VEM Solutions SpA	VEM	IT
29	Politecnico di Torino	POLITO	IT
30	University degli studi di Modena e Reggio Emilia	UNIMORE	IT
31	Bylogix SRL	BYLO	IT
32	Sleep Advice Technologies Srl	SAT	IT
33	Waterview SRL	WVIEW	IT
34	Innatera Nanosystems BV	INNAT	NL
35	Technische Universiteit Delft	TUDELFT	NL
36	NXP Semiconductors Netherlands BV	NXPN	NL
37	UAB TERAGLOBUS	TG	LT
38	Vilniaus Gedimino Technikos Uiversitetas	VGTU	LT
39	Elektronikas un Datorzinatnu Instituts	EDI	LV
40	Teraglobus Latvia SIA	TGLV	LV
41	Infineon Technologies India Pvt. Ltd.	IFIN	INDIA

3 Durchgeführte Arbeiten und erreichte Ergebnisse

SC1 Virtual City Routing

Im **ersten Projektjahr** wurde der aktuelle Stand der Technik analysiert, die Anforderungen definiert und der Digital Twin aufgesetzt.

- Untersuchung des Stands der Technik zur Energievorhersage
- Experimente zur Berechnung des kürzesten Pfads für Punkt-zu-Punkt-Verbindungen
- Initiale Erstellung des Digital Twins auf Basis historischer Verkehrsdaten der Stadt Amberg
- Berechnung der Abholstationen anhand eines statistischen Modells
- Entwicklung des Energievorhersagemoduls zur Bewertung von Routen
- Aufstellung der Anforderungen für das Gesamtsystem
- Workshop in Linz zur Vorbereitung der Anforderungen

Im **zweiten Projektjahr** wurden erste Algorithmen basierend auf dem Digital Twin und der Energiesimulation entwickelt.

- Erster Ansatz für das Flottenrouting mittels Reinforcement Learning, basierend auf klassischen Deep-Learning-Methoden
- Erstellung des System-Level-Designs

Im **dritten Projektjahr** lag der Fokus auf der Implementierung. Es wurde ein neuer Routing-Ansatz verfolgt und die Integration durchgeführt, insbesondere für verkehrsoptimiertes Routing.

- Entwicklung eines neuen Reinforcement-Learning-Ansatzes auf Basis von Transformern
- Implementierung der Steuerungsschnittstelle für das Live-Routing des Robo-Taxis
- Integrations-Workshop in Graz
- Implementierung des Live-Routings

Im Rahmen der **Verlängerung** wurde die Evaluierung der Algorithmen intensiviert und die Abschlusspräsentation vorbereitet und durchgeführt. Dabei wurden unter anderem das Routing und die Schnittstelle zum Robo-Taxi demonstriert.

- Vergleich verschiedener Mobilitätsmodi: Selbstfahrer, öffentlicher Nahverkehr, Taxi, Ridesharing, Fußgänger
- Finalisierung der Schnittstelle zum Robo-Taxi
- Erstellung einer Demonstrationswebsite
- Abschlusspräsentation

SC2

Während des **ersten Projektjahrs** konzentrierten sich die Arbeiten der OTH Amberg-Weiden in AI4CSM auf die Einarbeitung und Vorbereitung von Testfahrten:

- Untersuchung des Stands der Technik bezüglich Reichweitenvorhersage. Daraus wurden besonders vielversprechende Paper für eine spätere Implementierung ausgewählt.

- Auf dem Kenntnisstand der Wissenschaft aufbauend wurden Konzepte und mögliche Datenquellen eruiert. Beispielsweise sollte versucht werden, aktuelle Wetter- und Winddaten während der Fahrt von verschiedenen Wetterstationsdiensten aufzuzeichnen.
- Es wurde untersucht, inwieweit gute Trainingsdaten bereits verfügbar sind. Es wurde jedoch kein zufriedenstellendes Trainingsset gefunden
- Es wurde entschieden, Testfahrten durchzuführen um dabei die als relevant definierten Daten aufzuzeichnen.
- Verschiedene EV-Betreiber wurden bezüglich ihrer Zugänglichkeit zu Daten eruiert. Am auskunftsfreudigsten zeigte sich Tesla, auch aufgrund einer aktiven Fanbasis, die die CAN-Kommunikation in größeren Teilen reverse Engineered hat.
- Mit dem Auto-Verleiher wurde vertraglich vereinbart, Daten über die ODB-Schnittstelle aufzeichnen zu dürfen. Zusätzlich wurde der Zugang zum Tesla-Account des Fahrzeugs geteilt, so dass die aktuelle Fahrdaten online abgegriffen werden können.
- Das komplette Hard- und Softwarekonzept zur Datenaufzeichnung und Datenfusion wurde geplant und umgesetzt.

Während des **zweiten Projektjahres** konzentrierten sich die Arbeiten der OTH Amberg-Weiden in AI4CSM auf die Durchführung von Testfahrten sowie Bereinigung und Auswertung der aufgezeichneten Daten:

- Durchführen von Sommertestfahrten. Dazu musste nicht nur das Vertragswerk unterschrieben, es musste auch ein diverses Testteam eingewiesen und organisiert werden.
- Nach jeder Testfahrt wurden die verschiedenen Datenquellen in einem ersten Schritt aufbereitet, korreliert und geprüft.
- Im Anschluss an die Testfahrten wurden die Daten analysiert. Dazu wurden ein physikalisches Modell und andere Datenquellen herangezogen, um die aufgezeichneten Daten zu untersuchen, zu plausibilisieren und zu validieren.
- Die Ergebnisse und Mehrwert bestimmter Datenquellen wurde konkret untersucht und bewertet. Beispielsweise sind aktuelle Wetterdaten kaum auf den Fahrbetrieb anwendbar.
- Es wurden Wintertestfahrten vorbereitet. Dazu wurden die Erkenntnisse der Sommerfahrten genutzt, um den Workflow zu verbessern. Auch wurden für die Wintertestfahrten zusätzliche Datenfelder in die Aufzeichnung aufgenommen.
- Im zweiten Projektjahr erfolgte im Januar / Februar eine zweite Serie von Testfahrten, bei denen ebenfalls ein Tesla Performance 3 verwendet wurde. Es handelte sich nicht um das gleiche Fahrzeug, aber ein Fahrzeug das nur knapp ein Jahr später gebaut wurde.
- Auch wurde hier mit konkreten Planungen zum Hardwaredemonstrator begonnen.

Während des **dritten** Projektjahres widmete sich die OTH Amberg-Weiden in AI4CSM der Datenbereinigung der Testfahrten des Aufbaus des Hardwaredemonstrators.

- Untersuchung der Testfahrten mittels Korrelationsmatrix und Bestimmtheitsmatrix (R^2) sowie mehrdimensionaler Darstellung aufgezeichneter Parameter zur Plausibilisierung und Validierung der Daten. Darüber hinaus fördert dies ein intuitiveres Verständnis der Messdaten.
- Implementierung von vielversprechenden Papern und Bewertung. Dies gestaltete sich schwierig, da insbesondere der KI-Anteil, auch nach Rücksprache mit den Paperautoren, nicht rekonstruiert werden konnte.
- Untersuchung von Föderiertem Lernen hinsichtlich Datenschutzes und weiterführenden Konzepten wie Secure Aggregation, Differential Privacy und Fully Homomorphic Encryption.

Als Folge wurden alle diese Konzepte zurückgewiesen, auch insbesondere nach Studium aktueller Paper, die den tatsächlichen Datenschutz durch all diese Konzepte in Frage stellen.

- Auswahl des Konzeptes der Datenökonomie (Datenminimalismus) als Leitkonzept für die algorithmische Implementierung und Entwicklung eines Maschinenlernkonzepts in Flower
- Planung des Hardwareaufbaus und Implementierung und Test von Flower in Python
- Zum Testen und zur Demonstration der Implementierung wurden interaktive Websites in HTML, CSS und JavaScript programmiert.

In der Projektverlängerung widmete sich die OTH Amberg-Weiden der Finalisierung des Demonstrators, der Dissemination auf einer einschlägigen Konferenz und der Vorbereitung der Abschlusspräsentation.

- Finalisierung, Implementierung und Optimierung der Reichenweitenvorhersage und Test im Demonstrator
- Umfangreiches Testen des Demonstrators.
- Präsentation der Projektergebnisse auf der European Edge AI Conference – Oktober 2024 - in Cagliari, Sardinien
- Vorbereitung und Halten der Abschlusspräsentation.

3.1 Arbeiten und Ergebnisse WP1: Anforderungen

Für das Virtual City Routing wurden in WP1 die Anforderungen für den Digital Twin definiert als auch umgesetzt. Es wurden dabei der Umfang des Digital Twin und der Umliegenden Bausteine wie z.B. Abholzonen definiert. In Deliverable 1.1 wurden die KPIs festgelegt. Diese umfassten insgesamt 17 Anforderungen zu

- Energieeffizienz & Routenoptimierung
- Leistungsfähigkeit des Routingsystems
- Betriebsmodi & Schnittstellen
- Externe Datenquellen & Verkehrsmodelle

Im Rahmen von WP1 wurden die Anforderungen an das KI-Training definiert. Dabei galt es, nicht nur Anforderungen des Trainings an sich, sondern auch Anforderungen der technischen Integration in ein Gesamtsystem (Mercedes EQC) zu eruieren. Dazu war es notwendig, einerseits Anforderungen zu definieren, mit denen eine Datenweiterleitung von Fahrparametern an das KI-System ermöglicht wird und andererseits eine Ankopplung an die Supply Chain 1 (Routenoptimierte Fahrtstreckenauswahl) zu ermöglichen. Letztlich sollte in SC1 die Funktion eines Rufbusses implementiert werden, der energieoptimal Strecken zwischen Kunden abfährt. Die Ergebnisse der OTH Amberg-Weiden aus SC2 sollten hier als eine Inputgröße dienen.

Zusammengefasst ergaben sich aus Sicht der OTH Amberg-Weiden in der Supply Chain 2 drei wesentliche Anforderungsbereiche:

- Anforderungen bezüglich des Föderierten Lernens
- Anforderungen bezüglich der Integration in einen Mercedes EQC
- Anforderungen bezüglich der Integration in das KI-Konzept zur Routenoptimierung der Supply Chain 1

Für die Analyse und Evaluierung wurde eine Simulationsumgebung aufgebaut. Abbildung 8 zeigt eine Übersicht der erstellten Simulation.




Abbildung 8: Verkehrssimulation der Stadt Amberg

Die Anforderungen bezüglich föderierten Lernens beziehen sich auf die Datenquellen, die zur Energieabschätzung notwendig sind. Dazu gehören GPS-Position, Geschwindigkeit, momentaner Leistungsverbrauch in Verbindung mit externen Datenquellen wie des Straßentyps (Innenstadt, Landstraße, Autobahn) oder Wetterbedingungen (Deutscher Wetterdienst, Open Weather Map) und auch Höhendaten, die in hoher Präzision dem bayerischen Höhenatlas entnommen werden können.

Die Anforderungen bezüglich der Integration in einen Mercedes EQC beziehen sich auf vermutete notwendige Rechenleistung, hinreichend gute Funknetzverbindung oder die CAN-Kommunikation, über die der Mercedes EQC Daten für das KI-Training bereitstellen muss.

Die Anforderungen bezüglich der Integration in das KI-Konzept zur Routenoptimierung der Supply Chain 1 definieren das Interface von Supply Chain 1 und Supply Chain 2 oder diskutieren die Qualität der Energieabschätzung.

Darüber hinaus wurde anhand des Standes der Wissenschaft eine konzeptionelle Umsetzung des Föderierten Lernens entwickelt und dokumentiert. Bereits hier wurde die Idee der Implementierung eines individualisierten Modells diskutiert.

Die Ergebnisse wurden aufbereitet und im Deliverable 1.2 eingebracht.

Das KI-Konzept wurde in WP2 konzeptionell ausgearbeitet. Hier wurde die konkrete und wesentliche theoretische Ausarbeitung des KI-Konzepts erforscht und in WP4, WP5 und WP6 bis hin zu einem Tischdemonstrator implementiert. Eine Bewertung der Erfüllung der Requirements erfolgte in WP6 in den Deliverables 6.1 und 6.2.

3.2 Arbeiten und Ergebnisse WP2: System Design

In WP2 wurde in SC1 die System Architektur des Gesamtsystems entwickelt, die in Abbildung 1 gezeigt ist. Des Weiteren wurde der Digital Twin entwickelt. Schritte waren u.a.:

- Einlesen der Karte von OpenStreetMap
- Nachbearbeitung des Kartenmaterials
- Erstellung von Verkehrsbelastung für 24h
- Platzierung von Abholstationen über die Stadt anhand von statischem Modell (siehe Abbildung 9, Abbildung 10 und Abbildung 11)
- Weitere Elemente wie Ladestationen

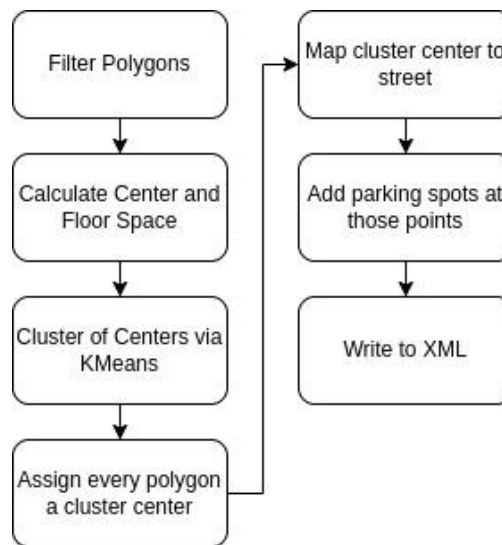


Abbildung 9: Algorithmus zur Bestimmung der Abholstationen

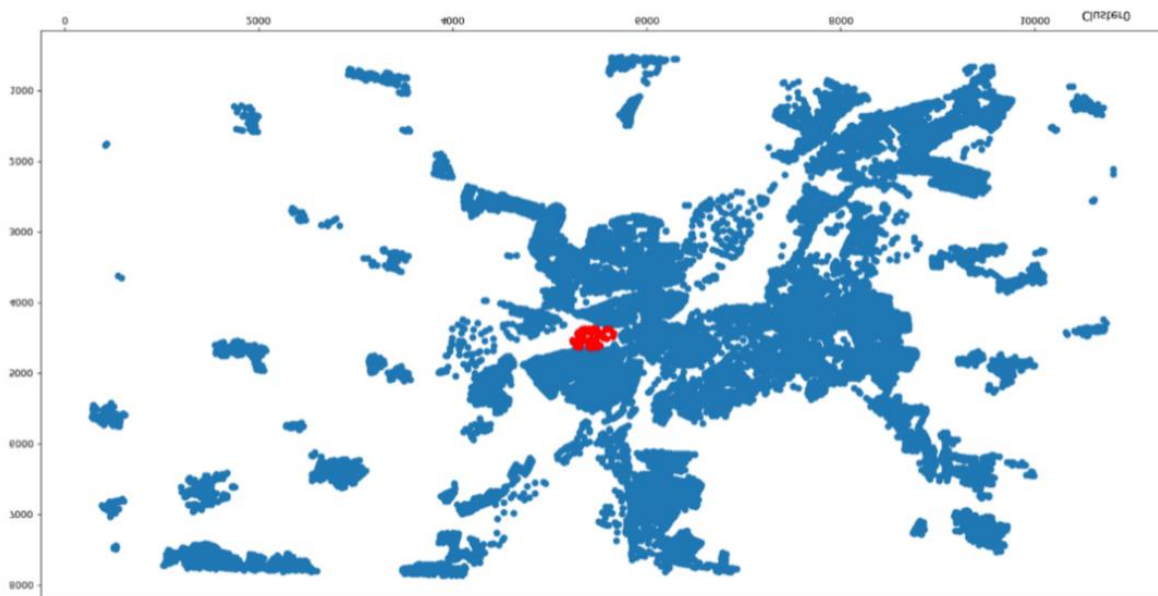


Abbildung 10: K-Means Algorithmus zur Stationsfindung

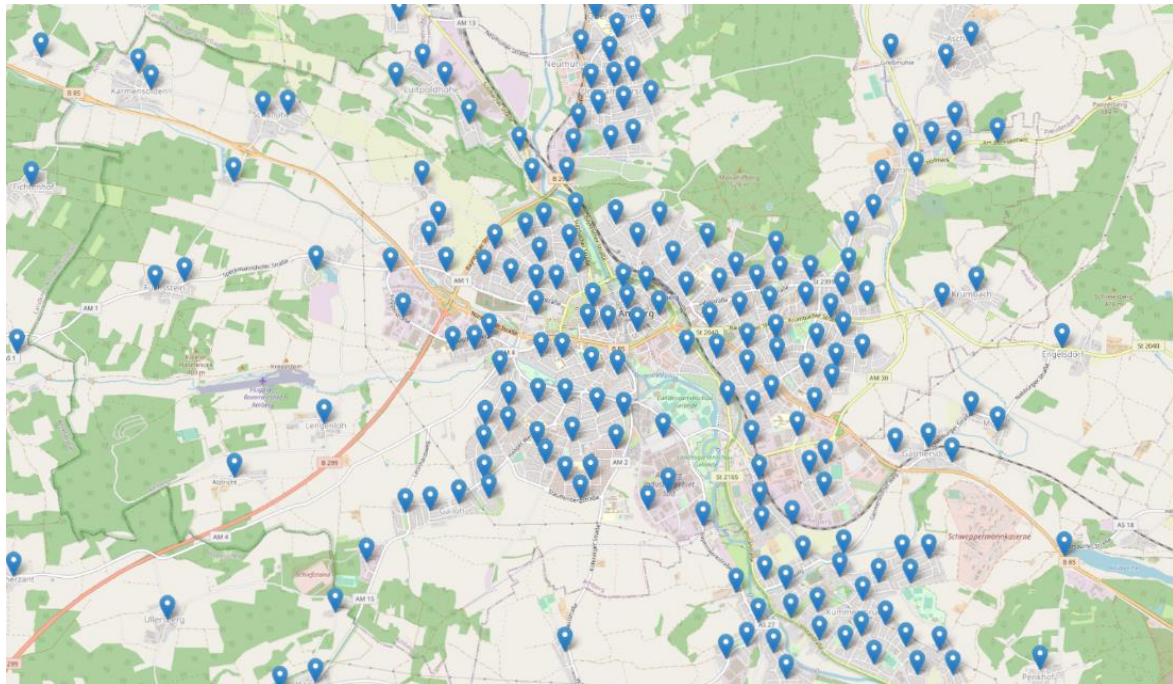


Abbildung 11: Abholstationen verteilt über Amberg

Für das Routing-Modul wurde zunächst ein erster Entwurf entwickelt, der auf **Stable Baselines** basierte, mit etablierten Reinforcement Learning Algorithmen wie PPO/A3C. Im weiteren Verlauf des Projekts wurde dieser jedoch durch einen leistungsfähigeren Ansatz auf **Transformer-Basis** ersetzt.

