



Sachbericht zum Verwendungsnachweis
Teil 1 & 2

ZE: AVL Software and Functions GmbH	Förderkennzeichen: 16MEE0208
Vorhabenbezeichnung: TRANSACT	
Laufzeit des Vorhabens: 01.06.2021 – 30.06.2024	



Contents

1	Teil I: Kurzbericht.....	3
1.1	Aufgabenstellung.....	3
1.2	Wissenschaftlicher und technischer Stand	3
1.3	Wesentliche Ergebnisse und Zusammenarbeit.....	4
2	Teil II: Ausführlicher Schlussbericht	5
2.1	Beschreibung	5
2.1.1	AP1: Anwendungsfallanforderungen, KPIs und Evaluierung.....	5
2.1.2	AP2: Verteilte Lösungsarchitekturen und Plattformen für sicherheitskritische CPS..	8
2.1.3	AP3: Safety, Performance, Security und Datenschutz für verteilte sicherheitskritische CPS	11
2.1.4	AP4: Schnelle Innovation von erweiterten Diensten.....	13
2.1.4.1	Vorhersage der Batterie-Restlebensdauer durch KI.....	13
2.1.4.2	Vereinfachte Over-The-Air Update des Edge-Devices	15
2.1.4.3	Virtualisierung von Fahrzeugen	15
2.1.5	AP5: Integration, Demonstratoren und Validierung	17
2.1.6	AP6: Management, Community-Building und Verwertung	23
2.2	Bezug auf zahlenmäßigen Nachweis.....	23
2.3	Verwertbarkeit der Ergebnisse	23
2.4	Fortschritte durch Dritte	24
2.5	Veröffentlichungen	24
2.6	Quellen.....	24
	Bibliography	24



1 Teil I: Kurzbericht

1.1 Aufgabenstellung

AVL SFR entwickelt im Rahmen des TRANSACT-Projekts einen Demonstrator, der sich auf Batteriemanagementsysteme (BMS) für batterieelektrische Fahrzeuge konzentriert. Ziel ist es, sicherheitskritische Daten des BMS in die Cloud zu übertragen, um die Sicherheit des Fahrers zu erhöhen. Die Umsetzung erfolgt auf Basis der gemeinsamen TRANSACT-Architektur, die ein Device-Edge-Cloud-Kontinuum bereitstellt und eine flexible sowie sichere Bereitstellung von Anwendungen ermöglicht. Dabei adressiert der Demonstrator mehrere zentrale Herausforderungen des Projekts:

- Transformation der CPS-Architektur – Vom monolithischen BMS hin zu einer verteilten Lösung mit Integration von Edge- und Cloud-Technologien.
- Sicherstellung der Leistung – Die Architektur gewährleistet eine zuverlässige Übertragung und Verarbeitung sicherheitskritischer Daten im Device-Edge-Cloud-Kontinuum.
- Sicherheit und Datenschutz – Sensible BMS-Daten werden sicher und unter Wahrung der Privatsphäre übertragen und analysiert.
- Entwicklung neuer Geschäftsmodelle – Der Ansatz ermöglicht datenbasierte Mehrwertdienste und die Transformation von Systemherstellern zu Lösungsanbietern.

AVL SFR verfolgt einen Ansatz, der auf der TRANSACT-Architektur basiert und das Device-Edge-Cloud-Kontinuum nutzt. Der Demonstrator wird so konzipiert, dass BMS-Daten sicher von den Geräten in die Cloud übertragen werden können. Dort können diese Daten analysiert und zur Verbesserung der Systemsicherheit verwendet werden, beispielsweise zur Erkennung und Vorhersage kritischer Zustände.

Die Lösung basiert auf einer heterogenen Architektur, die die Verteilung der Rechenlast zwischen Gerät, Edge und Cloud ermöglicht. Dabei werden Datenservices und KI-basierte Analysemodelle integriert. Dies lässt auch zu, dass die Daten für erweitertes Nutzen bereitgestellt werden, z.B. durch Integration mit Lösungen von Drittparteien, welches spezielles Domänenwissen besitzen, oder mit Handy Apps für die Kommunikation mit dem Fahrzeugbesitzer. Durch diesen Ansatz trägt der Demonstrator zur Entwicklung neuer, datenbasierter Geschäftsmodelle bei.

1.2 Wissenschaftlicher und technischer Stand

Die aktuelle Entwicklung in der Fahrzeugindustrie zeigt einen deutlichen Trend hin zur Nutzung vernetzter, sicherheitskritischer Systeme. Moderne Batteriemanagementsysteme überwachen Ladezustände, Temperaturen und andere sicherheitskritische Parameter, arbeiten jedoch häufig isoliert und gerätegebunden. Edge- und Cloud-Technologien bieten das Potenzial, diese Daten für weitergehende Analysen und Services zu nutzen. Der wissenschaftliche Stand betont dabei die Notwendigkeit, Daten sicher, zuverlässig und in Echtzeit zwischen Geräten, Edge- und Cloud-Systemen auszutauschen. In bisherigen Architekturen steht jedoch die vollständige Integration solcher Technologien in sicherheitskritische Systeme noch aus. Die Herausforderungen umfassen die Sicherstellung von Leistung, Cybersicherheit und Datenschutz im gesamten Kontinuum sowie die Entwicklung skalierbarer Architekturen.



1.3 Wesentliche Ergebnisse und Zusammenarbeit

Da die Sicherheit in diesem System höchste Priorität besitzt, wurde zunächst eine Analyse erstellt, um die Risikofaktoren zu identifizieren und adressieren, welche durch die Transformation des anfänglichen isolierten Systems zu einem verteilten und verbundenen System aufkommen. Abgeleitete Maßnahmen wurden während der gesamten Umsetzungsphase berücksichtigt und integriert.

Daten des BMS werden zunächst über ein Edge-Device gesammelt und vorverarbeitet. Das Edge-Device dient als Brücke zwischen dem Fahrzeug und der Cloud, um eine sichere, effiziente und latenzarme Übertragung zu gewährleisten. Das entwickelte Edge-Device unterstützt Remote-Updates, um sowohl Sicherheitslücken zu schließen als auch neue Funktionen und Dienste effizient bereitzustellen. Diese Funktion gewährleistet eine kontinuierliche Verbesserung und Anpassung der Lösung an aktuelle Anforderungen.

In der Cloud werden die übertragenen BMS-Daten analysiert, und sicherheitskritische Indikatoren wie Zellwiderstände berechnet um den Degradationsstatus frühzeitig zu erkennen. Fahrzeugdaten und -Zustand werden auf einer hierfür entwickelten Visualisierung-Plattform dargestellt. Dies ermöglicht präventive Maßnahmen zur Erhöhung der Fahrersicherheit. Die Funktionalität wurde innerhalb des Projekts durch einen sicherheitskritischen Zwischenfall validiert.

Durch die Verfügbarkeit der Daten in der Cloud, werden diese an Projektpartner bereitgestellt. Einerseits, um dediziertere Analysen zu fahren, wofür spezielles Domänenwissen notwendig ist. Zur Wahrung der Datenschutzanforderungen nach GDPR werden die Daten im Rahmen eines Multi-Cloud-Ansatzes verteilt verarbeitet. Mittels Federated Learning können Analysemodelle verbessert werden, ohne dass Rohdaten zentralisiert gespeichert werden, was die Privatsphäre schützt. Andererseits um die Ergebnisse der Datenanalyse und Zustandsdaten über eine mobile App an den Fahrer zurückzumelden.

Darüber hinaus wird innerhalb des Fahrzeugs eine sichere und verlässliche Kommunikation zwischen BMS und Edge-Device mittels Bluetooth Low Energy (BLE) eingerichtet. Verschlüsselungsmechanismen stellen sicher, dass die Datenintegrität und Vertraulichkeit gewahrt bleiben, während Simulationen die Verbindungsqualität auch unter externen Störeinflüssen analysieren.