Die Arbeiten WP2 umfassten die Planung, Vorbereitung und Durchführung von Testfahrten zur Aufzeichnung von Trainingsdaten. Danach erfolgten die Bereinigung, Untersuchung und Auswertung der aufgezeichneten Daten mittels eines physikalischen Modells.

Für die Planung der Testfahrten wurden zunächst die notwendigen Rahmenbedingungen festgelegt. Diese verfolgen einerseits das Ziel, einen möglichst diversen Datensatz zu erzeugen, andererseits sind die Projektressourcen begrenzt. Die OTH Amberg-Weiden hat ein diverses Testteam von 16 Fahrern (männlich/weiblich) im Alter meisten von 18 – 30 Jahren aus Studenten und Mitarbeitern des Teams Automotive der OTH Amberg-Weiden zusammengestellt. Diese fuhren im Rahmen von Testfahrten in Amberg, Schwandorf und Regensburg ca. 13.000 km Daten ein, während Fahrdaten aufgezeichnet wurden. Das Ergebnis ist ein Datensatz aus Kleinstadt, Großstadt und Überlandfahrten auf Landstraßen und Autobahnen.

Alle regulatorischen Bedingungen wie Versicherungen für alle Fahrer und die Erlaubnis, die Daten des Testfahrzeugs auszulesen, lagen vor. Die Wahl fiel auf einen Tesla Model 3 Performance (kurz Tesla). Dieser ist aufgrund einer großen Fanbase besonders auskunftsfreudig.



Abbildung 12: Foto des ausgeliehenen Tesla 3 Performance für die Sommertestfahrten 2022

Die Datenpipeline zur Datenaufzeichnung ist sehr komplex und erfordert den Zukauf von Hardwarekomponenten sowie die Nutzung frei verfügbarer Software. Es gibt zwei Methoden, um Fahrdaten vom Tesla auszulesen. Einerseits über den Tesla.com-Account und andererseits über die ODB2-Schnittstelle des Teslas. Die zwei Ansätze sind in folgendem Bild illustriert. Auch angedeutet ist das Korrelieren der Daten.

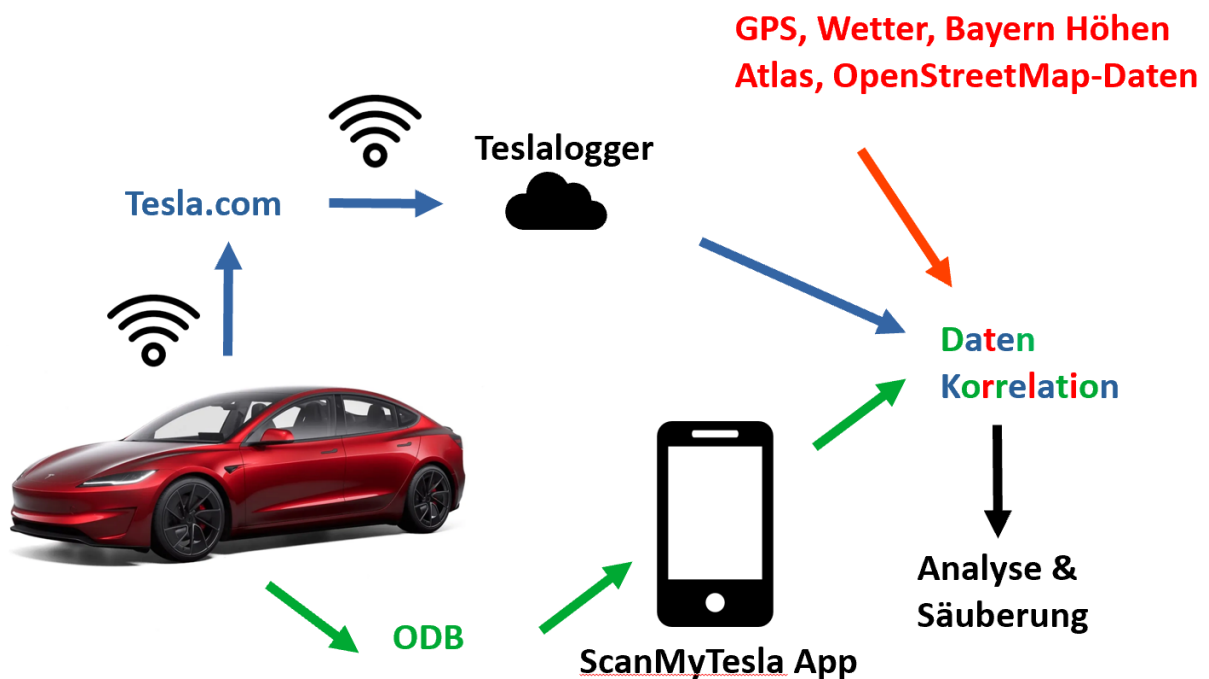


Abbildung 13: Datenaufzeichnungspipeline

An die ODB-Schnittstelle des Tesla wird der ODBLink LX Bluetooth angeschlossen. Es wurde ein Smartphone angeschafft, auf dem die ScanMyTesla-App während der Fahrten Daten aufzeichnet. Die Daten werden drahtlos per Bluetooth von der ODB-Schnittstelle direkt an das Smartphone gesendet

und über die ScanMyTesla-App der Firma EMDS e-mobility driving solutions aufgezeichnet. Der beschriebene Datenpfad ist in Abbildung 9 in grün dargestellt.

Zusätzlich gibt es einen Datenpfad, über den das Fahrzeug aktuelle Daten direkt an den Tesla.com-Fahrzeugaccount sendet. Dies setzt eine Funkverbindung voraus, ansonsten entstehen Datenlücken. Vom Tesla.com-Fahrzeugaccount können die Daten instantan von der Website aufgezeichnet werden. Dazu hat die OTH Amberg-Weiden eine entsprechende Softwareumgebung namens Teslalogger (<https://github.com/bassmaster187/TeslaLogger>) ausgewählt, auf einem Server der OTH Amberg-Weiden installiert und in Betrieb genommen. Während der Fahrten zeichnet der Server die Daten des Tesla-Accounts auf und speichert diese in einer Maria-Datenbank ab. Die Teslalogger Software enthält ein Visualisierungstool namens Grafana. Die Teslalogger Software wurde für die Bedürfnisse des Projekts etwas angepasst. Nach jeder Testfahrt wurden die aufgezeichneten Daten mittels Grafana evaluiert und auf Plausibilität geprüft. Darüber hinaus wurde ein Screenshot aufgenommen, um einen Eindruck der gefahrenen Strecke zu geben. Die folgende Abbildung zeigt einen Screenshot der Grafana-Software nach einer abgeschlossenen Testfahrt. Die gefahrene Strecke über Schwandorf bis nach Regensburg ist rechts in blau dargestellt. Auf der linken Seite sind die aufgezeichneten Parameter dargestellt. Die Testfahrt dauerte ca. 5 Stunden. Gegen 17 Uhr wurde das Fahrzeug aufgeladen.

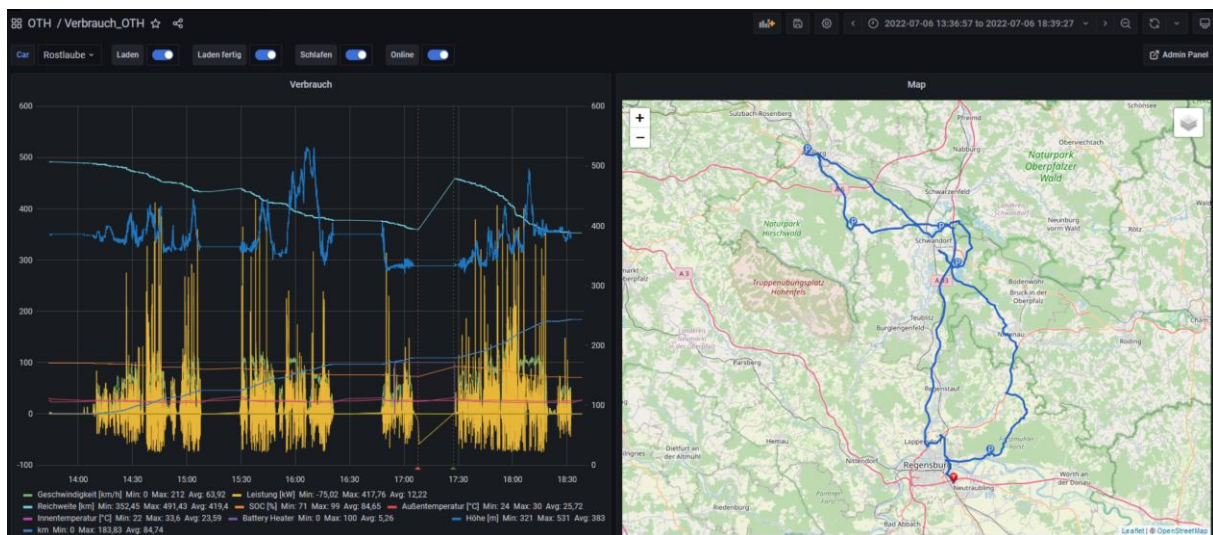


Abbildung 14: Auswertung mittels Grafana nach einer Testfahrt. Die aufgezeichneten Daten sind plausibel.

Nach dieser grundlegenden Untersuchung der aufgezeichneten Daten ist ein erheblicher Aufbereitungsaufwand notwendig. Dazu wurden eine Reihe von Pythonskripten programmiert und mehrere Tools und Dienste verwendet.

Abbildung 15 unten stellt den zuvor beschriebenen Datenaufzeichnungsprozess grafisch dar. Die Teslalogger Software speichert die Daten in einer Maria-Datenbank. Diese müssen für eine Datenkorrelation mit den Daten der ScanMyTesla-App als csv-Datei extrahiert werden. Dafür wurde dBeaver verwendet.

Nach dem Ausleiten der Teslalogger-Daten werden diese mit den Daten der ScanMyTesla-App und obigem Screen in einen Ordner für jede Testfahrt mit zusätzlich Informationen zur Plausibilität der Daten abgelegt. Dies ist der erste Schritt der Datenaufbereitung.

Im zweiten Schritt werden die Daten zeitlich zueinander korreliert. Dafür können identische Datenfelder zwischen den beiden Datenquellen verwendet werden. Beispielsweise das Geschwindigkeitsprofil. Die Daten werden zunächst händisch zeitlich so zueinander eingestellt, dass die Korrelation visuell einigermaßen passend erscheint. Da die Datenquellen sehr unterschiedliche Datenfrequenzen haben, wurde entschieden, die Datenfrequenz auf sehr hohe 1000 Hz zu setzen. Das ist erheblich höher als die Datenfrequenz der ScanMyTesla-App oder der Teslalogger Software.

Die Datenpunkte der beiden Apps können zeitlich exakt in der hohen Frequenz eingeordnet werden und fehlende Datenpunkte interpoliert werden. Nun ergeben sich zwei in Datenfrequenz gleichartige Geschwindigkeitsprofile aus den beiden Datenquellen. Diese können zeitlich schrittweise gegeneinander verschoben werden und das Integral der Differenz der beiden Funktionen berechnet werden. Der Zeitversatz, der das Integral minimiert, entspricht der besten zeitlichen Korrelation. Die beschriebene Funktion wurde von der OTH Amberg-Weiden in Python programmiert und ist ein Beispiel, wie aufwendig die Datenaufbereitung betrieben werden musste: Es war leider nicht möglich, die ScanMyTesla-App und die Teslalogger Software zeitlich einander abgestimmt zu triggern.

Ein anderes Beispiel sind die aufgezeichneten GPS-Koordinaten. Diese Koordinaten entsprechen ungefähr den Koordinaten von Straßen auf OpenStreetMap. Es ist jedoch ein sogenannter Matching Service notwendig, der die GPS-Koordinaten auf OpenStreetMap-Straßensegmente zuordnet. Dafür wurde der Dienst Valhalla verwendet. Mit Hilfe von Metaparametern wie dem Suchradius kann die Matching-Qualität beeinflusst und optimiert werden. Auch hier ist händisches Prüfen und Nachjustieren der Matchings notwendig.

Eine vereinfachte Darstellung der Datenaufbereitung wie oben beschrieben ist in Abbildung 15 dargestellt. Nachfolgend soll auf die grünen Blöcke genauer eingegangen werden. Die oberen Teile des Diagramms wurden bereits weiter oben beschrieben.

Expectation Based Analysis (Erwartungsbasierte Analyse): Mit Hilfe der aufgezeichneten Daten und bekannten Eigenschaften des Fahrzeugs (Masse) kann ein physikalisches Modell erzeugt werden. Einzelne Parameter werden dabei geschätzt. Nun kann dieses Modell auf vielfältige Weise auf den Datensatz angewendet werden. Modellvorhersagen und aufgezeichneten Daten liegen meist eng beieinander. Abweichungen ergaben sich z.B. durch wenig verfügbare Daten beispielsweise bei hohen Geschwindigkeiten > 130 km/h auf der Autobahn. Das von der OTH Amberg-Weiden verwendete Modell ist Ausgangspunkt für die Entwicklung der Reichweitenschätzung. Näheres zum verwendeten Modell und Auswertungen findet sich im Deliverable 2.2.

Coefficient of Determination (Bestimmtheitsmatrix R^2): Hierbei handelt es sich um eine statistische Methode zum Finden linearer Korrelationen zwischen Daten. Dafür wurden alle der über 40 aufgezeichneten Datenparameter gegenübergestellt. Es wurde eruiert, inwieweit Daten zumindest linear miteinander korrelieren. Dadurch ergibt sich ein tieferes Verständnis der Daten.

Real-time playback: Künstliche Intelligenz, besonders Limitierungen hinsichtlich des Trainings, sind nicht scharf definiert. Es gibt jedoch sich empirisch immer wieder bestätigende Ergebnisse. Grundsätzlich gilt, dass eine KI für sehr eng gefasste Aufgaben ähnlich gut werden kann wie ein Mensch. Häufig sogar etwas besser. Dies kann als Maßstab herangezogen werden, ob die weitere Entwicklung sinnvoll erscheint oder eher zu keiner weiteren wesentlichen Verbesserung führt. Zu diesem Zweck ist es sinnvoll, ein intuitives Verständnis der Daten zu erhalten. Eine weitere Methode, die die OTH Amberg-Weiden anwendete, ist daher das schlichte Abspielen der Trainingsdaten.

Auf Basis der bereinigten Daten und des intuitiven Verständnisses können anschließend KI-Konzepte entwickelt werden.

Data Collection and storage for Testdrives from 2 Data Sources

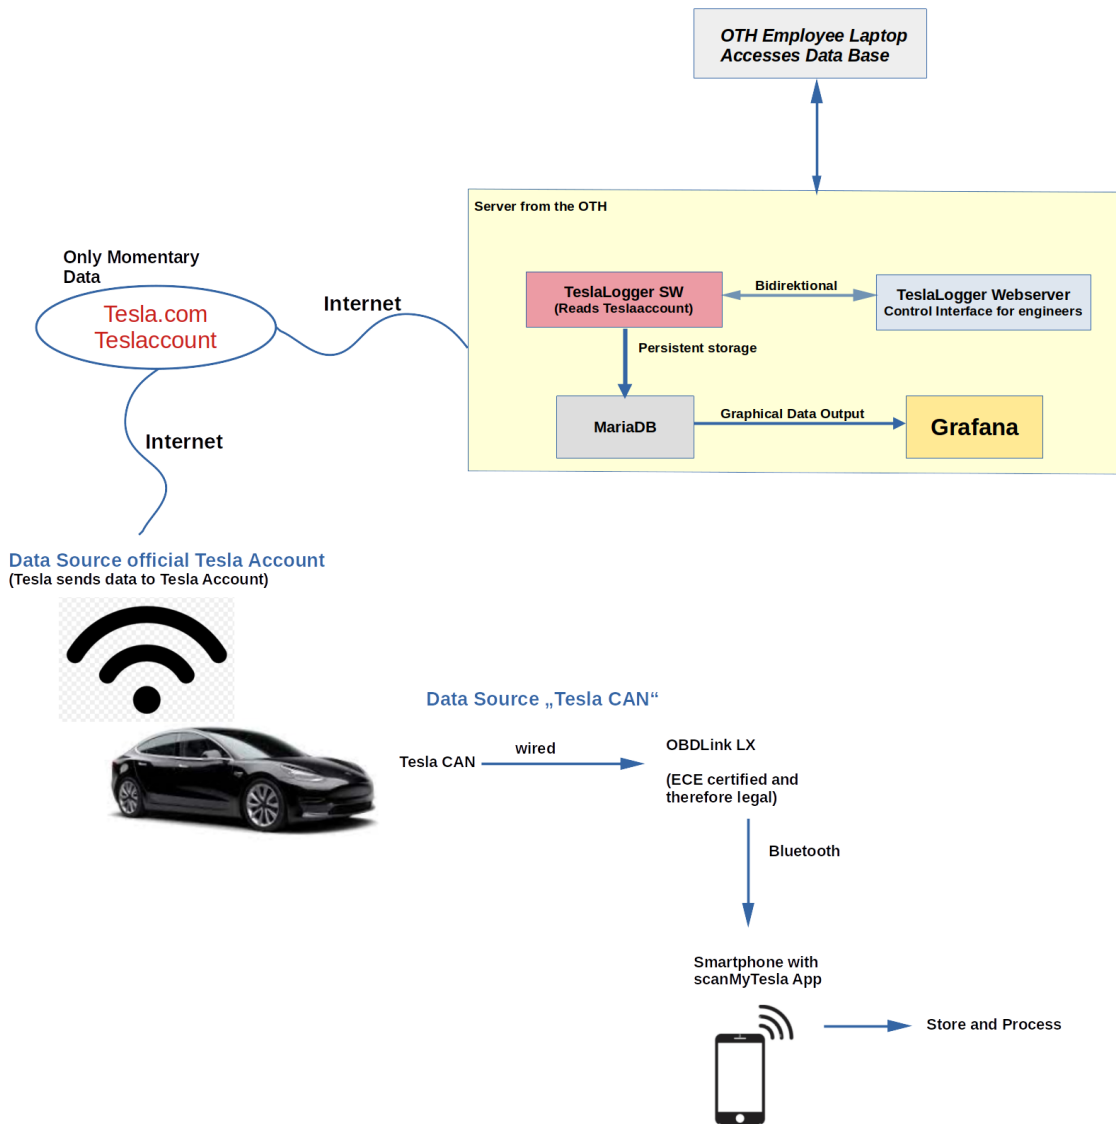


Abbildung 15: Datenaufzeichnung mittel ScanMyTesla-App und der Teslalogger Software

Simplified Data Processing Concept

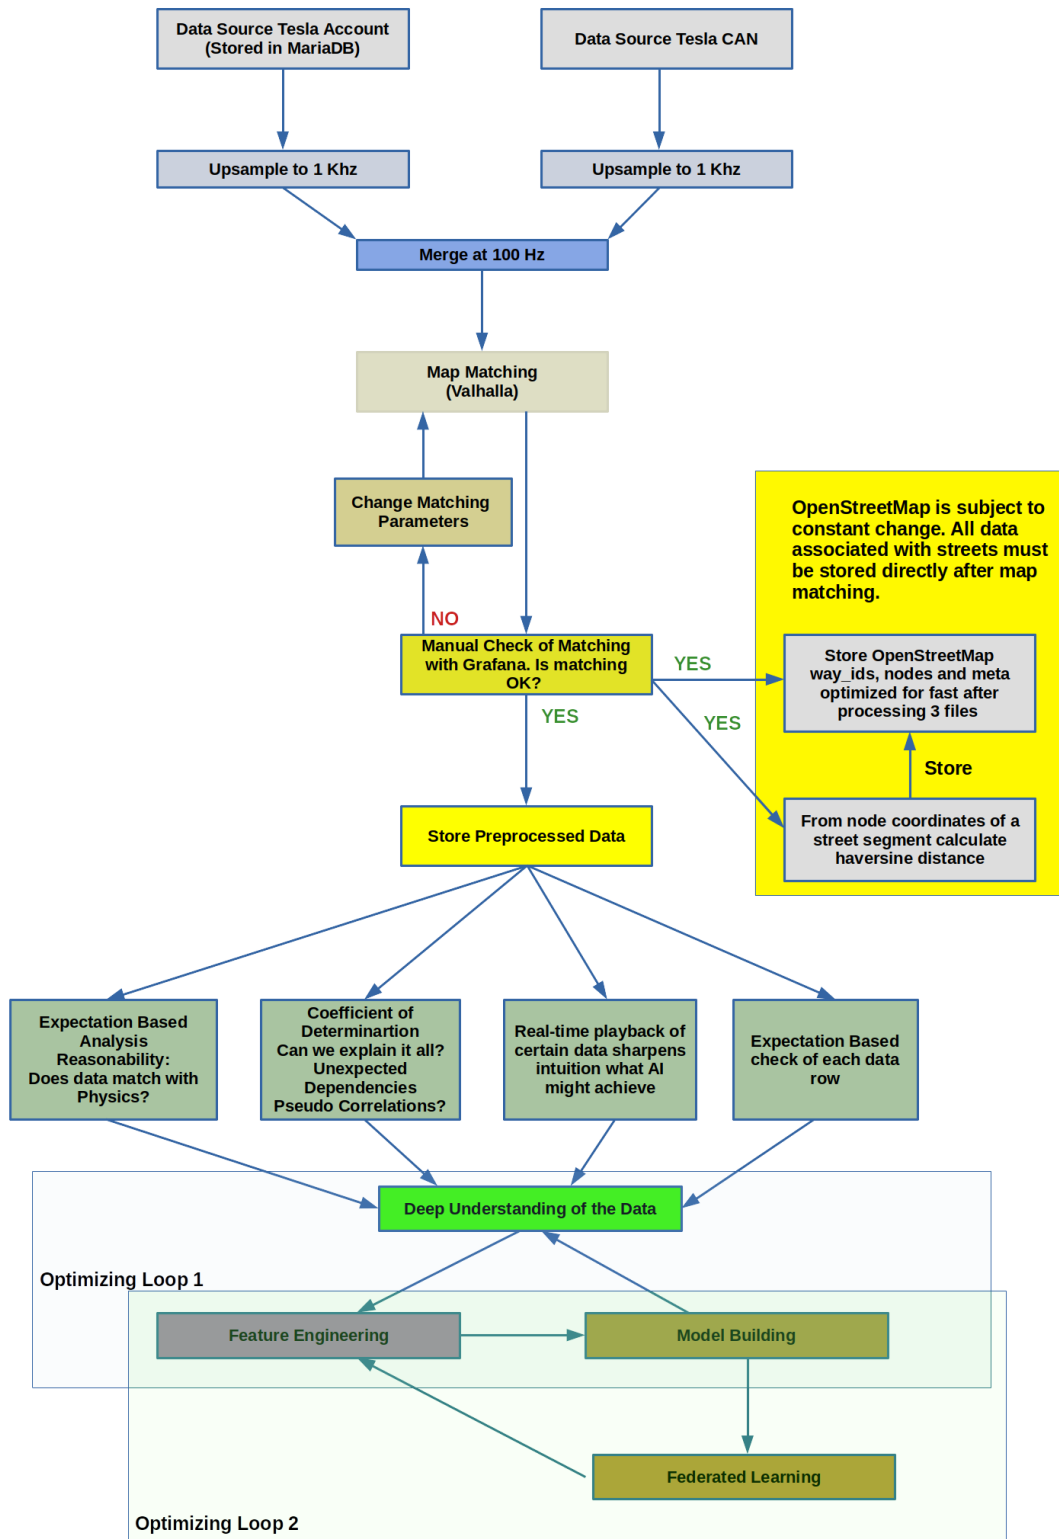


Abbildung 16: Erster Schritt der Datenaufbereitung mit Datenkorrelation und Map-Matching. Die zusätzlich dargestellten Optimization Loops sind ein Vorgriff auf WP4 und zeigen die Fortführung der Datenverarbeitungspipeline.

3.3 Arbeiten und Ergebnisse WP3: Electronic Components

Die OTH-AW hatte keine Anteile in diesem Arbeitspaket.

3.4 Arbeiten und Ergebnisse WP4: Embedded System Development

Im Virtual City Routing wurden in WP4 die in WP1 & WP2 definierten Bausteine implementiert. Dies umfasst die folgenden Punkte:

Energiesimulation:

Zur Bestimmung des Energieverbrauchs elektrischer Fahrzeuge wurde ein longitudinales verkehrsdynamisches Modell eingesetzt. Dieses Modell berechnet die auf das Fahrzeug wirkenden Kräfte und summiert diese zum Gesamtenergieverbrauch. Die berücksichtigten Kräfte umfassen:

- Rollwiderstand
- Luftwiderstand
- Hangabtriebskraft

Für die Berechnung wurden externe Datenquellen herangezogen, darunter Höhendaten der SRTM-Mission, OpenStreetMap sowie Wetterdaten von OpenWeatherMap. Um die Höhendaten weiter zu verfeinern, wurden zusätzlich Daten des BayernAtlas evaluiert.

Matrix Routing Query:

Um die kürzesten Wege zwischen den Abholstationen dauerhaft für den Routing-Algorithmus verfügbar zu machen, wurde das Matrix-Routing-Query-Modul entwickelt. In regelmäßigen Abständen berechnet dieses Modul die aktuell kürzesten Routen unter Berücksichtigung der jeweiligen Verkehrslage und ermittelt auf dieser Basis den zugehörigen Energieverbrauch. Dafür müssen die Charakteristika der jeweiligen Routen bekannt sein. Diese Informationen werden aus OpenStreetMap-Daten gewonnen, die in das SUMO-Simulationssystem importiert wurden. Dem Service wird dabei eine Liste von GPS-Koordinaten der Stationen übergeben. Als Antwort liefert das System eine Reihe von Streckendaten – darunter Tempolimits, Geokoordinaten der Straßenabschnitte und weitere relevante Eigenschaften. Diese Informationen dienen als Eingabeparameter für die Berechnung des Energieverbrauchs.

Routing-Solver

Der Routing-Solver ist eine zentrale Komponente, die optimale Kombinationen von Routen zwischen Stationen berechnet, mit dem Ziel, die Zeit zur Erfüllung der Kundenanforderungen zu minimieren. Dabei kommt ein Reinforcement-Learning-Ansatz zum Einsatz, der auf einer Transformer-Architektur basiert.

Bestehende Ansätze verwenden in der Regel Luftliniendistanzen, da bei der Nutzung detaillierter Streckendaten eine uneinheitliche Anzahl an Features pro Abholpunkt entsteht (z. B. zwei Features für X/Y-Koordinaten vs. ein Feature pro Station). Unsere Forschung untersuchte daher unter anderem den Einsatz von Dimensionsreduktionsmethoden, um aus einer Vielzahl von Features (N) eine kompakte Repräsentation mit zwei Dimensionen zu erzeugen. Siehe hierzu Abbildung 17.

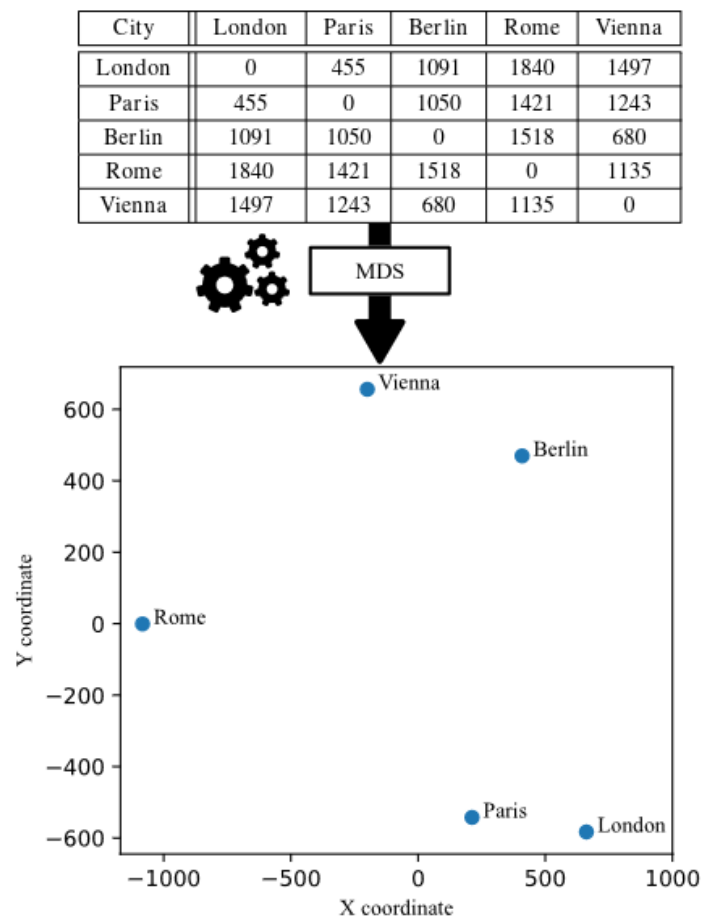


Abbildung 17: Beispiel zur Verwendung von Dimensionsreduktion zur Featureraum-Verkleinerung

Evaluation der Implementierung:

Die Funktionalität des Systems wird in vier unterschiedlichen Szenarien evaluiert: in den Städten Amberg, New York, Washington D.C. und Chicago. Die Auswahl der drei US-amerikanischen Städte basierte auf der Verfügbarkeit eines geeigneten Datensatzes (Fiedler & Mrkos, 2023).

Die Evaluation ist in zwei Teilbereiche gegliedert: Im ersten Teil werden sogenannte „Easy Problems“ betrachtet, bei denen 10 Kunden (entsprechend 20 Haltestellen) involviert sind. Diese kleinen Instanzen lassen sich exakt und optimal lösen.

Zur Bewertung der Skalierbarkeit werden im zweiten Teil größere Problemstellungen mit 100 Kunden untersucht. Aufgrund der Komplexität dieser Instanzen ist eine exakte Lösung nicht mehr praktikabel; ein direkter Vergleich mit den optimalen Lösungen ist daher nicht mehr möglich.

Als Referenz und Basis für die Bewertung kommt in beiden Fällen das in der Domäne etablierte Optimierungs-Framework **OR-Tools** von Google zum Einsatz (Perron & Didier, 2024). Für die einfachen Problemstellungen siehe Abbildung 18.