Die Arbeiten im Anwendungsfall Batteriemanagement wurden zusammen mit folgenden Partnern umgesetzt: CISC SEMICONDUCTOR GMBH, DAC Spolka Akcyjna, Deutsches Zentrum für Luft- und Raumfahrt, Denso Automotive Deutschland GmbH, Eclipse Foundation Europe GmbH, Politechnika Gdanska, Fraunhofer Gesellschaft zur Förderung der Angewandten Forschung E.V., Singlar Innovacion S.L., und Technische Universität Graz

2 Teil II: Ausführlicher Schlussbericht

2.1 Beschreibung

Das übergeordnete Ziel des TRANSACT-Projekts ist die Entwicklung einer universellen, verteilten Lösungsarchitektur für die Transformation sicherheitskritischer cyber-physikalischer Systeme (CPS), von lokalen isolierten Systemen hin zu sicheren und geschützten verteilten Lösungen unter Nutzung von Edge- und Cloud-Computing. Hierzu wird eine gemeinsame Systemarchitektur designet, welche in fünf unterschiedlichen Use Cases umgesetzt wird:

- UC1: Fernbetrieb autonomer Fahrzeuge zur Navigation in städtischen Umgebungen
- UC2: Kritische maritime Entscheidungsunterstützung erweitert durch verteilte, KI-unterstützte Edge- und Cloud-Lösungen
- UC3: Cloud-basierendes Batteriemangement für Elektrofahrzeuge
- UC4: Edge-Cloud-basierte Plattform für klinische Anwendungen zur bildgesteuerten Therapie und diagnostischen Bildgebungssystemen
- UC5: Kritische Entscheidungsunterstützung in der Abwasserbehandlung erweitert durch verteilte, KI-unterstützte Edge- und Cloud-Lösungen

AVL SFR ist für den UC3 verantwortlich.

Die detaillierten Ergebnisse werden im Folgenden strukturiert nach den Arbeitspaketen des Projekts dargestellt.

2.1.1 AP1: Anwendungsfallanforderungen, KPIs und Evaluierung

Zu Beginn wurde ein Betriebskonzept (Concept of Operations; ConOps) erstellt (siehe Abbildung 1)



Abbildung 1: Betriebskonzept des Demonstrators über die drei Ebenen Device, Edge und Cloud.).



Abbildung 1: Betriebskonzept des Demonstrators über die drei Ebenen Device, Edge und Cloud.

Darauf beruhend wurden die Use-Case-Spezifikationen in enger Zusammenarbeit mit den Partnern erarbeitet. Dabei definierte AVL als Use-Case-Leader endbenutzerorientierte Szenarien und Ziele, die mit den übergeordneten TRANSACT-Zielen abgestimmt waren. In der Nutzung des Systems gibt es zwei markante Stakeholder. Den Nutzer des Fahrzeuges und den



Entwickler bzw. Betreuer des Fahrzeuges mit Fokus auf das Batteriemanagementsystems. Entsprechend wurden die beiden Use-Cases „Erkennung abnormaler Batteriedegradation“ und „Entwicklung von Batterien und Batteriemanagementsystemen“ ausführlich beschrieben.

Parallel dazu wurden aus den initialen Spezifikationen funktionale und nicht-funktionale Anforderungen abgeleitet. Mithilfe der Spiralmethode identifizierte AVL die relevanten technischen Komponenten und formulierte die entsprechenden Anforderungen. Diese wurden iterativ verfeinert, bis ein umfassendes Bild der Anforderungen und Komponenten vorlag.

Ein weiterer Schwerpunkt lag auf der Beurteilung der Ergebnisse und der Veröffentlichung der TRANSACT-Methodik. AVL nahm aktiv an der Entwicklung von Ideen und Konzepten zur Bewertung des Transformationsprozesses teil. Aus der Perspektive der Businessanalyse, beobachtet man, dass in der Automobilindustrie der Begriff des Software Defined Vehicle (SDV) zunehmend präsenter wird. Bisher bestimmte die starre Architektur von Steuergeräten (ECUs) das Fahrzeugverhalten, was Änderungen und Erweiterungen erschwerte. SDV zielt darauf ab, diese Einschränkungen zu überwinden, indem die Intelligenz auf leistungsfähige, zentrale Recheneinheiten verlagert wird. Durch die Integration der Cloud können Rechenressourcen flexibel hinzugefügt, Daten in Echtzeit analysiert und sicherheitskritische Ereignisse schneller bearbeitet werden. Das lokale BMS wird dabei in ein verteiltes System umgewandelt, was als Vorläufer des SDV-Konzepts dient.

Die Kaufentscheidung von Kunden basiert auf einer Vielzahl von Faktoren wie Preis, Qualität und Sicherheit. Durch die Erweiterung des BMS steigt der Wert des Fahrzeugs, was den Ausschlag für eine Kaufentscheidung geben kann. Die neue Lösung bietet zusätzlich Funktionen wie Datenanalyse, automatisierte Berichterstattung und Schnittstellen zu Drittanbieterlösungen, die das System weiter verbessern.

Neben den technischen Aspekten wurden auch organisatorische Veränderungen betrachtet, die durch die erhöhte Systemkomplexität erforderlich wurden. Die Erweiterung des BMS erfordert die Einbindung zusätzlicher Teams. Vor der Umstellung waren hauptsächlich die Teams für BMS-Hardware, Software und Security&Safety in den Produktentwicklungsprozess involviert. Nach der Umstellung mussten jedoch auch folgende Teams integriert werden:

- Digitalisierung: für das ganzheitliche Management der Lösung.
- Cloud Services: für die Entwicklung der cloudbasierten Infrastruktur und Funktionen.
- Datenanalyse: für die Auswertung der nun verfügbaren Daten.
- IT/DevOps: für die Bereitstellung der Entwicklungsplattform und die Ermöglichung der Kommunikation zwischen On-Premise- und Cloud-Infrastruktur sowie Remote-Hardware.
- Security & Safety: für die Analyse der vergrößerten Angriffsfläche sowie Umsetzung der sicheren Kommunikation zwischen dem Fahrzeug und der Backend-Infrastruktur.

Diese Erweiterungen verdeutlichen die steigende Komplexität der verteilten Lösung. Je nach Geschäftsmodell kann entweder die bestehende AVL-Infrastruktur dupliziert oder skaliert werden, oder die gesamte Infrastruktur muss beim Kunden vor Ort aufgebaut und integriert werden. Es sind auch gemischte Setups möglich, bei denen z.B. die Gateway-Software auf vorhandener Hardware integriert wird, aber die Cloud von AVL bereitgestellt wird. Zudem muss das Personal des Kunden geschult werden, um das System zu warten und die analytischen Komponenten des Backends sowie die Kommunikationswege, einschließlich der Sicherheitsfunktionen, zu verstehen und zu integrieren.

2.1.2 AP2: Verteilte Lösungsarchitekturen und Plattformen für sicherheitskritische CPS

Der Zweck von AP2 ist das Design und die Erstellung einer gemeinsamen Architektur, welche für alle Use Cases innerhalb des TRANSACT Projekts, die Flexibilität bei der Bereitstellung von Anwendungen und der Verteilung von Aufgaben bieten. Die Vision ist, eine optimale Verteilung der Funktionalitäten über das Device-Edge-Cloud-Kontinuum zu ermöglichen, wobei Sicherheit, Datenschutz und Vertraulichkeit gewährleistet bleiben. Um diese Vision zu unterstützen, wird das Arbeitspaket die architektonischen Herausforderungen im Bereich Sicherheit und Datenschutz in verteilten Systemen sammeln und architektonische Muster bereitstellen, die diese Herausforderungen lösen oder deren Lösung erleichtern. Weiterhin werden Referenzen für Architekturen und Implementierungen zur Verfügung gestellt, die als Leitfaden für den Übergang von einer lokalen On-Device-Lösung zu gemischten Device-Edge-Cloud-Systemen dienen. Für diesen Übergang wird WP2 auch Mittel für die Spezifikation und simulationsbasierte Analyse der Dienste eines solchen Systems bereitstellen.

In Bezug auf den BMS Use Case (Batteriemanagementsystem) bedeutet dies, dass AP2 eine theoretische Grundlage für die Integration des BMS in eine verteilte Architektur bietet. Dabei wird eine Architektur entwickelt, die es ermöglicht, Aufgaben zwischen den Fahrzeuggeräten, Edge-Computing-Geräten und der Cloud effizient zu verteilen. Die durch AP2 bereitgestellten Referenzen und Methoden unterstützen den Übergang des BMS zu einer dezentralen, aber sicheren und datenschutzkonformen Lösung, die mit anderen Fahrzeugfunktionen und Cloud-Diensten zusammenarbeiten kann.

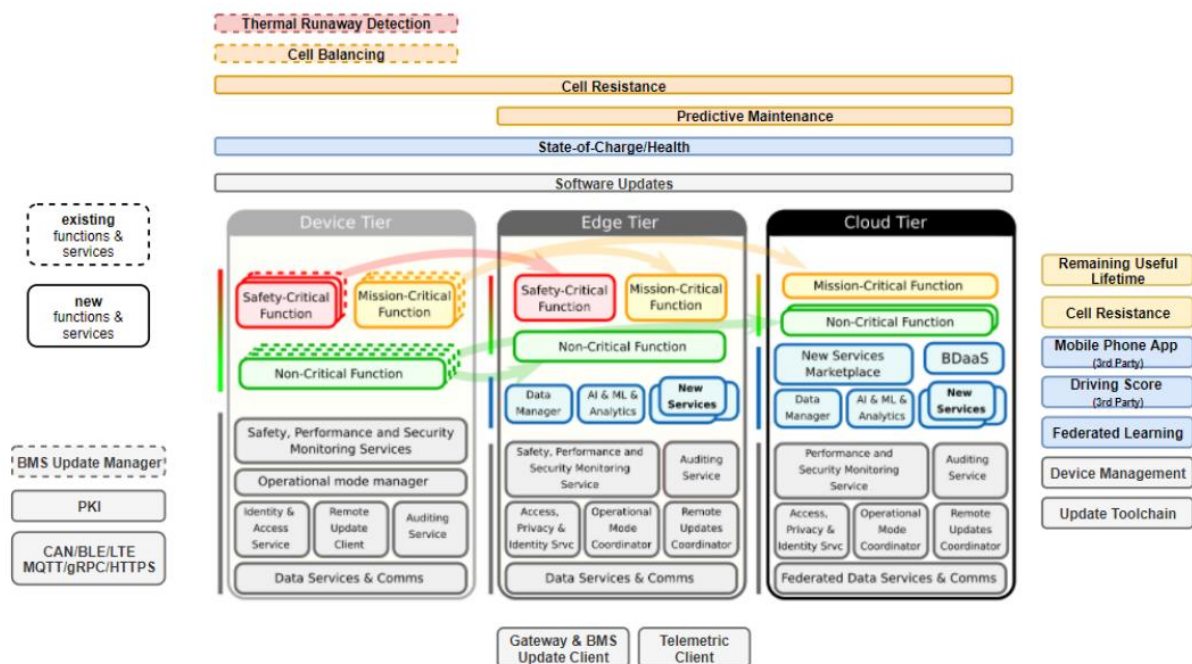


Abbildung 2: Zusammenhang zwischen der generischen TRANSACT-Architektur und den Umsetzungen im Use Case Demonstrator.



Neben der theoretischen und generalisierten Betrachtung der Architektur (siehe Abbildung 2) wurden bestimmte Aspekte anwendungsorientiert betrachtet. So wurde z.B. ein Sicherheitskonzept entwickelt, das speziell auf moderne, verteilte Fahrzeugarchitekturen, aber auch auf andere Cyber-Physikalische Systeme (CPS) anwendbar ist. Der Fokus lag auf der Nutzung symmetrischer Verschlüsselungsverfahren für Komponenten mit geringer Rechenkapazität. Zudem wurden Architekturkomponenten und -prozesse beschrieben, die eine sichere Kommunikation zwischen Fahrzeugen und der Cloud ermöglichen, wobei X.509 Zertifikate und gegenseitige Authentifizierung eingesetzt werden.

Ein weiterer zentraler Aspekt war die Analyse von Trade-offs, insbesondere das Abwägen zwischen Qualitätsmerkmalen. Laut dem International Requirement Engineering Board (IREB) werden Anforderungen in zwei Gruppen unterteilt: funktionale Anforderungen und Qualitätsmerkmale. Während die funktionalen Anforderungen den Verhaltensbereich abdecken, definieren die Qualitätsmerkmale stark die gesamte Softwarearchitektur und spiegeln sich hauptsächlich im physischen Bereich wider. In diesem Projekt ist die Zielarchitektur jedoch bereits definiert. Daher besteht die Aufgabe eher darin, die bestehenden (oder neuen) Funktionen zu zerlegen und der entsprechenden Ebene und dem physischen Architekturelement zuzuordnen.

AVL hat Vorschläge zur Transformation klassischer Lösungen in verteilte, sicherheitskritische CPS-Systeme eingebracht. Hierbei wurde auch der generische Entwicklungsprozess für die Transformation unterstützt. Eine der Herausforderungen bei der Umstellung auf verteilte Systeme besteht darin, dass bestehende Systeme oft nicht in klar abgegrenzte Phasen und Domänen unterteilt sind. AVL entwickelte hierfür ein Konzept, das auf Reverse Engineering basiert, um bestehende Systeme zu analysieren und nachträglich neu zu strukturieren, um eine Re-Allokation der Funktionen und Komponenten zu ermöglichen. Das wurde anhand des Use Cases auch exemplarisch aufgezeigt.

Der Ansatz umfasst die folgenden Schritte:

1. Physikalische Zerlegung des Systems.
2. Bewertung der physikalischen Elemente gemäß den Qualitätsmerkmalen.
3. Funktionale Zerlegung.
4. Zuordnung der funktionalen und physikalischen Domänen in Bezug auf das Qualitätsmerkmal.

Zur Vereinfachung wird hier die Zuordnung zur Anforderungsdomäne übersprungen. Die funktionalen Anforderungen werden jedoch implizit im Kontext der funktionalen Analyse und Zerlegung berücksichtigt.

Beispiel: Berechnung des DC-Widerstands der Batteriezellen.

Use Case: Ein Algorithmus soll den individuellen DC-Zellwiderstand des Batteriepakets berechnen.

Physikalische Zerlegung des Systems:

- Device-Ebene: Batteriemanagementsystem (BMS; eingebettetes System)
- Edge-Ebene: LTE-Gateway
- Cloud: Cloud-System

Bewertung der physikalischen Elemente gemäß den Qualitätsmerkmalen.

Die Bewertungsergebnisse sind in Tabelle 5 dargestellt.

Quality Attribute	Physical Domain			Functional Domain		
	BMS	Gateway	Cloud	Read	Store	Compute
Adaptability	3	2	1	3	2	1
Extensibility	3	2	1	3	2	1
Interchangeability	3	2	1	3	3	3
Interoperability	2	2	1	3	3	3
Maintainability	3	2	1	3	2	1
Performance	3	2	1	3	1	1
Persistency	3	2	1	3	1	1
Reliability	1	2	2	1	2	2
Safety	1	2	3	3	3	3
Scalability	3	3	1	3	1	1
Security	3	1	1	3	1	1
Standards	1	3	3	1	3	3
Testability	3	2	1	3	1	1
Timeliness	1	2	3	1	2	2

Abbildung 3: Bewertung der Qualitätsmerkmale pro physikalischer Komponente und Funktion: Die Bewertungsskala reicht von 1 (sehr gut) bis 3 (schlecht); die Anforderung aus funktionaler Sicht reicht von 1 (sehr wichtig) bis 3 (geringe Relevanz).