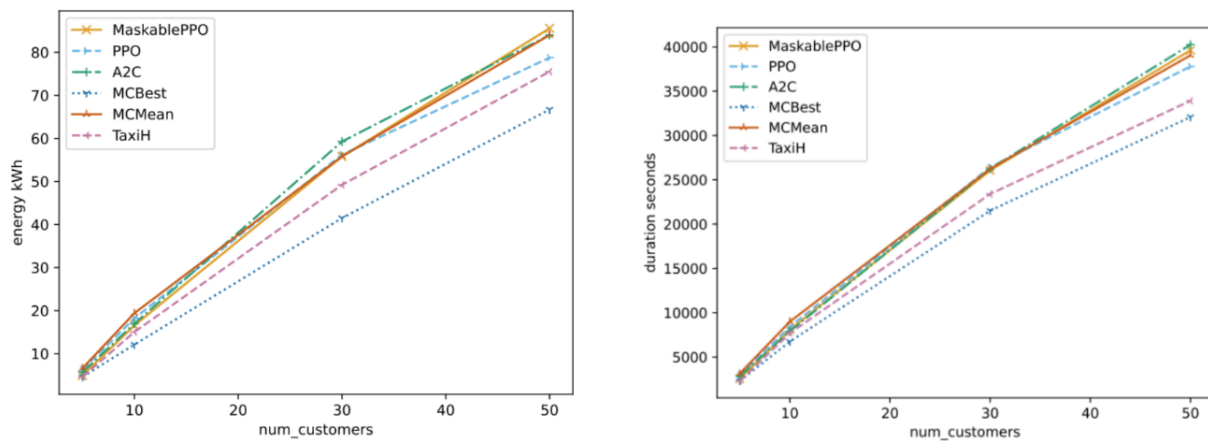


Abbildung 18: Energieverbrauch und Transportdauer für die gerouteten Strecken eines Fahrzeuges und unterschiedliche Anzahl an Kunden

Roadside Units

Erfassung der Verkehrssituation mit virtuellen Roadside Units:

Zur Erfassung der aktuellen Verkehrslage – insbesondere der Anzahl und Geschwindigkeit der Fahrzeuge – wurde durch den Partner **VG TU** eine Implementierung virtueller *Roadside Units (RSUs)* entwickelt. Diese Lösung wurde anschließend von der **OTH Amberg-Weiden** angepasst und großflächig im Umfeld der Stadt Amberg eingesetzt. Dabei wurde an **jeder Straßenkante eine virtuelle RSU** platziert, um eine flächendeckende Datenerfassung zu gewährleisten. Für einen Ausschnitt der Implementierung siehe Abbildung 19. Abbildung 20 zeigt eine Übersichtskarte mit den Roadside Units in der Simulation.

```
traci.start(["sumo-gui", "-c", "file_name.sumocfg"])
traci.junction.subscribeContext("RSU1", tc.CMD_GET_VEHICLE_VARIABLE, 50,
[tc.VAR_SPEED, tc.VAR_WAITING_TIME])
print(traci.junction.getContextSubscriptionResults("RSU1"))
for step in range(500):
    print("step", step)
    traci.simulationStep()
    data1 = traci.junction.getContextSubscriptionResults("RSU1")
    print("RSU1: " + str(traci.junction.getContextSubscriptionResults("RSU1")))
```

Abbildung 19: Relevanter Codeausschnitt zur Generierung von Roadside Units




Abbildung 20: Roadside Units platziert in der SUMO-Simulation von Amberg

In SC2 des WP4 hat sich die OTH Amberg-Weiden zunächst in das Tooling des Flower Frameworks eingearbeitet. Flower unterstützt zahlreiche Betriebssysteme, unter anderem auch Android und Apple.

Das Studium des Standes der Technik erfolgte an zentralisierten KI-Konzepten. Ziel war es, vielversprechende Veröffentlichungen zu implementieren. Die Struktur der Datenverarbeitung war – nach Rücksprache mit den Autoren - nachvollziehbar und die Ergebnisse sahen vielversprechend aus. Die Ergebnisse des Trainings lagen häufig im Bereich einiger Prozent.

Während des Prozesses des Implementierens und Evaluierens von Veröffentlichungen wurde immer deutlicher, dass diese teils recht unterschiedliche Einflussgrößen verwendeten, die Ergebnisse der Implementierung dennoch gut waren. Es schien sich zeigen, dass die vielen unterschiedlichen Einflussgrößen an sich keine größere Bedeutung haben. Auch in den wissenschaftlichen Veröffentlichungen fehlte eine systematische Analyse, welche Einflussgrößen einen gut begründeten Einfluss haben. Stattdessen wird eine möglichst große Anzahl an verfügbaren Datenquellen mit den neuesten KI-Methoden verknüpft.

Dies war die entscheidende Erkenntnis, einen fachlich gut begründeten datenminimalistischen Ansatz zu wählen. Dies bedeutete auch, dass es nicht das Ziel sein könne, eine bereits vorhandene Lösung im Kontext von föderiertem Lernen zu implementieren. Stattdessen musste dieser Ansatz selbst entworfen werden. Datenminimalismus heißt auch immer Datenschutz. Denn Daten, die sich nicht in den Trainingsdaten befinden, können auch nicht verloren gehen. So zeichnete sich hier bereits eine Synergie ab zwischen einem sinnvollen Beitrag zur Wissenschaft und den Zielen des Teilvorhabens der OTH Amberg-Weiden. Damit geht die OTH Amberg-Weiden sogar über das ursprünglich definierte Ziel hinaus, lediglich eine bestehende Lösung im Kontext von föderiertem Lernen zu implementieren.

Es erfolgte eine konkrete Problemquantifizierung und die Definition eines sogenannten Baseline-Klassifikators. Dieser Baseline-Klassifikator dient als Referenzpunkt für das zu implementierende KI-Modell. Die **Problemdefinition** erfolgte folgendermaßen: Aus den aufgezeichneten Sommertestfahrten wurde der verbrauchte State-of-Charge (SoC) ermittelt und dies durch die gefahrene Strecke geteilt. Der SoC gibt die Restladung des Tesla in Prozent an, bewegt sich also zwischen 0 und 100%.

Daraus ergibt sich streckenbezogener SoC/km. Wenn während einer 100 km langen Testfahrt 40% des verfügbaren State-of-Charge verwendet wurde, dann ist der Testfahrtbezogene 0,4 SoC/km. Mittels Dreisatzes lässt sich die Aussage umkehren: Mit 100% SoC hätte die Testfahrt 2,5 mal wiederholt werden können. Dabei wäre eine Strecke von 250 km zurückgelegt worden.

Nun lässt sich für alle Testfahrten auf diese Weise berechnen, wie weit hätte gefahren werden können. Die Ergebnisse liegen ungefähr zwischen 250 und 500 km. Das ist eine sehr konkrete **Problemdefinition**. Denn unabhängig von Fahrer und Teststrecke variiert der Energieverbrauch um einen Faktor 2. Nun kann ein **Baseline-Klassifikator** wie folgt definiert werden: „Das Fahrzeug fährt mit 100% SoC immer eine Strecke von 375 km“. Unter Verwendung dieses einfachen Klassifikators liegt der Fehler der Reichweitschätzung, gemessen an der Problemdefinition, bei +/- 125 km oder +/- 33,3 %. Ein komplexeres Modell muss also diesem Baseline-Klassifikator überlegen sein.

Ein weiterer wichtiger Schritt zur Einarbeitung war die Onlineteilnahme am **Flower Summit**. Der Flower Summit ist eine jährlich stattfindende, zweitägige Konferenz, bei der Projekte und Weiterentwicklungen des Flower Frameworks diskutiert werden. Die Konferenz fand vom 14. Bis 15. März 2024 in London statt und bestand aus einem Research Day und einem Industrial Day.

Zu diesem Zeitpunkt war es bereits geplant, neben der Client-Server-Kommunikation, die Flower zur Durchführung des föderierten Lernens nutzt, parallel eine weitere frei nutzbare Websocket-Kommunikation zu programmieren. Dies war notwendig, um die Daten zur Demonstration für die Abschlusspräsentation zu verwenden. Eine geeignete Kommunikation für „arbitrary messages“ wurde als Flower Nightly (Beta-Version) angekündigt. Die Nutzung einer Beta-Version erschien jedoch als zu großes Projektrisiko und so wurde der Umstieg auf die neue Version verworfen.

Auch wurde in den Talks deutlich, dass Kunden große Bedenken haben, föderiertes Lernen zu nutzen, sich aber selbst Krankenhäuser darauf einlassen. Im konkreten Fall ging es um eine Covid-Früherkennung. Die begrenzte Verfügbarkeit von Corona-Tests, insbesondere zu Anfang der Pandemie, machte eine Anamnese anhand von leicht feststellbaren Merkmalen notwendig. Viele Patientenmerkmale lassen sich anhand von Machine Learning nutzen, um eine Früherkennung technisch zu unterstützen, da sie strukturiert und standardmäßig im Krankenhaus erfasst werden. Zwar erlaubten die Krankenhäuser keinen direkten Zugriff auf die IT, jedoch wurden die strukturierten Daten händisch von Personal zum Zwecke des Federated Learnings auf die Geräte übertragen. Dieser Fall ist besonders interessant, da es sich um einen B2B-Kontext handelt, in dem es um hochsensible Daten geht. Robotaxis, Flottenbetriebe und das notwendige Vertrauen von einem KFZ-Hersteller zu einem Flottenbetreiber ist ebenfalls ein B2B-Kontext. Das Businessmodell scheint zukunftsfähig, wenn durch entsprechende KI-Methoden sichergestellt wird, dass der Datenschutz gewährleistet ist.

Ein weiteres wesentliches Ergebnis war ein Überblick über relevante und viel diskutierte Datenschutzmethoden. Dies veranlasste die OTH Amberg-Weiden zu einer genaueren Untersuchung der Datenschutzkonzepte und hatte maßgeblichen Einfluss auf das vorgeschlagene KI-Konzept. Die Methoden heißen Secure Aggregation, Differential Privacy und Fully Homomorphic Encryption. Eine tiefergehende Einarbeitung in diese Konzepte erfolgt in WP5.

In WP4 plante und entwickelte die OTH Amberg-Weiden wesentliche Teile des Hardware-Demonstrators. Der Hardwaredemonstrator ist ein Tischdemonstrator, der laut der ursprünglichen Planung aus einem Server und 4 Clients bestand. Auf dem Server arbeitet der Flower Server, der Modellupdates der Flower Clients empfängt, die Modellparameter mittelt, und das erzeugte globale Modell an die Clients zurücksendet. Dieser Prozess an sich ist nicht sichtbar und das Flower Framework unterstützte zu dieser Zeit auch keine Visualisierung. Also entschied sich die OTH Amberg-Weiden diese Visualisierung selbst zu implementieren. Jeder Client und der Server sollten eigene Touchdisplays erhalten, um den Bezug zwischen Hardware und Visualisierung einfach nachvollziehbar zu gestalten.

Des Weiteren sollte die gesamte Kommunikation kabellos erfolgen. Auch die Kommunikation vom Server und den Clients hin zu den Touchdisplays. Dies ermöglicht einen übersichtlicheren Versuchsaufbau und erlaubt eine für die Abschlusspräsentation freie Anordnung der Komponenten. Auf den Flower Clients sollten die Testfahrten abgespielt werden. Auf diese Weise wurden neue Trainingsdaten erzeugt. Darüber hinaus sollte die Integration in den Mercedes EQC möglichst kabellos erfolgen. Dazu gab es zwischen der TTTAuto und der OTH Amberg-Weiden Abstimmungen. Auch mit Mercedes wurden CAN-Datenfelder, die für das Training notwendig waren, abgestimmt.

Um einer realistischen Implementierung möglichst nahe zu kommen, wurde stattdessen eine sogenannte „ORA-Box“ angeschafft. Hierbei handelt es sich um einen Automobilcomputer, der von der OTH Amberg-Weiden im Projekt 1000KMPlus entwickelt wurde. Die angeschaffte ORA-Box wurde Teil des Tischdemonstrators. Letztlich würden die CAN-Daten des Mercedes EQC darüber abgegriffen und der Trainingseinheit, einem NVIDIA Orin AGX Computer, zur Verfügung gestellt werden.

Die folgende Abbildung stellt den in WP4 ursprünglich geplanten Versuchsaufbau dar.

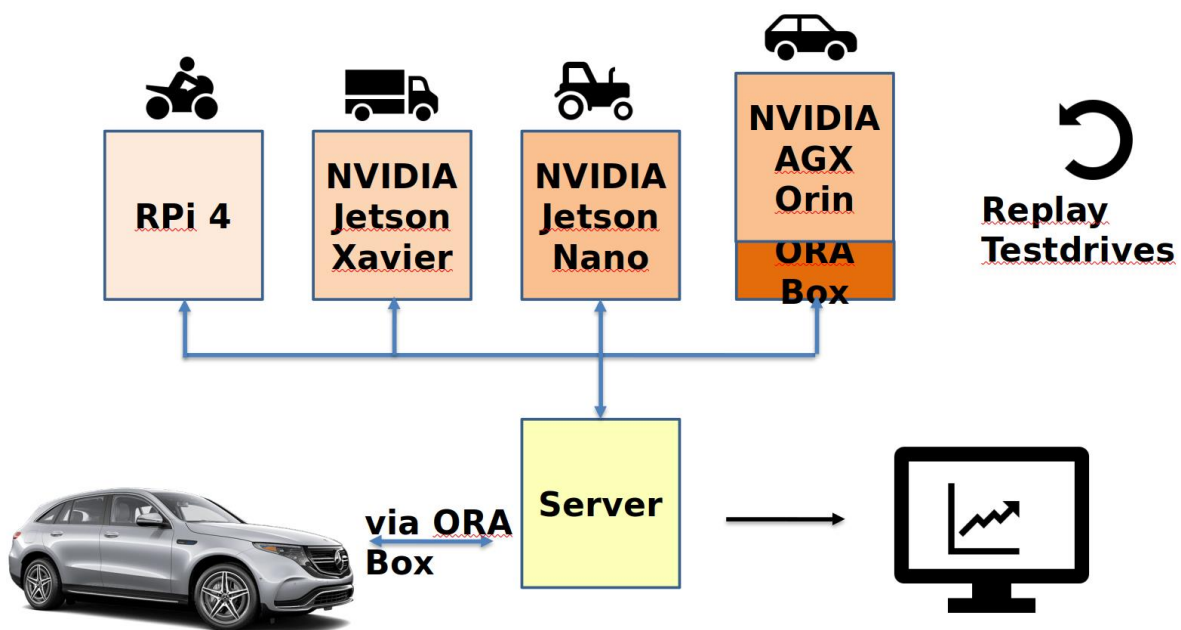


Abbildung 21: Initiale Planung des Hardware-Demonstrators

Das Ziel einer kabellosen Implementierung führte jedoch zu einem Projektrisiko. Als Touch Displays wären Tablets eine gute und kosteneffiziente Lösung. Im ersten Schritt wurde versucht, via VNC auf einen Bildschirm zu streamen. Dies Tests verliefen jedoch nicht zufriedenstellend, da selbst bei geringer Auflösung hohe Datenraten erforderlich waren. Deswegen fiel die Wahl letztlich auf Android Tablets. Anstatt eine App zu programmieren, entschied sich die OTH Amberg-Weiden dazu, eine Website zu entwickeln, die auf den Android Geräten arbeiten würde. Das ist ein wesentlicher Schritt zu Risikominimierung. Dennoch musste sich die OTH Amberg-Weiden in JavaScript einarbeiten und einige technische Implementierungshürden, die das Android Betriebssystem birgt, überwinden. Die technische Implementierung aus Flower Server, Flower Clients, Tablets und der zuvor beschriebenen Websocket-Kommunikation lässt sich wie folgt darstellen:

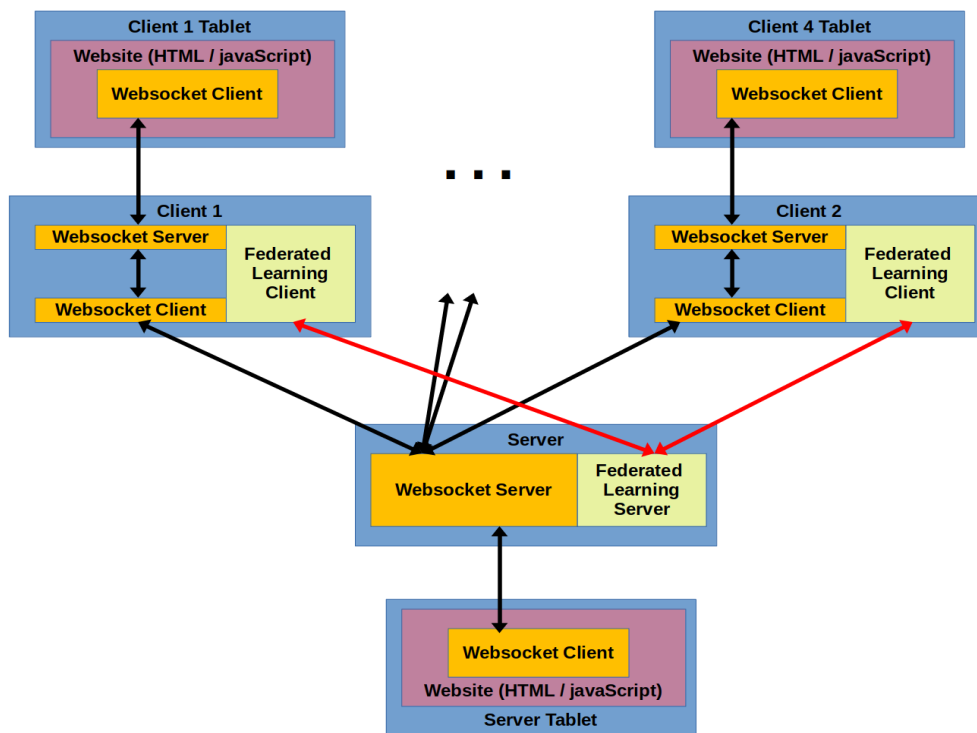


Abbildung 22: Flower Framework Kommunikation und parallele, von der OTH Amberg-Weiden implementierte Websocket-Kommunikation

Darüber hinaus wurde festgelegt, dass die Android Tablets im Batteriebetrieb arbeiten sollten. Dadurch konnten Kabel vermieden werden und der Demonstrator würde schlanker werden und sich bei der Abschlussdemonstration auf die Zielfunktion konzentrieren. Es wurde festgelegt, dass die Batterien der Tablets einen Arbeitstag (8 h) bei voller Displayleuchtstärke im Batteriebetrieb ohne Aufladen arbeiten können sollten. Volle Displayleuchtstärke wurde festgelegt, da die Displays während der Abschlusspräsentation in einem gut ausgeleuchteten Raum oder einer Halle sein würden. Um dies sicherzustellen, wurden für jedes Tablet zusätzlich ein 10.000 mAh Akku angeschafft, die in den Standfüßen der Tablethalterungen verborgen wurden. Folgende Abbildung zeigt das Tablet auf dem Standfuß mit Akku.