Funktionale Zerlegung:

- Zellspannungen und -ströme lesen.
- Daten persistent speichern.
- Zellwiderstand berechnen.

Zuordnung der funktionalen und physikalischen Domänen in Bezug auf das Qualitätsmerkmal

Durch den Vergleich der Anforderungen der Funktionen und der Bewertung der Qualitätsmerkmale pro Ebene können die folgenden besten Übereinstimmungen identifiziert werden:

- "Read" wird dem BMS zugeordnet.
- "Store" wird der Cloud zugeordnet.
- "Compute" wird der Cloud zugeordnet.

Der dargestellte Ansatz zeigt, wie der funktionale und der physikalische Bereich abgebildet werden können. Es ist erwähnenswert, dass neben den Qualitätsmerkmalen auch andere Designentscheidungen eine Rolle spielen können, wie zum Beispiel die Clustering aufeinanderfolgender Funktionen.



2.1.3 AP3: Safety, Performance, Security und Datenschutz für verteilte sicherheitskritische CPS

Ziel von AP3 ist es, Konzepte und Lösungen zu entwickeln, die sicherstellen, dass verteilte, sicherheitskritische CPS-Systeme über die notwendigen Mittel verfügen, um sicher, leistungsfähig, sicherheitskonform und datenschutzfreundlich zu arbeiten, während sie gleichzeitig von Edge- und Cloud-unterstützten Diensten profitieren. Basierend auf den in AP1 identifizierten Anforderungen werden diese Konzepte und Lösungen entwickelt und mit der in AP2 erarbeiteten TRANSACT-Referenzarchitektur abgestimmt. Dabei werden auch die Spannungen und Wechselwirkungen zwischen den Konzepten und Lösungen hinsichtlich Sicherheit und Leistung im Vergleich zu Sicherheits- und Datenschutzanforderungen identifiziert.

Wahrscheinlich ist das häufigste Problem im Bereich des maschinellen Lernens der Mangel an Daten für das Training. Das zentrale Sammeln von Daten aus verschiedenen Quellen, einschließlich privater, wird jedoch höchstwahrscheinlich mit der europäischen Datenschutz-Grundverordnung (DSGVO) in Konflikt geraten. Die Verordnung basiert auf zwei Säulen: Datenschutz und Privatsphäre. Die Artikel der Verordnung beschreiben Aspekte wie: Transparenz und Kommunikation, Recht auf Zugang, Genauigkeit, Recht auf Löschung, Recht auf Einschränkung der Verarbeitung, Datenportabilität und Widerspruchsrecht. Die DSGVO war eine Reaktion auf das mangelhafte Selbstverständnis von Unternehmen im Umgang mit der Privatsphäre, dem Besitz und der Nutzung der Daten der Nutzer.

Offensichtlich scheinen Privatsphäre und Datenverarbeitung im maschinellen Lernen miteinander zu konkurrieren. Anstatt Systeme zu entwickeln, die mit jeder bestehenden und zukünftigen Verordnung konform sind, stellt ein alternativer Ansatz den Datenschutz von Anfang an sicher, z. B. Federated Learning. In diesem Fall werden private Daten niemals übertragen und nur lokal gespeichert.

AVL hat hier die Anwendungsmöglichkeit von Federated Learning für den Use Case untersucht. Hierbei handelt es sich um eine Daten-Architektur für maschinelles Lernen, wobei die Daten am Ort der Erzeugung und somit beim Besitzer verbleiben und dennoch neuronale Netze trainiert werden können. Dieses Konzept wurde initial von Google entworfen und implementiert (H. Brendan McMahan, 2016).

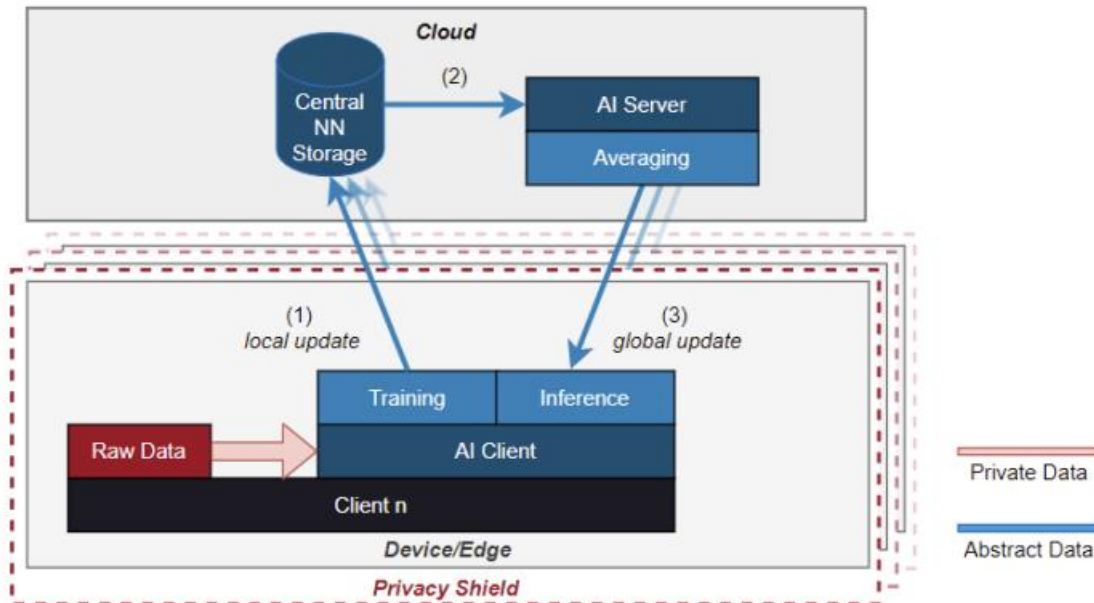


Abbildung 4: Privacy-by-Design Lösung für das Trainieren mit verteilten Daten. (1) Rohdaten werden nur lokal für die Inferenz verwendet, aber niemals an eine Instanz außerhalb des Fahrzeugs übertragen. Sie werden auch für das Training verwendet, das ausschließlich lokal durchgeführt wird. (2) Das lokale Update der neuronalen Netzwerkgewichte wird dann an den zentralen Speicher übertragen, wo sie mit den Gewichten aller anderen teilnehmenden Clients gemittelt werden. (4) Das globale Update wird dann an alle Clients verteilt.

Speziell im Use Case des Batteriemangement Systems stellt sich die Situation wie folgt dar: Anstatt die privaten Daten für das Training an das Cloud-Backend zu übertragen, läuft der Trainingsprozess lokal auf dem Gerät oder Edge, was zu einer lokalen Aktualisierung des bereits implementierten neuronalen Netzwerks führt (siehe Abbildung 4, Schritt 1). Danach werden die neuen und abstrahierten Gewichte an das Cloud-Backend übertragen (Schritt 2), wo sie von verschiedenen Clients gesammelt und gemittelt werden. Es erfolgt keine Übertragung der Rohdaten mehr, und alle Datenschutzprobleme werden umgangen. Die neuen Gewichte werden dann als globales Update an alle Clients und für die Inferenz (Schritt 3) verteilt. Auf diese Weise verbleiben die privaten Daten auf dem Gerät/Edge, das der Person gehört, die die Daten erzeugt – ein Datenschutzschild wird aufgebaut.

Die Umsetzung erfolgte im Zuge einer Masterarbeit zwischen AVL und der TU München. Als Basis wurde das Framework ADAP Flower verwendet. Im speziellen ging es um die Berechnung der verbleibenden Nutzungsdauer der Batterie (Remaining Useful Lifetime, RUL), siehe dazu Abbildung 5. Die Ergebnisse wurden auch in einem gemeinsamen Paper veröffentlicht (Kröger, 2023).

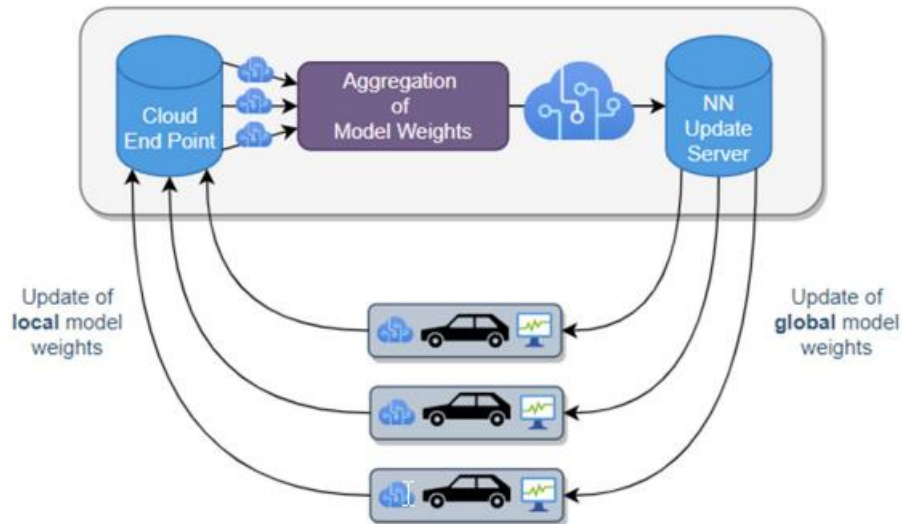


Abbildung 5: Austausch von Modellgewichten eines neuronalen Netzwerks, das zur Vorhersage der verbleibenden Nutzungsdauer der Batterie verwendet wird.

2.1.4 AP4: Schnelle Innovation von erweiterten Diensten

Durch die verteilte Architektur und die Anwendung moderner Technologiestacks eröffnen sich neue Möglichkeiten, um die Entwicklung und Integration neuer Dienste stark zu beschleunigen. Dazu gehören fortschrittliche Technologien wie künstliche Intelligenz, DevOps, (Co-)Simulationen und Virtualisierung

Ein Schwerpunkt liegt auf der Integration von KI-Diensten in verteilte, sicherheitskritische CPS, um deren Leistungsfähigkeit zu erhöhen und innovative Lösungen zu fördern. Parallel dazu werden Strategien für kontinuierliche Updates und unabhängige Releases entwickelt, um Systeme flexibel und sicher zu halten. Zudem wird erforscht, wie die Entwicklung von Innovationen durch den Einsatz verteilter Lösungen beschleunigt werden kann, indem Entwicklungsprozesse optimiert und Technologien wie Virtualisierung genutzt werden.

AVL hat hier an verschiedenen Lösungen im Zusammenhang mit dem Use Case gearbeitet.

2.1.4.1 Vorhersage der Batterie-Restlebensdauer durch KI

Da die BMS bzw. Batteriedaten in der Cloud verfügbar sind, können die Vorteile der persistenten Speicherung und der skalierbaren Rechenleistung genutzt werden. Datenanalyse, insbesondere mittels KI, werden dadurch ermöglicht. Konkret wurde untersucht, wie Federated Learning mit einem Vorhersagemodell für die Batterie-Restlebensdauer (Remaining Useful Lifetime; RUL) kombiniert werden kann. Die Modelarchitektur für die Vorhersage stammt von (Li, et al., 2021) und wurde Seitens AVL angepasst und mittels öffentlicher Daten trainiert (Severson, et al., 2019). Die Basis des Modells ist ein Long Short-Term Memory Konzept, welches auch die Basis für Transformer-Modelle wie das inzwischen sehr bekannten ChatGPT

bildet. Die Aufgabe des RUL-Modells besteht darin, aufgrund der bisherigen Degradation der Zellen vorherzusagen, wie sich der Verlauf in der Zukunft darstellen wird. Abbildung 6 zeigt beispielhaft mehrere Degradationsvorhersagen des trainierten Modells, wenn dieses auf Daten angewendet wird, welche noch nicht für das Training verwendet wurden.

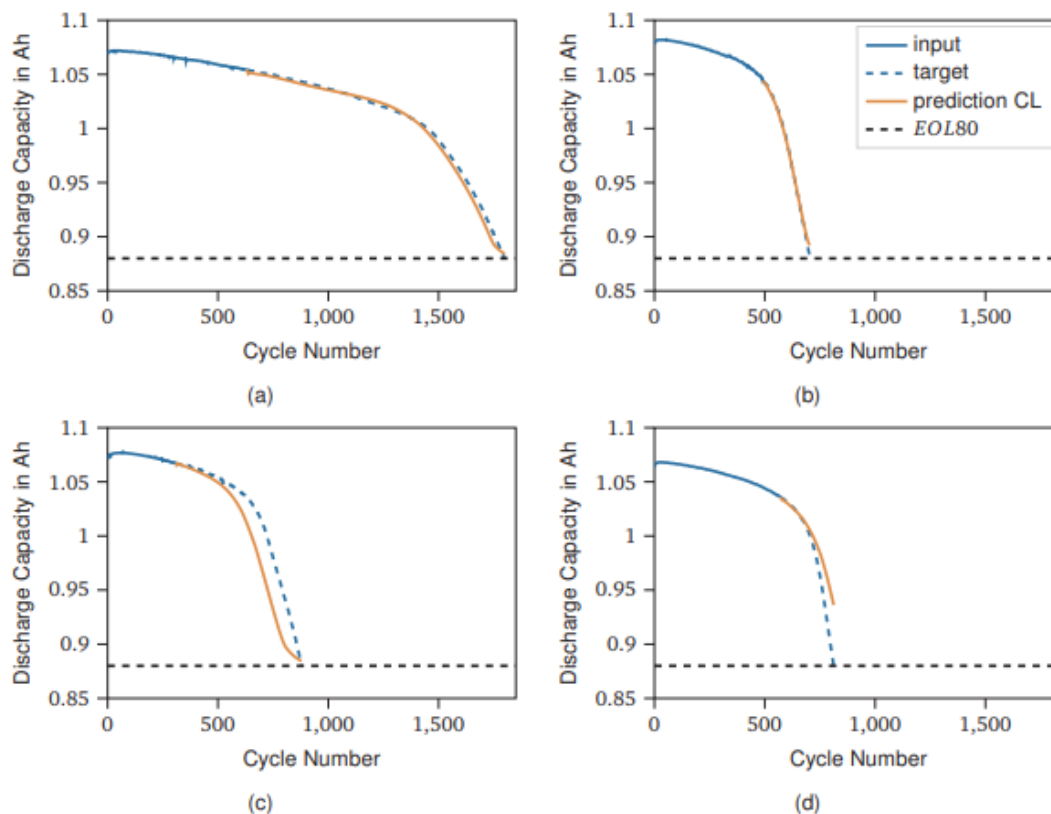


Abbildung 6: Degradationsverlauf von Batteriezellen. Die Daten dargestellt durch die durchgezogene Linie („input“) stellen die Eingabewerte für das Modell dar. Die orange durchgezogene Linie („prediction CL“) ist die Vorhersage des KI Modells über den weiteren Verlauf der Zelldegradation. Zum Vergleich ist der tatsächliche Verlauf als blaue gestrichelte Linie hinterlegt („target“).

Die Qualität der Ergebnisse variiert, jedoch kann das Model mit stark unterschiedlichen Verläufen der degradierenden Batteriezellen umgehen. Hier wurden für das Training alle Datensätze klassisch zentral gesammelt und verarbeitet. Im nächsten Schritt wurde verglichen, wie sich die Qualität der Vorhersagen verändert, wenn die Daten nicht mehr zentral gesammelt und verarbeitet werden, sondern im Sinne von Federated Learning auf verschiedene Klienten, z.B. Flottenbetreiber oder sogar einzelne Fahrzeuge, verteilt sind.