Abbildung 23: Tablet auf Standfuß mit Akku

Die OTH Amberg-Weiden entschied sich für die Implementierung des Google Material Light Designs als Webseitenoberfläche. Die folgende Abbildung zeigt einen Screenshot eines Tablets des seitlich geöffneten Menüs. Neben einer Demonstratoransicht für die Abschlusspräsentation gibt es noch eine „Developer“-Ansicht und „Statistics“-Ansicht für Testzwecke und eine „Info“-Ansicht mit Hintergrundinformationen zum Projekt.

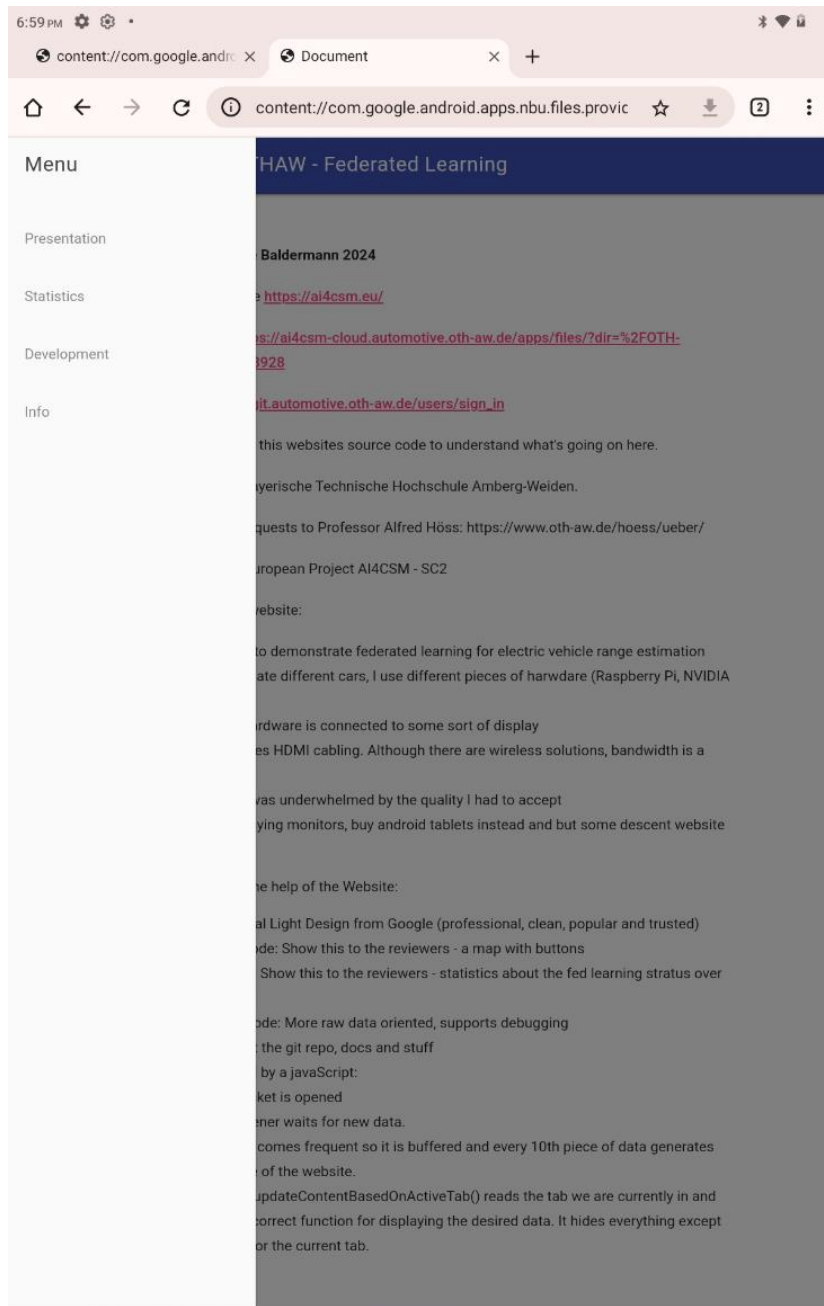


Abbildung 24: Google Material Light Design wurde auf den Tablets verwendet.

Zunächst wurde eine rudimentäre Website programmiert, die zwei OpenStreetMap-Karten lud und mit hoher Frequenz 800 rote und 10 blaue Linien anhand von Zufallskordinaten zeichnete. Die Daten der Zufallskordinaten wurden über WiFi an das Tablet kommuniziert. Auf diese Weise konnte ein realistischer Energieverbrauch im Demonstrator frühzeitig simuliert werden, ohne dass die finale Implementierung vorhanden war. Die folgende Abbildung zeigt das Tablet im 8 Stundentest:

Integration des Roadside-Unit-Skripts

Das **RSU-Skript** dient der Erfassung von Verkehrsdaten aus der Simulation. Als Eingaben benötigt es:

- die **SUMO-Konfigurationsdatei** der Simulation,
- die **Positionen der Roadside Units**, welche auf SUMO-Kanten platziert sind,
- sowie die **Simulationszeit**, die angibt, wann und wie lange der Verkehr aufgezeichnet wird.

Während der Ausführung startet das Skript die Simulation und erfasst die Anzahl der Fahrzeuge sowie deren Geschwindigkeit, die an jeder RSU vorbeifahren. Als Ausgabe wird eine CSV-Datei `rsu_data.csv` erzeugt, die folgende Informationen enthält: RSU-ID, Zeitstempel, Fahrzeuganzahl und durchschnittliche Geschwindigkeit.

Diese Daten werden genutzt, um in künftigen Simulationen realistischere Geschwindigkeiten auf den Kanten zu modellieren. Dabei wird die Reiseroute nicht nach der maximal zulässigen Geschwindigkeit gewichtet, sondern auf Basis der gemessenen Durchschnittsgeschwindigkeit im zuvor definierten Zeitfenster.

Das Routing-Skript berechnet anschließend kürzeste Punkt-zu-Punkt-Verbindungen zwischen allen möglichen Start- und Zielstationen im Netzwerk. Dies erfolgt effizient in einem **Batch-Prozess**, was die Berechnungszeit erheblich reduziert. Die Routen können entweder mit dem **SUMO-Tool duarouter** oder mit einer **eigenen Implementierung auf Basis von networkx** erstellt werden. Letztere erlaubt die Verwendung eigener Routing-Algorithmen.

Als Ergebnis wird eine XML-Datei durch duarouter erzeugt, die gemeinsam mit den Kundenanfragen als Eingabe für den **Szenario-Generator** dient. Dieser konvertiert die XML-Datei und die Kundenanforderungen in ein passendes **JSON-Format**, das von der **kombinatorischen Routing-Engine** zur Lösung des DARP-Problems eingelesen werden kann.

Die kombinatorische Routing-Engine berechnet anschließend die optimalen Routen und Haltestellenfolgen für die Fahrzeuge. Diese Routen können analog zu den DRT-Tools in SUMO eingebunden werden. Dabei kommen entweder **eigene Solver/Heuristiken** oder die **Google OR-Tools** zum Einsatz, welche eine sehr effiziente Heuristik darstellen ([SUMO DRT-Tools](#)).

In WP5 erfolgte die Auswertung durch das Starten der Simulation mit den **vorkalkulierten Routen** als Parameter. Dynamische Routenanpassungen während der Simulation waren nicht möglich. Um dynamische Effekte besser abbilden zu können, wurde zusätzlich das **SUMO-DRT-Modul** eingerichtet und die Ergebnisse verglichen.

Eine auf den **OR-Tools** basierende Lösung wurde mit dem **Reinforcement-Learning-Ansatz** verglichen (siehe Deliverable 4.3). Diese Lösung erlaubt zudem die Auswertung von Szenarien mit mehreren Fahrzeugen gleichzeitig.

Integration Robo-Taxi

Im zweiten Teil der Integration wurde eine Schnittstelle zum **Virtual Vehicle Robo-Taxi** realisiert. Nachdem die zu fahrenden Kanten aus der Liste der anzufahrenden Haltestellen bekannt sind, müssen diese Informationen an das Robo-Taxi übermittelt werden.

Das Robo-Taxi erwartet die Routen im **OpenDRIVE-Format**, daher muss die geplante Route entsprechend konvertiert werden. Zudem erwartet das System jeweils den **nächsten Streckenabschnitt** bis zur kommenden Haltestelle, an der entschieden wird, wie weiter verfahren werden soll.

Im Gegenzug sendet das Robo-Taxi:

- die **aktuelle Position** (in Form des OpenDRIVE-Abschnitts),
- die **Anzahl der Fahrgäste**,
- sowie ein **Idle-Signal**, sobald die nächste Haltestelle erreicht ist.

Das Idle-Signal löst auf der Cloud-Seite das **Verschicken der nächsten Route** aus der Stationsliste aus.

Während eines Integrations-Workshops in **Graz** wurde die Kommunikation mit dem Edge-Device im Fahrzeug getestet. Die Routing-Software lief dabei auf einem Notebook.

Auf der Cloud-Seite wird die aktuelle **Routen-ID** (ein fortlaufender Zähler) sowie die entsprechenden **OpenDRIVE-IDs** der Route angezeigt. Das Edge-Device sendet ebenfalls die aktuelle Routen-ID, die Position, die Anzahl der Fahrgäste und den Idle-Status. Dieser signalisiert einen Zustieg oder Ausstieg. Nach einem Halt verändert sich die Anzahl der Fahrgäste typischerweise, und das Idle-Signal veranlasst die Cloud, die nächste Teilstrecke zu übermitteln.

Im Rahmen von WP5 wurden die in WP4 entwickelten Konzepte komplettiert und in den Hardware-demonstrator integriert. Ein wesentlicher Beitrag in WP5 ist die Analyse und Bewertung der im Bereich Förderiertem Lernen genutzten Datenschutzkonzepte. Dies wirft allerdings die Frage auf, weshalb föderiertes Lernen an sich nicht ausreichend zu sein scheint. Es gibt eine Reihe von Untersuchungen, die zeigen, dass mit den Modellupdates, die von den Clients an den Server gesendet werden, sich die Trainingsdaten rekonstruieren lassen. Dies gelingt auch für sehr komplexe Netzwerkstrukturen wie CNNs. Das „Leaken“ der Trainingsdaten an den Server erfordert, diesem Vertrauen zu müssen. Aber genau dies soll aus Datenschutzgründen vermieden werden. Dies begründet die Notwendigkeit der Implementierung weiterführender Datenschutzkonzepte. Diese Datenschutzkonzepte wurden in Kapitel 1 bereits erwähnt und heißen Secure Aggregation, Differential Privacy und Fully Homomorphic Encryption. Im Folgenden werden die wesentlichen Erkenntnisse und darauf basierenden Entscheidungen für die algorithmische Implementierung beschrieben.

Das Ziel der OTH war es, ein datensparsamen KI-Modell zu implementieren. Dazu ist es sinnvoll, an einem eindrucksvollen Beispiel das „Leaken“ von Trainingsdaten zu demonstrieren und zu analysieren. Dazu hat die OTH Amberg-Weiden den CIFAR10-Datensatz verwendet. Ein einzelnes Neuron erhält dabei Eingangsbilder. Im einfachsten Fall würde jedes einzelne Eingangstrainingsbild zu einem kleinen Update des Neuronenmodells führen. Dieses Modellupdate würde an den Server gesendet werden, der das föderierte Lernen orchestriert. Das Eingangsbild wird nach Farbkanälen aufgesplittet und jedem Pixel der Farbkanäle wird ein Gewicht zugeordnet. Die Gewichte werden mit Hilfe der Sigmoid-Funktion trainiert. Trainingsziel ist die binäre Entscheidung, ob es sich beim gezeigten Bild um ein Automobil handelt oder nicht. Die folgende Abbildung zeigt ein Eingangsbild (Trainingsdaten) oben. Darunter befindet sich die noch untrainierten Gewichte des Neurons. Interessant sind die Bilder ganz unten. Hier zeigt sich, dass das Modellupdate das Eingangsbild enthält, allerdings gewichtet, so dass es verblasst. Das Originalbild könnte (fast) vollständig wiederhergestellt werden, wenn das Modellupdate bezüglich seiner Farbwerte gespreizt werden würde. Dazu könnte die valide Annahme getroffen werden, dass das dunkelste Pixel tatsächlich einer Helligkeit von 0 und der hellste Pixel einer Helligkeit von 255 entsprechen müsste. Die wesentliche Erkenntnis jedoch ist, dass das Modellupdate die verblassten Eingangstrainingsdaten enthält und in diesem einfachen Beispiel praktisch kein Datenschutz gewährleistet ist, selbst wenn föderiertes Lernen verwendet wird.




Abbildung 26: Föderiertes Lernen "leaked" die Trainingsdaten über das Modellupdate

Um diesem Problem adäquat Rechnung zu tragen, werden die bereits erwähnten zusätzlichen Datenschutzkonzepte verwendet. Allerdings entstammen die Konzepte aus anderen Anwendungskontexten und werden auf föderiertes Lernen übertragen. Diese Schwäche ist immer wieder Angriffspunkt. Immer mehr Veröffentlichungen greifen auch Kombinationen aus den Datenschutzkonzepten erfolgreich an. Hinzu kommt, dass die zusätzlichen Datenschutzkonzepte das Training erheblich verlängern und teilweise das implementierbare Modell begrenzen und in ihrer Modellqualität degradieren. Es scheint ein ewiges Katz- und Mausspiel zu sein, wie es im Security-Bereich schon seit Jahrzehnten stattfindet.

Die OTH Amberg-Weiden hat sich daher entschieden, diese Datenschutzkonzepte nicht anzuwenden und stattdessen den datensparsamen Ansatz zu optimieren. Denn KI-Experten sind keine Security-Experten. Dafür verstehen sie, welche Informationen und Muster in Daten verborgen sind und können Datenschutz so am besten adressieren. Die folgende Abbildung zeigt, wie sich das Konzept der OTH Amberg-Weiden im Vergleich zu Föderiertem Lernen und zusätzlichen Datenschutzkombinationen verhält. Im Vergleich zu Föderiertem Lernen (FL) ist die globale Modellkomplexität gering. Das ergibt sich aus dem Konzept der Datensparsamkeit. Das führt zu einer kurzen Trainingszeit bei hoher Modellqualität. Einen Kontrast dazu stellt das Konzept „FL + FHE + DP“ dar. Die Anwendung von Fully Homomorphic Encryption (FHE) führt dazu, dass nicht alle mathematischen Operationen zur Verfügung stehen oder nur begrenzt angewendet werden können. Division beispielsweise lässt sich nur in Näherung durchführen und benötigt hunderte- oder sogar tausende Male länger zum Berechnen als eine einfache Division ohne dieses Konzept. Dadurch wird die mögliche Modellkomplexität begrenzt und gleichzeitig die Trainingszeit erheblich erhöht. Durch FHE, aber auch insbesondere Differential Privacy (DP), degradiert die Modellqualität erheblich, unabhängig von der Trainingszeit. Dies im Kontrast zum Konzept der OTH Amberg-Weiden gibt einen guten Einblick, wie stark das vorgeschlagene Konzept im Vergleich zur etablierten Wissenschaft sein kann.

FL = Föderiertes Lernen ; SA = Secure Aggregation ; FHE = Fully Homomorphic Encryption
 DP = Differential Privacy ; DS = Datensparsamkeit




Abbildung 27: Das KI-Konzept der OTH Amberg-Weiden im Vergleich zum Stand der Wissenschaft

Darauf aufbauend implementierte die OTH Amberg-Weiden das folgende Konzept. Ausgehend vom zuvor definierten Baseline-Klassifikator.

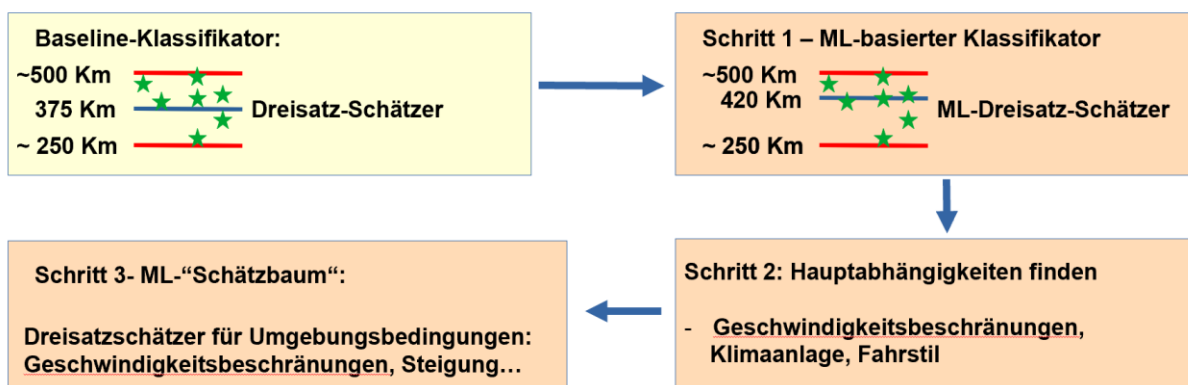


Abbildung 28: Systematisierung der Reichweitenvorhersage auf Basis eines ML-trainierten Schätzbaums

Abbildung 28 verdeutlicht das Konzept. Ausgehend vom in WP4 entwickelten Baseline-Klassifikator werden für die relevantesten Kriterien ein Schätzbaum entwickelt, der auf Basis der Umgebungsbedingungen einen Energieverbrauch je km schätzt. Durch diese Baumstruktur wird die KI nicht nur einfach, sondern geht auch ein wesentlicher Schritt in Richtung „Explainable AI“.