Abbildung 7 zeigt, wie sich der Fehler in der Vorhersage verhält, wenn derselbe Datensatz (96 einzelne Messung) auf verschiedene Anzahl n an Klienten verteilt wird. Für den Fall $n=1$ gilt, dass alle 96 Datensätze zentral verarbeitet werden und dient somit als Referenzwert. Dahingegen wird mit $n=96$ der andere Grenzfall betrachtet, dass jedes Fahrzeug einen Datensatz darstellt und die Daten nur lokal verarbeitet werden. Das Ergebnis zeigt, dass der durchschnittliche MAPE von etwa 1% auf lediglich 2% ansteigt. Somit wurde gezeigt, dass

Federated Learning sehr gut mit der Vorhersage der RUL kombiniert werden kann. Es ist zu erwarten, dass mit erhöhter Anzahl an Teilnehmer die Divergenz zwischen zentralisierten und verteilten Lernen nahezu verschwinden wird.

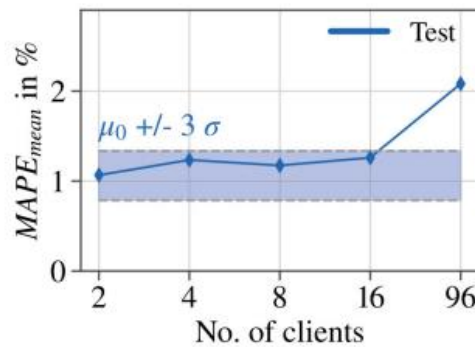


Abbildung 7: Mean Average Percentage Error (MAPE) in Abhängigkeit vom Ausmaß der Verteilung der Daten über verschiedene Klienten. Entnommen aus (Kröger, 2023).

2.1.4.2 Vereinfachte Over-The-Air Update des Edge-Devices

Für die Datenübertragung zwischen Fahrzeug und Cloud hat AVL eine eigene Telemetrielösung (Edge-Device, Gateway) entwickelt. Auch wenn es hierfür verschiedene Lösung auf dem Markt gibt, wurde im Laufe des Projekts klar, dass keine der kommerziell verfügbaren Telemetrielösungen den Anforderungen des Projekts nachkommt. Die AVL eigene Lösung („BMcB“) muss auch die Möglichkeit bereitstellen, möglichst einfach eine neue Softwareversion auszuführen. Hierfür wurde durch Virtualisierung der Hardware und das Aufbringen einer Docker Laufzeitumgebung eine Trennung zwischen Hardware und Software erreicht. Die Software kann unabhängig von der darunterliegenden Hardware in der Entwicklungsumgebung des Softwareentwickler implementiert werden (z.B. x86). Eine automatisierte Build Pipeline innerhalb der ALV IT Infrastruktur erzeugt einen Docker-Container innerhalb einer virtualisierten Hardwareumgebung, sodass dieser kompatibel zur Zielhardware-Architektur (z.B. ARM64) ist. Der Docker Container wird dann in einer Docker Container Registry, gehostet durch Microsoft Azure, bereitgestellt. Auf dem Gateway läuft eine Applikation, welche bei jedem Start überprüft, ob eine neue Softwareversion vorliegt. Falls ja, wird diese automatisch heruntergeladen und gestartet.

Dieser Ansatz vereinfachte die Entwicklung enorm, da nun das Gateway (BMcB) permanent verkabelt im Testfahrzeug verbleiben kann. Vorher war es immer notwendig, das Gateway komplett auszubauen, mit dem PC zu verbinden, um neue Softwareversion aufzuspielen. Besonders im Zuge des schnellen bereitstellen durch moderne Methoden wie CI/CD (Continuous Integration/Delivery/Deployment) eine enorme Erleichterung. Ein solcher Ansatz ist für ein BMS z.B. bei weitem nicht so einfach umsetzbar. Durch die Verteilung der Funktionalitäten entsprechend der Updatehäufigkeit auch entsprechend allokiert werden. Für Funktionalitäten, die noch schneller angepasst werden müssen, empfiehlt sich die Umlagerung in die Cloud-Umgebung.

2.1.4.3 Virtualisierung von Fahrzeugen

Die Drei-Ebenen-TRANSACT-Architektur bedingt eine abstrakte Trennung:

- **Datenerzeugung** durch das Fahrzeug bzw. BMS (Device).
- **Datenakquise und Übertragung** durch das Gateway (Edge).
- **Datenauswertung** in der Cloud.

Die Abhängigkeit erfolgt ebenfalls dieser Reihenfolge. Es ist somit klar, dass die Erzeugung und Bereitstellung von Fahrzeugdaten essenziell für die darauffolgenden Schritte Datenakquise, Übertragung und Auswertung sind. Jedoch ist dies in der Realität sehr umständlich, da hierfür jedes Mal ein Testfahrer mit dem Testfahrzeug im Straßenbetrieb unterwegs sein muss. Dies bedingt einen enormen Aufwand. AVL hat deswegen das Fahrzeug virtualisiert, um bei Bedarf ausreichend reale Fahrzeugdaten bereit zu haben. Dieses Teilprojekt lief daher unter dem Namen „Virtual Vehicle“.

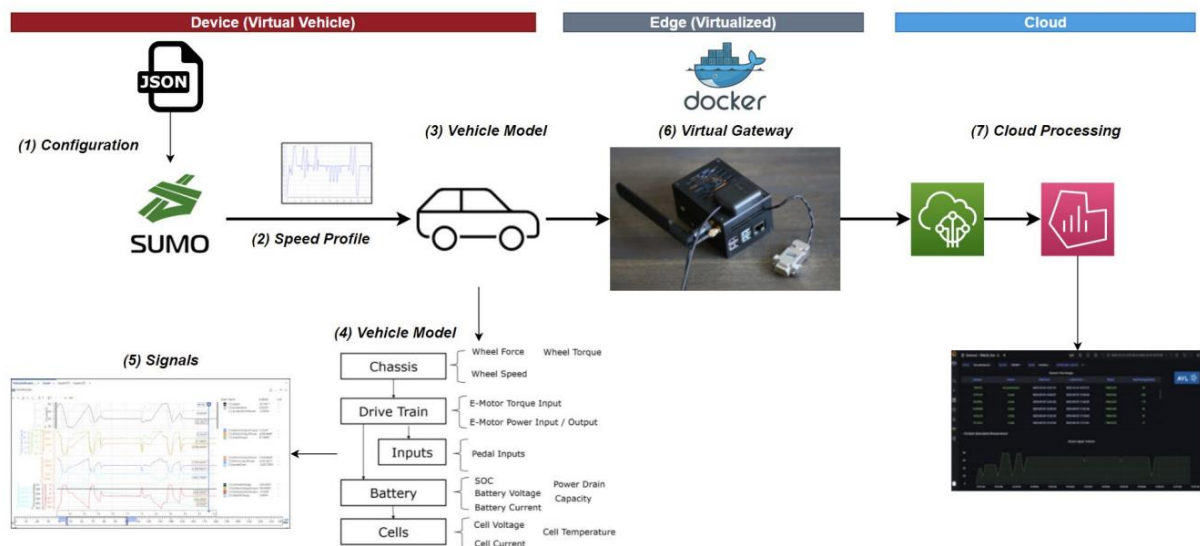


Abbildung 8: Das Virtual Vehicle emuliert ein reales Fahrzeug (Device), während das Gateway (Edge) virtualisiert als Docker-Container läuft, um realistische Daten für das Testen von Cloud-Backend-Lösungen zu erzeugen.

Das Virtual Vehicle ist ein Simulationstool, das mithilfe von Eclipse SUMO (Simulation of Urban Mobility) und einem Fahrzeugmodell Simulationsdaten generiert (siehe Abbildung 8). Zunächst werden Konfigurationen in einer JSON-Datei gespeichert (1). Diese Datei enthält Details zu den Szenarien, der Anzahl und Art der Fahrzeuge sowie dem Fahrverhalten. Auf Grundlage dieser Konfiguration wird ein Szenario in Eclipse SUMO erstellt. Mithilfe einer grafischen Benutzeroberfläche (GUI) und OpenStreetMaps (siehe Abbildung 9) kann die Region ausgewählt werden, in der die Simulation durchgeführt werden soll.

Als Ausgabe werden lediglich ein Geschwindigkeitsprofil und Positionsdaten generiert (2), die anschließend vom Fahrzeugmodell verarbeitet werden. Das Fahrzeugmodell (3) emuliert ein reales Fahrzeug und enthält dementsprechend die gleichen Subsysteme wie ein echtes Fahrzeug (Fahrgestell, Antriebsstrang, Batterie, Batteriezellen usw.) (4). Die Subsysteme sind mit Matlab/Simulink entworfen und anschließend mit Python implementiert. Dabei handelt es sich um gekoppelte physikalische Modelle, die die gleichen Signale generieren, wie sie auch von einem realen Fahrzeug bereitgestellt werden (5).

Mit Hilfe einer DBC-Datei (Data Base CAN) werden die Signale in hex-basierte Signale kodiert und in CAN-Frames verpackt. An diesem Punkt entspricht das Datenformat dem, was auf einem CAN-Bus in einem Fahrzeug vorzufinden ist. Dies ist auch die Schnittstelle, an die im realen Fahrzeug das Gateway angeschlossen ist. In diesem Szenario werden die Daten jedoch nicht an einen physischen CAN-Bus geschrieben und wieder ausgelesen, sondern direkt an das virtualisierte Gateway weitergeleitet (6). Dabei wird dieselbe Softwarearchitektur wie bei der realen Hardware verwendet.

Die Gateway-Software stellt eine Verbindung zum Cloud-Endpunkt her, indem sie denselben Authentifizierungsprozess durchläuft. In der Cloud wird die reguläre Datenverarbeitungs pipeline gestartet, um die CAN-Pakete erneut zu dekodieren, die Signale zu speichern, zu visualisieren und Analysen durchzuführen (7).

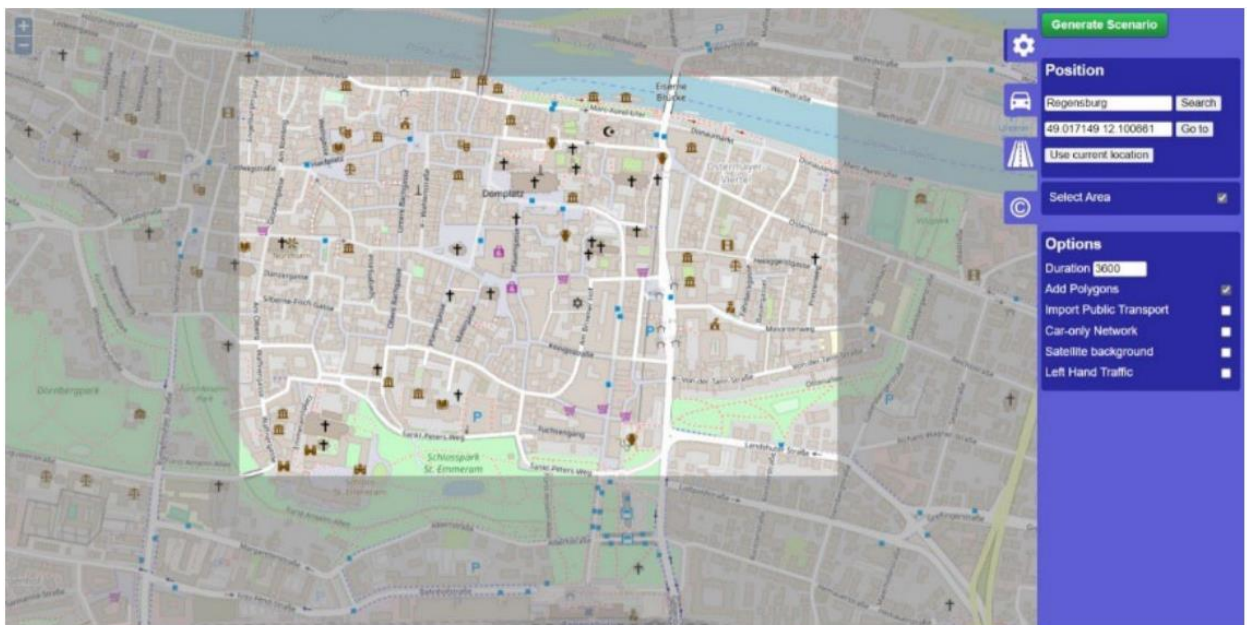


Abbildung 9: Der Open Street Maps Web Wizard bietet eine Schnittstelle zur Auswahl des gewünschten Gebiets und zur Durchführung der Simulation.

Dieses Tool war unter anderem äußerst hilfreich für das Testen des Algorithmus für die Berechnung der Zellwiderstände. Da das Virtuelle Fahrzeugmodell eine virtuelle Replikation eines echten Fahrzeuges ist, werden dort auch physikalische Parameter hinterlegt, z.B. Widerstandswerte für jede Zelle im Subsystem Batterie. Somit gibt es einen klaren Referenzwert, welcher dann wiederum mit den Ergebnissen des Algorithmus in der Cloud verglichen werden kann.

2.1.5 AP5: Integration, Demonstratoren und Validierung

Der Schwerpunkt des Projekts liegt in der Umsetzung der TRANSACT-Architektur in einem Demonstrator.

Das Testfahrzeug ist ein ehemaliges Mercedes-Benz Coupé mit Verbrennungsmotor, das im Rahmen anderer Projekte (nicht TRANSACT) in ein Batterieelektrisches Fahrzeug (BEV) umgewandelt wurde. Alle Kernkomponenten wurden von AVL hergestellt: E-Achse, Hochvoltbatteriepaket, Wechselrichter und das Batteriemanagementsystem. Abbildung 10 zeigt das Testfahrzeug.



Abbildung 10: BEV Testfahrzeug "E-Coupe".



Abbildung 11: AVL's Batteriemanagementsystem.

Im Use Case 3 wird das Device durch das Batteriemanagementsystem (Abbildung 11) repräsentiert, das ISO 26262-konform ist. Die sicherheitskritischen Steuerfunktionen werden nicht ausgelagert, da sie äußerst zeitkritisch sind. Ziel dieses Anwendungsfalls ist es, neue Funktionen zu erforschen, die durch die Erweiterung des Systems auf Edge- und Cloud-Technologien ermöglicht werden.

Für die Datenübertragung vom Fahrzeug in die Cloud wurden Gateways entwickelt (s. Abbildung 12).



Abbildung 12: AVL's LTE Gateway "BMcB"

Im Verlauf dieses Projekts wurde deutlich, dass das entwickelte Gateway auch für andere Anwendungen im Automobilbereich vorteilhaft ist, z. B. für Ladestationen, aber auch in anderen

Bereichen wie Smart-City-Anwendungen. Das LTE-Gateway ist eines der wichtigsten Ergebnisse dieses Projekts für AVL. Ursprünglich war geplant, ein handelsübliches Gateway zu verwenden. Allerdings sind solche Gateways in der Regel geschlossene Systeme, bei denen keine Anpassung ohne Mitwirkung des Anbieters möglich ist, was mit immensen Kosten verbunden ist.

Für dieses und zukünftige Projekte wurde ein Gateway mit vollem Zugriff benötigt, das die Integration der erforderlichen Hardware- und Softwarekomponenten ermöglicht, die sich je nach Projekt ändern können. Die Grundlage des Gateways bildet ein Raspberry Pi 4, ausgestattet mit einem CAN-Modul, einem LTE-Shield, einer Echtzeituhr und einem Batteriepaket mit Stromregler, um ein kontrolliertes Herunterfahren bei Stromausfall (z.B. Ausschalten des Fahrzeugs) zu gewährleisten.