Außerdem wurde festgelegt, dass neben dem globalen Modell auch ein lokales Modell trainiert werden soll. Im direkten Vergleich mit dem globalen Modell können Nachrichten erzeugt und dem Fahrer in den Armaturen dargestellt werden. Dadurch kann der Fahrer zu energiebewussterem Fahrverhalten animiert werden.

Grundsätzlich sind zwei Konzepte naheliegend und gut realisierbar. Im Fahrzeug wird ein lokales Modell mit hoher Lernrate trainiert. Wenn die Energie/km – Schätzer beispielsweise mehr als 10% vom globalen Modell abweicht, wird der Fahrer informiert. Eine andere Variante ist es, den tatsächlichen Energieverbrauch der letzten Minuten mit der Schätzung des globalen Modells zu vergleichen. Beide Modelle haben ihre Berechtigung und wurden implementiert.

Abgesehen von den Datenschutzaspekten wurden die aufgezeichneten Daten auf Zeile-zu-Zeile Basis analysiert. Es fiel auf, dass es einminütige Lücken in den aufgezeichneten CAN-Daten gab. Und zwar wenn der Tesla an einer Ampel zu halten schien. Beim nächsten Datenpunkt fährt der Tesla bereits mit hoher Leistungsaufnahme. Das führt in der Berechnung des Energieverbrauchs, die ebenfalls Zeile-zu-Zeile erfolgt, zu einem ungewöhnlich hohen Ausreißer. Dies zeigt, dass eine Datenanalyse kaum standardisiert erfolgen kann, sondern immer im Hinblick auf den konkret implementierten Algorithmus. Es muss die Frage beantwortet werden, ob die Art der Datenverarbeitung und Weiterverwendung zu ungewöhnlichen Mustern führt, die in den realen Daten nicht enthalten sind.

Letztlich wurden die auffälligen Datenpunkte aber belassen wie sie sind. In Anbetracht des datensparsamen KI-Systems der OTH Amberg-Weiden können Probleme ausgeschlossen werden, da diese Datenspikes sehr selten auftreten und herausgemittelt werden. Dies wird von der OTH Amberg-Weiden als konkreter Erfolg im Kontext „Explainable AI“ bewertet. In der folgenden Abbildung ist ein Foto während des Versuchsaufbaus inkl. Roll-up während des Abschlussevents.



Abbildung 29: Demonstrator und Roll-up auf dem AI4CSM-Abschlussevent vom 11. bis 13. Februar 2025 in Stuttgart

Die Ergebnisse von WP5 sind in D5.4 und D5.5 detailliert erläutert.

3.6 Arbeiten und Ergebnisse WP6: Test, Validation and Demonstration

Mobilitätsvergleich in Arbeitspaket 6 (WP6)

Im Rahmen von WP6 wurden der Digital Twin genutzt zum Vergleich von Ridesharing mit anderen Mobilitätsformen zu untersuchen.

Hierfür wurden Mobilitätsanforderungen generiert (siehe Abbildung 30). Auf Basis dieser Anfragen wurden verschiedene Mobilitätsmodalitäten miteinander verglichen, um den Erfüllungsgrad definierter KPIs (Key Performance Indicators) zu bewerten (Abbildung 31):

- Öffentlicher Nahverkehr (Bus)
- Taxi
- Ridesharing mit zwei verschiedenen Algorithmen:

- **DRT1:** *drtOnline*-Tool von SUMO, basierend auf einer Heuristik aus dem Bereich der Linearen Programmierung
- **DRT2:** *drtOrtools*-Tool von SUMO, basierend auf den Google OR-Tools
- Nutzung des eigenen Fahrzeugs




Abbildung 30: Heatmaps der Start- und Zielpositionen von Kunden: links basierend auf den durch OMOD generierten 832 Mobilitätsanfragen, rechts basierend auf zufällig initialisierten Positionen in SUMO (1080).

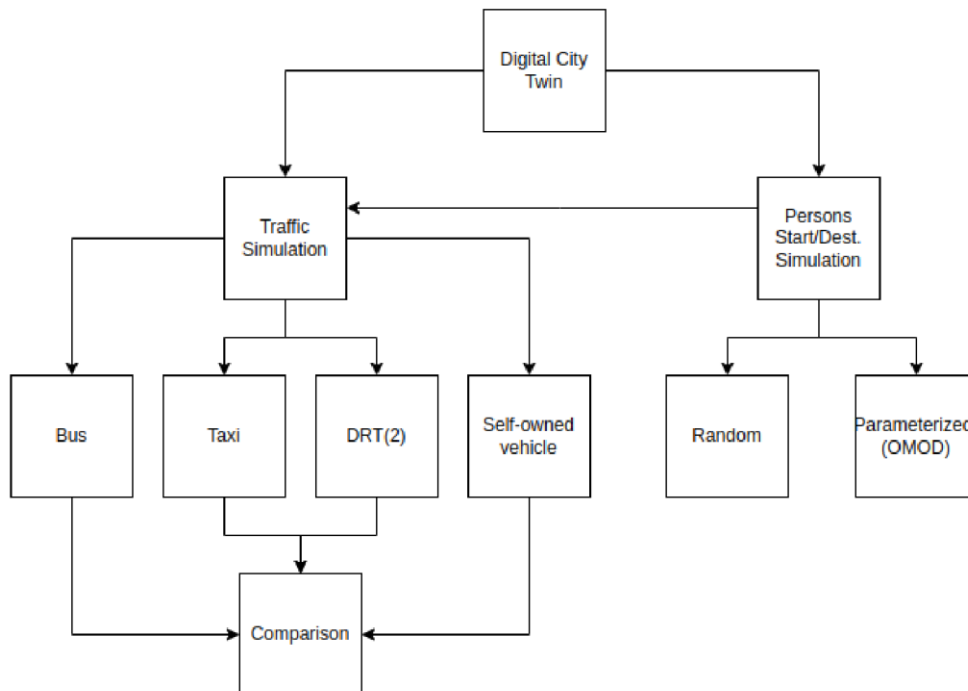


Abbildung 31: Evaluierungs Setup

KPIs

Energieeffizienz:

Die Energieeffizienz wird durch die Optimierung des Energieverbrauchs erreicht. Der Energieverbrauch korreliert hauptsächlich mit der zurückgelegten Strecke. Andere Einflussfaktoren wie der Fahrstil haben nur einen geringen Einfluss auf die Routenwahl, da sie sich gleichmäßig auf alle Routenalternativen auswirken. Aus diesem Grund und aufgrund von Implementierungsvorteilen nutzen wir die gefahrene Strecke als Näherung für die Energieeffizienz. Alternativ kann der bestehende Code so angepasst werden, dass der Energieverbrauch direkt optimiert wird – indem die Distanzmatrix der Abholstationen durch eine Energiekostenmatrix ersetzt wird. In diesem Fall müsste jedoch die Schicht zur Generierung der Knoteneinbettungen (Node Embeddings) für jede mögliche Anzahl an Knoten neu trainiert werden. Der restliche Teil des Modells kann durch Transfer Learning wiederverwendet werden. Da die erste Schicht umso mehr Parameter enthält, je größer der Eingaberaum ist, verlängert sich die Trainingszeit entsprechend. Größere Eingabemengen erfordern zudem mehr Speicher und erschweren somit das Training bei größeren Problemgrößen. Daher ist es praktikabler, im Modell die euklidische Distanz als Maß zu verwenden (und in der Evaluation die reale Strecke), da auf diese Weise ein Modell mit kleinerem Eingaberaum wiederverwendet werden kann.

- **Latenz bei geteilter Mobilität (Shared Mobility Latency)**

Die Latenz bei geteilter Mobilität wird bewertet, indem die durchschnittliche Fahrzeit für eine gegebene Anzahl an Fahrgästen mit Referenzwerten des öffentlichen Nahverkehrs verglichen wird. Öffentlicher Nahverkehr bezieht sich im Kontext von Amberg auf den Busverkehr, da dies die verfügbare Transportmöglichkeit im betrachteten Kartenausschnitt ist.

- **Verkehrsdurchsatz (Traffic Throughput)**

Der Verkehrsdurchsatz wird durch die Anzahl der Fahrzeuge gemessen, die sich gleichzeitig auf der Straße befinden. Dabei werden die Werte mit denen eines traditionellen Taxiservices sowie mit jenen von Selbstfahrer*innen verglichen, da ein Ziel die Reduktion des Individualverkehrs ist.

Energieeffizienz

Abbildung 32 zeigt die insgesamt gefahrenen Strecken aller Fahrzeuge pro Modalitätsmodalität. Die Darstellung verdeutlicht, dass Ridesharing-Systeme gegenüber Taxis und selbstfahrenden Fahrzeugen hinsichtlich der Effizienz besser abschneiden. Die exakten Fahrtstrecken variieren dabei je nach verwendetem Ridesharing-Algorithmus. Busse erzielen die geringste Gesamtdistanz und sind in dieser Hinsicht die effizienteste Modalität.

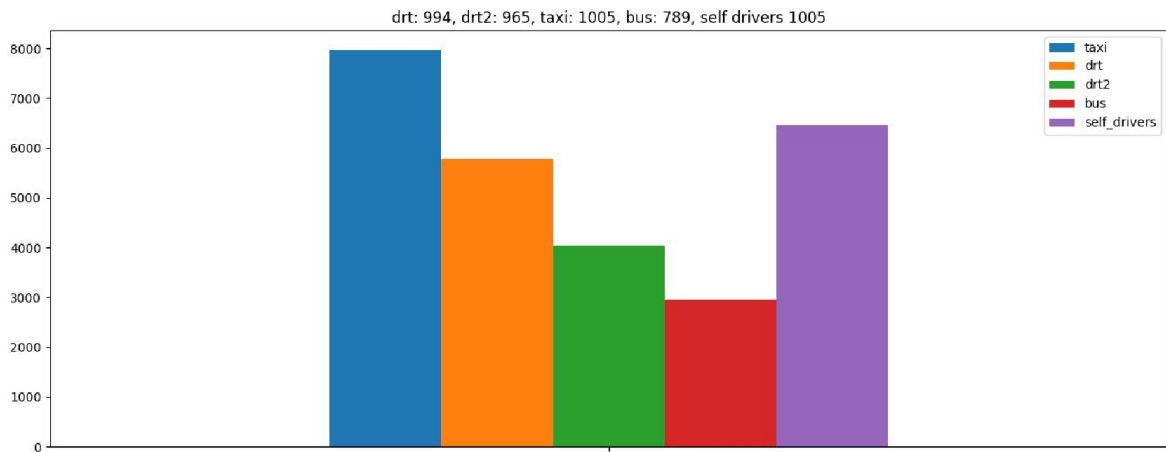


Abbildung 32: Gesamtdistanzen, die für alle Fahrzeuge einer Modalität gefahren wurden, um die Kunden zu bedienen

Es ist jedoch wichtig zu beachten, dass sowohl Busse als auch die Ridesharing-Algorithmen DRT/DRT2 nicht alle Kunden bedient haben. Dies wird auch durch die in der Bildüberschrift angegebenen Fahrgastzahlen deutlich. In der Simulation wurden einige Kunden vom Ridesharing-Algorithmus ausgeschlossen, verpassten den Bus oder entschieden sich aufgrund langer Wartezeiten für den Fußweg – da dieser in solchen Fällen die attraktivere Option war. Dies deutet darauf hin, dass die Abdeckung des Busnetzes für etwa 20 % der Anfragen unzureichend ist.

Modalität:	Bus	DRT	DRT2	Taxi	Selbstfahrer
Gefahrene km:	2948	5773	4045	7966	6470

Ein Blick auf den Ridesharing-Dienst mit den Algorithmen DRT bzw. DRT2 zeigt einen Anstieg der insgesamt gefahrenen Kilometer – und damit auch des Energieverbrauchs – um 28 % bzw. 50 % im Vergleich zum klassischen Taxisystem. Zusätzlich reduziert sich durch die geringere Anzahl gleichzeitig benötigter Fahrzeuge der Gesamtverkehr, was den Nutzen der geteilten Mobilität weiter erhöht.

Shared Mobility Latenz

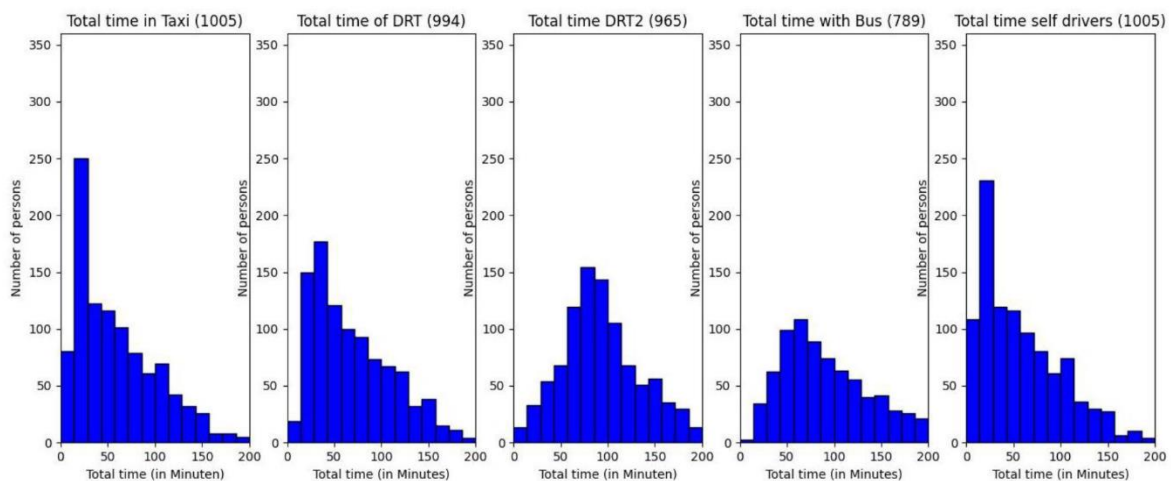


Abbildung 33: Gesamtzeit die eine Mobilitätsform erforderte, um die Kundenanfrage zu erfüllen

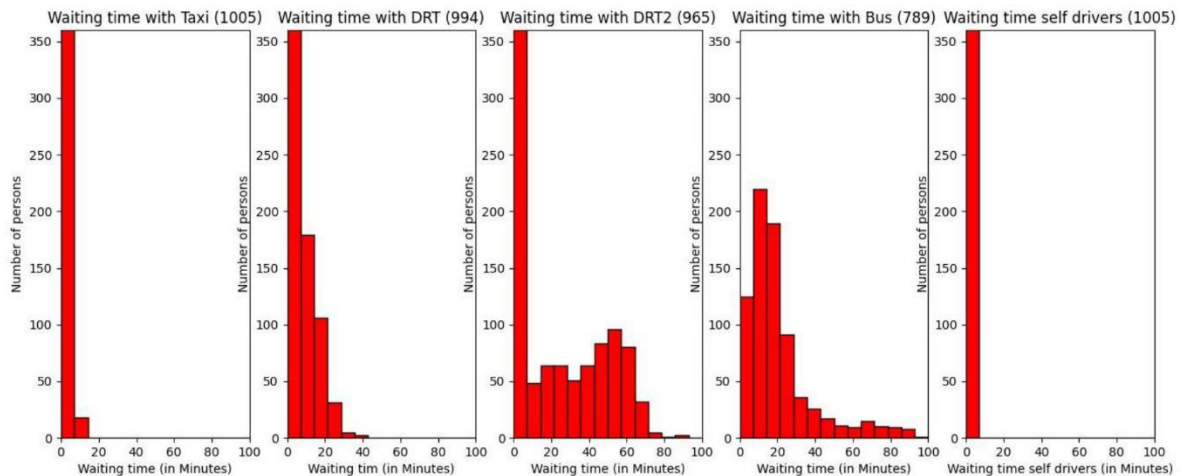


Abbildung 34: Wartezeit der Mobilitätsform

Wartezeit und Fahrstrecke im Vergleich:

Wie Abbildung 34 zu erkennen ist, sind die Wartezeiten für Selbstfahrer und Taxis ähnlich. Die durchschnittlich zurückgelegte Strecke ist bei Selbstfahrern jedoch etwas kürzer, was darauf zurückzuführen ist, dass Taxis zunächst zum Kunden fahren müssen. Bei Selbstfahrern wurde in der Simulation keine Wartezeit berücksichtigt, da Parkzeit ignoriert wurde – was in der Realität, insbesondere in Großstädten, ein erheblicher Faktor sein kann. Für Taxis ist die Wartezeit gering, da mit 100 eingesetzten Fahrzeugen ausreichend Kapazität vorhanden ist, um alle Kunden ohne nennenswerte Verzögerungen zu bedienen.

Demand Responsive Transport (Ridesharing):

Im Bereich des Ridesharing variieren die Wartezeiten je nach verwendetem Algorithmus. DRT (basierend auf drtOnline) schneidet besser ab als der Bus, während DRT2 (basierend auf drtOrtools) etwas schlechtere Werte zeigt.

Die mittleren Transportzeiten betragen:

Modalität:	Ø Transportzeit (Min.):
Bus	98,9
Taxi	59,9
DRT	91,8
DRT2	100,9
Selbstfahrer	59,1

Beim Vergleich von Ridesharing mit dem Bus zeigt sich eine **Reduktion der durchschnittlichen Fahrzeit um 7 % bei DRT**, während **bei DRT2 ein Anstieg um 2 %** zu beobachten ist. Diese Ergebnisse verdeutlichen, dass die Wahl des Algorithmus einen erheblichen Einfluss auf die *Shared Mobility Latency* hat. Eine signifikante Optimierung – beispielsweise die angestrebte Reduktion um 20 % – konnte mit den hier eingesetzten Algorithmen allerdings nicht erreicht werden. Dies legt nahe, dass weiterentwickelte Verfahren, etwa mit *Reinforcement Learning*, künftig bessere Ergebnisse erzielen könnten.

Verkehrsdurchsatz (Traffic Throughput):

Die Anzahl gleichzeitig benötigter Fahrzeuge in den jeweiligen Systemen wurde wie folgt ermittelt:

Modalität	Ø Fahrzeuge im Einsatz
Bus	16,5
Taxi	54,9
DRT	26,8
DRT2	20,1
Selbstfahrer	48,3

Diese Zahlen zeigen, dass Ridesharing etwa **45–60 % weniger Fahrzeuge** auf der Straße benötigt als individueller Verkehr mit Selbstfahrern. Das Bussystem setzt zwar die geringste Anzahl an Fahrzeugen ein, allerdings ist zu beachten, dass Busse deutlich größer sind und dadurch **einen wesentlich höheren Energieverbrauch pro Fahrzeug** aufweisen.

Sharing Factor:

Um zu bewerten, wie viele Kunden eine Modalitätsmodalität gleichzeitig nutzen, wurde der Key Performance Indicator (KPI) **Sharing Factor** herangezogen. Dieser Kennwert wird definiert als das Verhältnis der von Fahrgästen insgesamt zurückgelegten Strecke zur von Fahrzeugen mit Fahrgästen gefahrenen Strecke.

Die folgenden Werte wurden für das betrachtete Szenario ermittelt:

Modalität	Sharing Factor
Bus	3,1
Taxi	1,0
DRT	2,8
DRT2	4,0
Selbstfahrer	1,0

Der Sharing Factor für Taxis und Selbstfahrer liegt bei **1**, da in der Simulation jeweils nur **ein Kunde pro Fahrzeug** transportiert wurde. Gruppentransporte wurden nicht berücksichtigt.

Im Gegensatz dazu zeigt sich bei den Ridesharing-Diensten ein deutlich höherer Sharing Factor, wobei die Effizienz stark vom verwendeten Algorithmus abhängt. Der auf den **Google OR-Tools** basierende Algorithmus **DRT2** erreicht mit einem Wert von **4** den höchsten Wert. Dies geht jedoch zulasten der Kundenerfahrung, da die **Wartezeiten** im Vergleich zu anderen Modalitäten **länger** ausfallen.

Arbeitspaket 6 verfolgte weiterhin das Ziel, die aufgezeichneten Trainingsdaten und den entwickelten Demonstrator mit den in WP1 definierten Anforderungen abzugleichen.

Anforderungen bezüglich des Föderierten Lernens: Anforderungen bezüglich der Trainingsdaten wurden durch umfangreiche Trainingsdaten mit über 40 Merkmalen adäquat Rechnung getragen. Über 13.000 Km Testfahrten im Bereich Amberg, Schwandorf, Regensburg und Nürnberg wurden eingefahren. Die implementierte Algorithmik ist durch die datensparsame Implementierung wenig rechenintensiv, so dass das Training auf einem Raspberry Pi erfolgen kann. Auch die Kommunikationsanforderungen werden durch das datensparsame Modell erfüllt.

Anforderungen bezüglich der Integration in einen Mercedes EQC: Anforderungen bezüglich der Integration wurde soweit möglich von Seite der OTH Amberg-Weiden Rechnung getragen. Eine produktnahe Implementierung erfolgte im Tischdemonstrator mittels der ORA-Box. Dies ist dieselbe Hardware, die während des vorangegangenen 1000KmPlus-Projektes in den Mercedes EQC integriert wurde. Es erfolgte mit Mercedes auch eine Abstimmung der CAN-Pakete. Darüber hinaus wurde mit TTTAuto eine wireless Integration in den Mercedes mittels der von TTTAuto entwickelten Funklösung planerisch vorbereitet.

Die Anforderungen bezüglich der Integration in das KI-Konzept zur Routenoptimierung der Supply Chain 1:

Die Planung für eine finale Integration orientiert sich am Konzept des bereits abgeschlossenen Projektes 1000KmPlus. Das Konzept der Implementierung ist in folgender Abbildung dargestellt. Über die ORA-Box können die CAN-Daten des Mercedes abgegriffen und an den Client gesendet werden. Die ORA-Box fungiert auch als transparente Nachrichtenweiterleitung zwischen dem Client und dem Server. Da es sich um einen statischen Demonstrator handelt, war es nicht möglich, das Konzept vollständig zu implementieren.

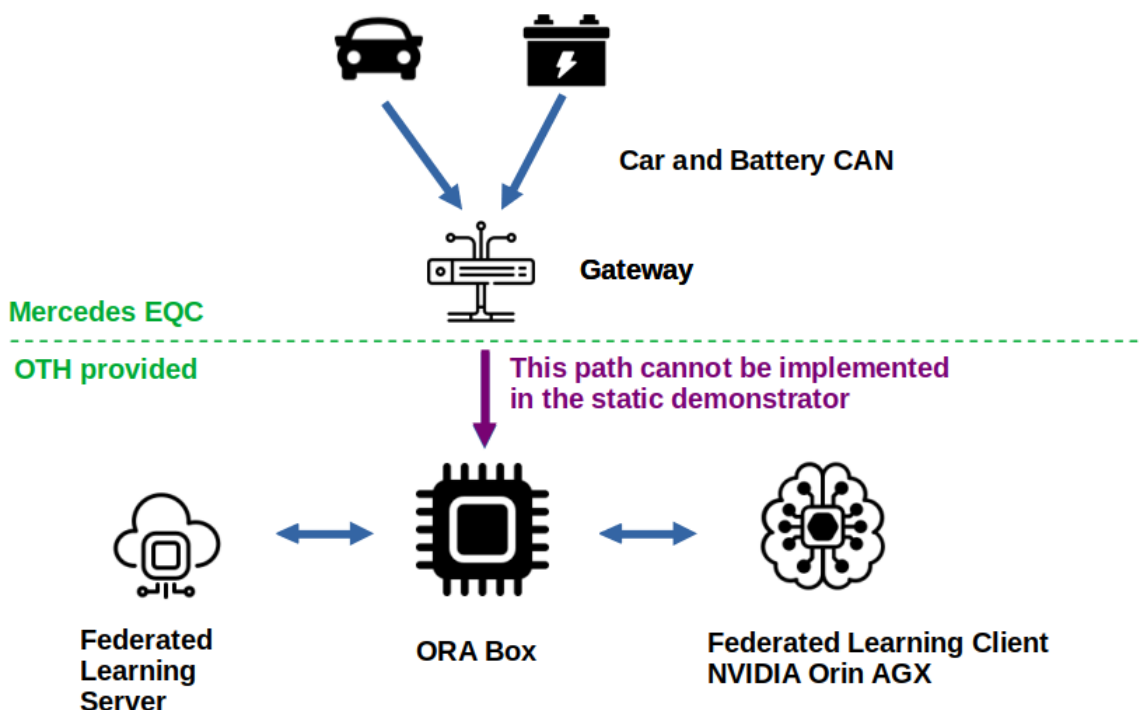


Abbildung 35: Integration von Föderiertem Lernen über die ORA-Box in den Mercedes EQC

Die Trainingsergebnisse zeigen, dass das Konzept funktioniert. Die folgende Abbildung visualisiert den Trainingsfortschritt über Trainingsrunden. Dargestellt sind Trainingsparameter für Geschwindigkeitsbegrenzungen von 10 bis 130 km/h. Diese Geschwindigkeitsbegrenzungen lassen sich auch im Vorfeld einer Fahrt zur Vorhersage vom Energieverbrauch in Abhängigkeit der Fahrtgeschwindigkeit ermitteln. Unbegrenzte Abschnitte auf der Autobahn wird 130 km/ zugeordnet. Es werden also 13 Parameter trainiert, die die Strecke nach Geschwindigkeitsbegrenzungen einteilt und jeder Geschwindigkeitsbegrenzung einer Energie / km zuordnet, Auf diese Weise können für beliebige Strecken, selbst unbekannte Strecken, für die noch keine Trainingsdaten vorliegen, bezüglich des Energieverbrauchs Vorhersagen getroffen werden, Die Parameter für 50 km/h und 100 km/h trainieren am schnellsten, da dies die häufigsten erlaubten Geschwindigkeitsbegrenzungen im Trainingsmaterial sind. Bei „CAR 1“ und „CAR 2“ zeigen sich kurzzeitige Ausreißer in den Trainingsparametern.

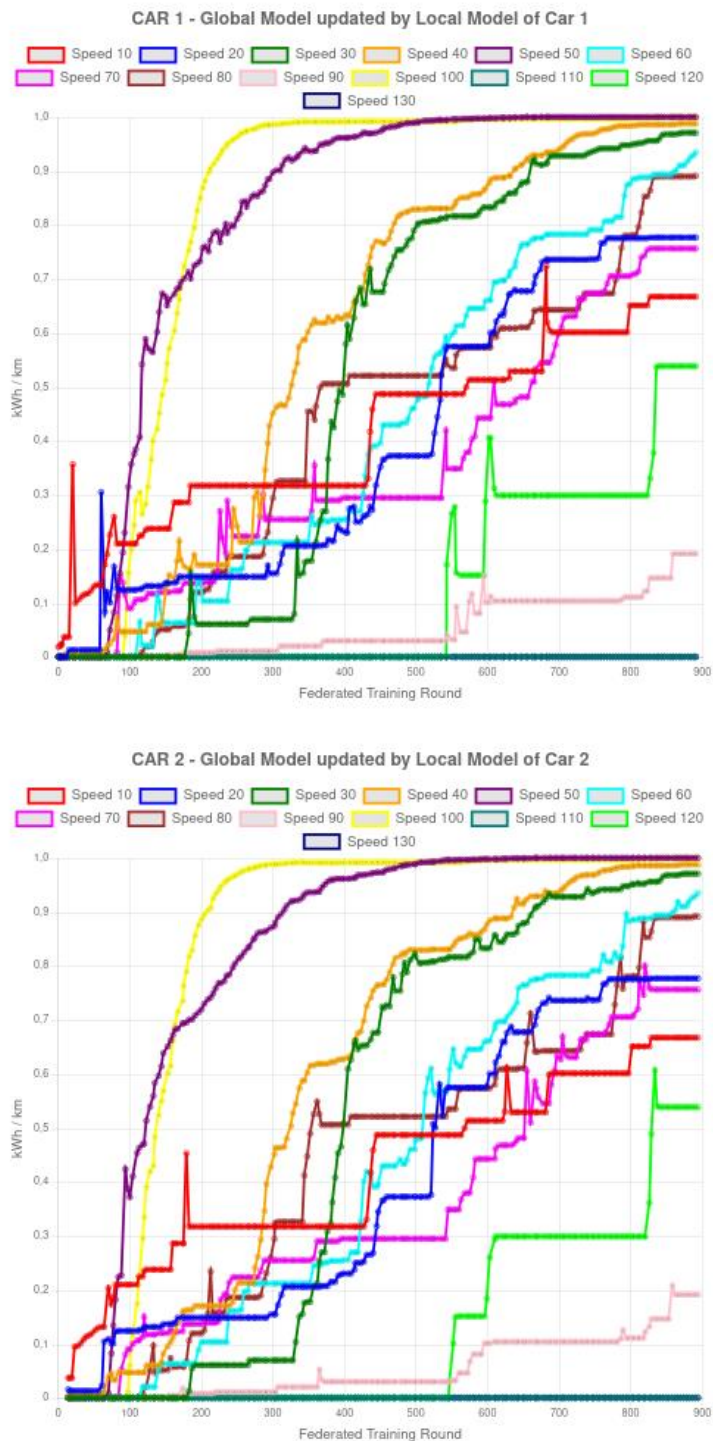


Abbildung 36: Visualisierung der Trainings der KI-Parameter. Der Übersichtlichkeit halber werden zwei von vier Fahrzeugen dargestellt.

Dies lässt sich darauf zurückführen, dass nur ein einziges oder zwei Fahrzeuge in der entsprechenden Geschwindigkeitsbegrenzung fahren, die anderen jedoch nicht. Da alle Parameter bei einem Energieverbrauch von 0 kWh/km anfangs initialisiert werden, können sich während des Trainings Parameter eines oder zweier Fahrzeuge schnell verändern, während dieselben Parameter der anderen Fahrzeuge auf 0 verharren. Durch die serverseitige Parametermittlung wird der Ausreißer mit dem nächsten globalen Modellupdate eliminiert. Besonders deutlich wird das anhand der hell-grünen Kurve für „Speed 120“, also 120 km/h. Die serverseitige Mittelung stellt sicher, dass jedes Fahrzeug von den

Fahrten aller Fahrzeuge profitiert. Deutlich wird auch, dass die rote Kurve „Speed 10“ (10 km/h) im Wesentlichen zu Beginn trainiert wird. Jede Trainingsfahrt beginnt auf einem Parkplatz, meist der OTH-Parkplatz für den teils 10 und teils 20 km/h hinterlegt sind. Dann fahren alle Fahrzeuge durch die Stadt und über längere Zeit bleibt er Parameter unverändert, bis der nächste Parkplatz angefahren wird oder die nächste Trainingsfahrt beginnt. Die Ergebnisse können im Detail in den Deliverables 6.1 und 6.2 nachvollzogen werden.

3.7 Ergebnisse WP7: Regulatory alignment, Standardisation, Exploitation, and Stakeholder Relations

Bis auf die durchgeführten Veröffentlichungen hatte OTH-AW keine Anteile in diesem Arbeitspaket.

3.8 Ergebnisse WP8: Project Management and Projects Clustering

OTH-AW hat keine Anteile in diesem Arbeitspaket.

4 Ergebnisverbreitung

Die aus den erfolgreichen Arbeiten in den technischen Arbeitspaketen des Projekts AI4CSM entstandenen Publikationen und Konferenzbeiträge stellen wesentliche Ergebnisse dar.

4.1 Konferenzbeiträge und Publikationen

Während der dreieinhalbjährigen Projektlaufzeit wurden die erzielten (Zwischen-)Ergebnisse fortlaufend aufbereitet und auf Konferenzen oder in öffentlich präsentiert.

Publikationen:

- K. Lutter, M. Schaffenroth, H. Lepke und A. Höß, „Repräsentativer Trainingsdatensatz für KI-gestützte Energieverbrauchsvorhersage für Elektrofahrzeuge“, *Forschungsbericht 2023*, S. 78-84, 2023.
- M. Schaffenroth, A. Baldermann, M. Fischer und A. Höß, „Reinforcement Learning für die Steuerung von Fahrzeugflotten“, *Forschungsbericht 2024*, S. 170–176, 2024.
- A. Baldermann, H. Lepke und A. Höß, „Reichweitenschätzung für Elektrofahrzeuge“, *Forschungsbericht 2025*, S. 70–76, erscheint 2025.
- M. Högner, Simulation von Verkehrsszenarien mit SUMO am Beispiel des Verkehrsnetzes der Stadt Amberg zur Evaluierung von Algorithmen autonomer Fahrzeuge, Bachelorarbeit, 28.2.2022
- T. Frank, Entwicklung eines verkehrsbasierten Routingsystems in einer simulierten Umgebung, Bachelorarbeit, 9.4.2024

Konferenzteilnahmen:

- K. Lutter, „Representative Training Dataset for Data-Driven Energy Consumption Prediction for Electric Vehicles“, *Women in Data Science Regensburg, OTH Regensburg*, 25.05.2023.
- Flower Summit 2024, 14-15 März 2024, London, Großbritannien (Online).
- EEAI 2024: The European Conference on EDGE AI Technologies and Applications, 21-23 October 2021, Cagliari, Sardinia

4.2 Erfindungen/Schutzrechtsanmeldungen

Im Rahmen von AI4CSM wurden von der OTH-AW keine Patentanmeldungen eingereicht.

5 Planung und Ablauf des Projekts

5.1 Planung und Ablauf von AI4CSM

Bei der Planung des Projektes AI4CSM konnte seitens OTH-AW auf die Erfahrungen aus Vorgängerprojekten (z.B. AUTBUS) zurückgegriffen werden. Die Planung konnte daher – auch aufgrund der guten Kooperation mit den anderen Verbundpartnern – zügig abgeschlossen und konsequent umgesetzt werden.

Den Herausforderungen entsprechend wurde das Projekt AI4CSM in einer Matrixstruktur gegliedert, welche Arbeitspakete und Demonstrator-spezifische Aktivitäten (Supply Chains) beinhaltet. In den Arbeitspaketen wurde die Basis für die Spezifikation, die Entwicklung, die Realisierung und die Evaluierung der innovativen Komponenten und Systemen geschaffen. Im Rahmen der Supply Chain SC2 erfolgte – zusammen mit Mercedes, AVL, TTTAuto – die Realisierung des Demonstrators 2.2. Auf die in jedem Arbeitspaket mit OTH-AW-Beteiligung bis Projektende erzielten Ergebnisse wurde in Kapitel 0 ausführlich eingegangen. An dieser Stelle sei zusammenfassend betont, dass die OTH-AW alle erwarteten Ergebnisse in vollem Umfang erreichte.

Die im Jahr 2020 aufkommende Corona-Pandemie und Personalmangel verursachte vor allem im ersten Projektjahr von AI4CSM nennenswerte Verzögerungen. Herausfordernd war zum einen die Koordination mit den Verbundpartnern, welche bis zum Ende des ersten Projektjahres nur Online erfolgte. Während des harten Lockdowns konnten die Mitarbeiter der OTH-AW dagegen ihr Equipment größtenteils mit nach Hause nehmen und im Home-Office weiterarbeiten, sodass dies die Arbeiten der Hochschule wenig beeinflusste. Als Folge der sich bei der überwiegenden Anzahl der Partner und auch der OTH-AW ergebenden Verzögerungen wurde gemeinsam mit ECSEL beschlossen, die Projektlaufzeit um 10 Monate bis zum 28.02.2025 zu verlängern, um sämtliche Arbeiten vollständig abschließen und abrechnen zu können. Das Abschlussreview fand Mitte Februar 2025 in Stuttgart in Präsenz statt.

5.2 Während der Projektlaufzeit bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Im Zuge der Antragstellung wurden die für AI4CSM relevanten Produkte, Projekte (soweit bekannt) und Forschungsprojekte analysiert. Gegenüber diesem Stand ergaben sich während der Projektlaufzeit keine weiteren wesentlichen FE-Ergebnisse.

6 Änderungen in der Zielsetzung

Während der Projektlaufzeit von 46 Monaten ergaben sich für das Teilvorhaben der OTH Amberg-Weiden in Supply Chain 2 wesentliche Änderungen der Zielsetzung. Im Amendment-Request „AMD-101007326-28“:

Ursprünglich beabsichtigte OTH Amberg-Weiden, KI und föderiertes Lernen zur Erkennung, Analyse und Reaktion auf Defekte einzusetzen, die beispielsweise im Antriebsstrang oder der Batterie eines Fahrzeugs auftreten. Leider hat sich herausgestellt, dass es im Kontext des Projekts nicht möglich ist, eine ausreichende Menge an geeigneten Trainingsdaten zu sammeln, da Defekte in Fahrzeugkomponenten nur sehr selten auftreten. Mit zu wenig Trainingsdaten ist es jedoch nicht möglich, hochwertige KI-Modelle zu trainieren.

Daher beantragte die OTH Amberg-Weiden um eine Abänderung der Zielsetzung, den föderierten Lernansatz auf ein anderes fahrzeugbezogenes Thema anzupassen. Ziel ist es, den Energieverbrauch eines Elektrofahrzeugs entlang der Fahrstrecke vorherzusagen. Eine präzise Vorhersage des Energieverbrauchs ist notwendig, um die Akzeptanz von Elektrofahrzeugen zu fördern, indem sie die Reichweitenangst verringert und als Grundlage für energieeffiziente Routing-Mechanismen (in SC1) dient. Geeignete Trainingsdaten zum Energieverbrauch von Elektrofahrzeugen können von den Projektpartnern selbst einfacher und in ausreichender Menge gesammelt werden. OTH hat bereits mit der Erfassung relevanter Daten begonnen. Selbstverständlich werden auch die Daten anderer Partner in unsere Algorithmen einfließen.

Die vorgeschlagene Änderung wurde sowohl mit dem SC2-Task-Leiter (AVL) als auch mit dem Leiter des Demonstrators SCD 2.1 (MBAG) abgestimmt. Die beantragte Änderung hat weder Auswirkungen auf den Gesamtprojekthalt noch auf Liefergegenstände oder Meilensteine, noch auf die Arbeit anderer Partner, noch auf den Aufwand oder das Budget.

7 Verwertungsplan und Erfolgsaussichten

Die OTH-AW hat das Potenzial und die hohe Relevanz der Forschungsfelder „Zuverlässige Kommunikation“, „Sichere Kommunikation“, „Vertrauenswürdige Kommunikation“ und „Authentifizierungstechnologien in Kommunikationsnetzwerken“ erkannt und arbeitet seit mehreren Jahren vor dem Beginn von AI4CSM zusammen mit namhaften Partnern entlang der gesamten Wertschöpfungskette an diesen Themen. Im Rahmen des ECSEL-Projekts AI4CSM wurden bestehende Bausteine auf die Drohnenanwendung portiert und wichtige zusätzliche Bausteine erarbeitet, die optimal als Ausgangspunkt für weitere, darauf aufbauende Forschungs- und Entwicklungsprojekte dienen können.

Geplante Verwertung der Ergebnisse aus AI4CSM

Als Hochschule strebt die OTH-AW keine wirtschaftliche Verwertung der in AI4CSM erarbeiteten Ergebnisse an. Die OTH-AW ist jedoch daran interessiert, die in Forschungsprojekten erworbenen Erkenntnisse – sofern möglich - im Rahmen von Patentanmeldungen zu verwerten.

OTH-AW wird die in AI4CSM gewonnenen Erkenntnisse in die Lehre integrieren. In die Ausbildung der Studentinnen und Studenten werden z. B. die neuesten Erkenntnisse aus dem Forschungsprojekt in einer Vorlesung im Masterstudiengang KI in einer dedizierten Federated Learning Vorlesung vermittelt, aber auch zur Außendarstellung der Forschungskompetenz der Hochschule verwendet. Durch Bachelor- und Masterarbeiten sind Studenten direkt in die Entwicklungsprozesse der Forschungsthemen eingebunden. Unser Ziel ist dabei, möglichst gut und praxisnah ausgebildete Absolventinnen und Absolventen für den Arbeitsmarkt vorzubereiten.

Weiterhin werden wir die erzielten Ergebnisse nicht nur auf Konferenzen/Tagungen einem Fachpublikum präsentieren, sondern einer breiten interessierten Öffentlichkeit vorstellen. Beispiele sind etwa Studieninformationstage (mit dem Ziel, Studierende - v.a. Frauen - für MINT-Studiengänge zu begeistern) oder Tage der offenen Tür bzw. Nacht der Wissenschaft, aber auch Beiträge in der lokalen Presse, auf der Hochschulwebseite und über unsere Social-Media-Kanäle (LinkedIn, Facebook, Instagram).

Verwertungsmöglichkeiten außerhalb des AI4CSM-Konsortiums

Das schlagkräftige AI4CSM-Konsortium wird auch nach dem Projektabschluss eine Quelle für eine gut ausgerichtete übergreifende Zusammenarbeit bleiben. Sowohl die OTH-AW als auch die Partner haben ein viel besseres Verständnis von den Anforderungen und Lösungen aller Supply Chains erhalten, die OTH-AW insbesondere durch die Zusammenarbeit innerhalb der SC2. Die mit dem Projekt AI4CSM erzielten Ergebnisse werden die Attraktivität der OTH-AW als Partner in weiteren Projekten mit der Industrie (speziell der Automobilindustrie, und ihren Tier1s und Tier2s) stärken. Zudem erlauben die AI4CSM Supply Chains (insbesondere die SC2) eine Erweiterung vom System-Knowhow der Hochschule in den Bereichen Federated Learning und Datenschutz.

Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

Die in AI4CSM erworbenen Kenntnisse sollen deswegen über die Lehre an der OTH-AW hinaus in weitere Forschungsprojekte einfließen, wodurch das gewonnene Wissen erweitert und vertieft werden kann. Einige Nachfolgeprojekte konnten bereits während der Projektlaufzeit von AI4CSM erfolgreich akquiriert werden und die Erkenntnisse aus AI4CSM laufend in die Projekte eingebracht werden.

Die Ergebnisse aus AI4CSM dienen als Basis für die Forschungsarbeiten der OTH-AW in den folgenden Projekten

- VRUIDFUL (gestartet am 1.11.2022)
- A-IQ Ready (gestartet am 1.1.2023)
- ARCHIMEDES (gestartet am 1.5.2023)
- ShapeFuture (gestartet am 1.5.2024)
- PowerizeD (gestartet am 1.1.2023)

Diese Liste kann als Beleg für die hohe Relevanz der in AI4CSM von der OTH-AW erarbeiteten Ergebnisse gewertet werden.

8 Wichtigste Positionen des zahlenmäßigen Nachweises

Die mit Abstand größte Position der Projektkosten betrifft die Personalkosten für das bei AI4CSM an der OTH-AW beschäftigte Personal, das die umfangreichen Forschungs- und Entwicklungsarbeiten durchführte. Mehr als 90% der Kosten entfielen auf diese Position.

Kosten für die Anschaffung von Hardware und die Anmietung des Tesla 3 Performance für Testfahrten. Ein Teil der anfallenden Kosten konnte durch hochschulinterne Mittel gedeckt werden.

Die Reisekosten fielen deutlich geringer aus als ursprünglich geplant, da aufgrund der Corona-Pandemie weniger Reisen zu Projekttreffen und Konferenzen durchgeführt wurden.

Im Projektverlauf wurde eine kostenneutrale Projektverlängerung notwendig, um die bestmöglichen Arbeitsergebnisse zu erzielen. Die dafür erforderlichen Personalmittel wurden durch Umschichtung von Reise- und Sachkosten in Personalmittel finanziert.

9 Referenzen

- [1] European Environment Agency., „Trends and projections in Europe 2022,“ Publications Office of the European Union, Luxemburg, 2022.
- [2] European Commission, „A European Strategy for Low-Emission Mobility. Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions,“ Brussels, 2016.
- [3] E. E. Agency. [Online]. Available: European Environment Agency, 2022. New registrations of electric vehicles in Europe. Copenhagen, Retrieved January 30, 2023 from <https://www.eea.europa.eu/ims/new-registrations-of-electric-vehicles>.
- [4] S. Y. M. P. S. G. Z. a. P. C. Statharas. [Online]. Available: 2019. Factors Influencing Electric Vehicle Penetration in the EU by 2030: A Model-Based Policy Assessment. *Energies* 12, 14 (January 2019), 2739. DOI:<https://doi.org/10.3390/en12142739>.
- [5] in Wen Li, Patrick Stanula, Patricia Egede, Sami Kara, and Christoph Herrmann. 2016. Determining the Main Factors Influencing the Energy Consumption of Electric Vehicles in the Usage Phase. *Procedia CIRP* 48, (January 2016), 352–357. DOI:<https://doi.org/10.1016/j.procir.2016.01.010>.
- [6] E. M. Szumska und R. S. Jurecki, „Emilia M. Szumska and Rafał S. Jurecki. 2021. Parameters Influencing on Electric Vehicle Range. *Energies* 14, 16 (January 2021), 4821. DOI:<https://doi.org/10.3390/en14164821>“.
- [7] E-GUIDE.RENAULT.COM / Zoe-ph2 / Know everything about your vehicle / Index. Retrieved February 3, 2023 from <https://gb.e-guide.renault.com/eng/Zoe-ph2/Know-everything-about-your-vehicle>.
- [8] [Online]. Available: 2018. How to Add Your Car to ABRP. A Better Route Planner. Retrieved January 30, 2023 from <https://forum.abetterrouteplanner.com/blogs/entry/19-how-to-add-your-car-to-abrp/>.
- [9] „Tesla, Inc. 2023. Model 3 Owner’s Manual. (January 2023). Retrieved February 2, 2023 from,“ [Online]. Available: https://www.tesla.com/ownersmanual/model3/de_de/Owners_Manual.pdf.
- [10] W. V. T. C. S. F. a. J. V. M. Cedric De Cauwer, „A Data-Driven Method for Energy Consumption Prediction and Energy-Efficient Routing of Electric Vehicles in Real-World Conditions,“ *Energies* 10, 05 05 2017.
- [11] „Michail Masikos, Konstantinos Demestichas, Evgenia Adamopoulou, and Michael Theologou. 2015. Mesoscopic forecasting of vehicular consumption using neural networks. *Soft Comput* 19, 1 (January 2015), 145–156. DOI:<https://doi.org/10.1007/s00500-014-1238-4>“.
- [12] „Jin Zhang, Zhenpo Wang, Peng Liu, and Zhaosheng Zhang. 2020. Energy consumption analysis and prediction of electric vehicles based on real-world driving data. *Applied Energy* 275, (October 2020), 115408. DOI:<https://doi.org/10.1016/j.apenergy.2020.115408>“.
- [13] „Xuewei Qi, Guoyuan Wu, Kanok Boriboonsomsin, and Matthew J. Barth. 2018. Data-driven decomposition analysis and estimation of link-level electric vehicle energy consumption under real-world traffic conditions. *Transportation Research Part D: Transport and Infrastructure* 64, (November 2018), 102–112. DOI:<https://doi.org/10.1016/j.trd.2018.09.004>“.

- [14] „Jin Zhang, Zhenpo Wang, Peng Liu, and Zhaosheng Zhang. 2020. Energy consumption analysis and prediction of electric vehicles based on real-world driving data. Applied Energy 275, (October 2020), 115408. DOI:<https://doi.org/10.1016/j.apenergy.2020.115408>“.
- [15] „McMahan, H. B. et al. (2017). Communication-Efficient Learning of Deep Networks from Decentralized Data. <https://arxiv.org/abs/1602.05629>,” [Online].
- [16] „Dwork, C. (2006). Differential Privacy. https://doi.org/10.1007/11681878_14“.
- [17] „Bonawitz, K. et al. (2017). Practical Secure Aggregation for Federated Learning on User-Held Data. <https://arxiv.org/abs/1611.04482>,” [Online].
- [18] „Gentry, C. (2009). A Fully Homomorphic Encryption Scheme. PhD Thesis, Stanford. <https://crypto.stanford.edu/craig>,” [Online].
- [19] „AUTOSAFE - Modulares System für integrale Sicherheit im Straßenverkehr,” [Online]. Available: http://autosafe.oth-aw.de/index.php?option=com_content&task=category§ionid=1&id=1&Itemid=30. [Zugriff am 18 1 2019].
- [20] „HAVEit,” [Online]. Available: <http://www.haveit-eu.org/displayITM1.asp?ITMID=6&LANG=EN>. [Zugriff am 2019 1 18].
- [21] „UR:BAN - Urbaner Raum: Benutzergerechte Assistenzsysteme und Netzmanagement,” [Online]. Available: <http://urban-online.org/de/urban.html>. [Zugriff am 18 1 2019].
- [22] „Kooperatives Hochautomatisiertes Fahren (Ko-HAF),“ [Online]. Available: <https://www.ko-haf.de/startseite/>. [Zugriff am 18 1 2019].
- [23] „eDAS - efficiency powered by smart Design meaningful Architecture connected System,” [Online]. Available: <http://www.edas-ev.eu/>. [Zugriff am 18 1 2019].
- [24] „3CCar,” [Online]. Available: <https://www.3ccar.eu/>. [Zugriff am 18 1 2019].
- [25] „AutoDrive,” [Online]. Available: <https://autodrive-project.eu/>. [Zugriff am 18 1 2019].
- [26] „Programmable Systems for Intelligence in Automobiles (Prystine),“ [Online]. Available: <http://prystine.eu/>. [Zugriff am 18 1 2019].
- [27] „AI4DI,” [Online]. Available: <http://ai4di.eu/>. [Zugriff am 28 1 2020].
- [28] B. f. B. u. Forschung, „KI-ASIC,” [Online]. Available: <https://www.elektronikforschung.de/projekte/ki-asic>. [Zugriff am 28 1 2020].
- [29] „1000kmPLUS,” [Online]. Available: <https://1000kmpius.automotive.oth-aw.de/>. [Zugriff am 29 1 2020].
- [30] „AutBus,” AVL Software and Functions GmbH, [Online]. Available: <https://roding-research.avl-functions.com/foerderprojekte/autbus-de/>. [Zugriff am 19 03 2025].