Die entwickelten Gateways verfügen lediglich über einen einzigen CAN-Eingang, während das Fahrzeug mehrere CAN-Busse besitzt. Daher wurde ein CAN-Router von PEAK Systems installiert und konfiguriert, um die Signale von verschiedenen Bussen zu einem einzigen neuen Bus zusammenzuführen. Das LTE-Gateway ist dann mit dem zusammengeführten CAN-Bus verbunden.

Für das Verarbeiten und Visualisieren der Daten in der Cloud sind ein Backend und ein Frontend notwendig. Zuerst setzte AVL auf Microsoft Azure, jedoch überzeugten die Fähigkeiten von AWS deutlich. Für die erste Umsetzung der Visualisierung wurde ein Grafana-Dashbaord verwendet. Das Backend empfängt die Daten und werden dort verarbeitet. Unter anderem wurde auch ein Algorithmus implementiert, welcher aus den verfügbaren Messdaten die Widerstände der einzelnen Zellen berechnet, welcher ein Maß für die Degradation bzw. Gesamtzustand der Zelle ist. Abbildung 13 zeigt die Ergebnisse aus einer Testfahrt auf dem Dashboard.



Abbildung 13: Berechnung der Zellwiderstände des E-Coupes.

Es ist ersichtlich, dass es eine Zelle (Cell 035) gibt, die ein markant auffällig Verhalten zeigt. Es wurden auch von verschiedenen Testfahrern wiederholt Auffälligkeiten des Testfahrzeugs gemeldet. Zusammen mit der Information aus den Messungen wurde beschlossen, die Batterie des Fahrzeugs zu entfernen und genauer zu untersuchen (s. Abbildung 14). Wie sich zeigte, war tatsächlich die identifizierte Zelle 035 in einem kritischen Zustand (s. Abbildung 15).

Somit konnte gezeigt werden, dass die Erweiterung des isolierten Systems zu einem verteilten System wichtige erweiterte Möglichkeiten bietet Funktionen zu integrieren, die auf einem reinem isolierten BMS nicht umsetzbar sind, da diese Funktionen einerseits die Speicherung von vielen Daten benötigen und gleichzeitig darauf beruhen, schnell angepasst werden zu können.



Abbildung 14: Ausgebaute Antriebsbatterie des E-Coupes.




Abbildung 15: Angekohlte Elektrode der Zelle 035.

Ab diesem Zeitpunkt stand das E-Coupe Testfahrzeug nicht mehr zur Verfügung und wir mussten auf andere Fahrzeuge ausweichen. Jedoch ging dies immer mit Einschränkungen einher, da in den anderen Fahrzeugen nicht das AVL BMS verbaut war. Daher wurden die weiteren Entwicklungen primär gegen das Virtual Vehicle (s. 2.1.4.3 Virtualisierung von Fahrzeugen) entwickelt.

Da das Grafana-Dashboard schnell an seine Grenzen stieß, war es notwendig auch das Frontend komplett neu zu entwickeln. Abbildung 16 und Abbildung 17 zeigen die Benutzersicht der Lösung. Zu sehen sind eine Übersicht über die Fahrzeugflotte, sowie die gesammelten Daten eines Fahrzeugs über verschiedene Fahrten hinweg.

Ferner wurde im Laufe des Projekts offensichtlich, wie mächtig und gleichzeitig portable die Gesamtarchitektur ist. D.h. die Architektur lässt sich auch auf andere Anwendungsfälle ausweiten. Wie in Abbildung 16 links oben zu sehen ist, wurde die AVL Lösung „DECL“ genannt, was für „Device-Edge-Cloud“ steht – jene Kernarchitektur die in TRANSACT entwickelt wurde. Details dazu unter Abschnitt „2.3 Verwertbarkeit der Ergebnisse“.

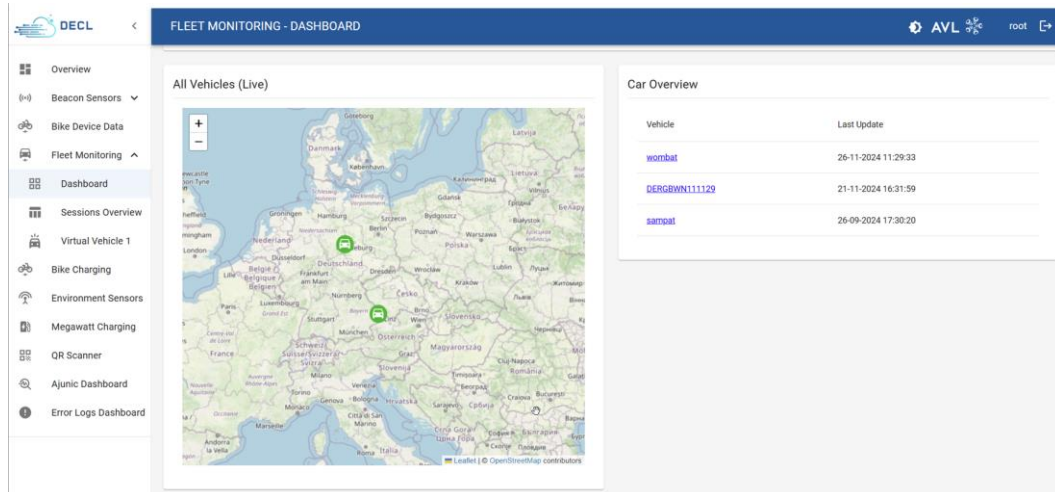
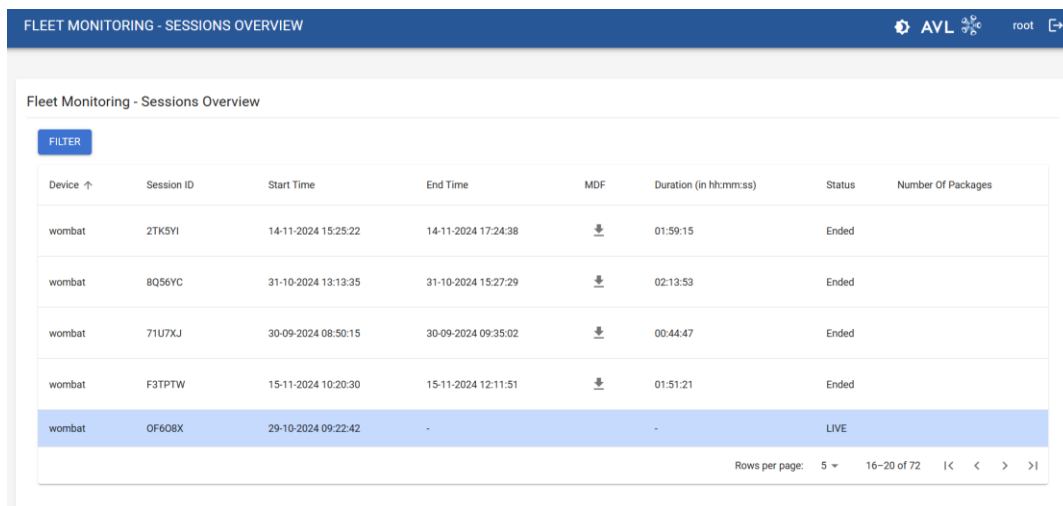


Abbildung 16: Übersicht über Fahrzeugflotte.



Device	Session ID	Start Time	End Time	MDF	Duration (in hh:mm:ss)	Status	Number Of Packages
wombat	2TK5YI	14-11-2024 15:25:22	14-11-2024 17:24:38		01:59:15	Ended	
wombat	8Q56YC	31-10-2024 13:13:35	31-10-2024 15:27:29		02:13:53	Ended	
wombat	71U7XJ	30-09-2024 08:50:15	30-09-2024 09:35:02		00:44:47	Ended	
wombat	F3TPTW	15-11-2024 10:20:30	15-11-2024 12:11:51		01:51:21	Ended	
wombat	0F608X	29-10-2024 09:22:42	-	-	-	LIVE	

Rows per page: 5 | 16-20 of 72 | < > >>

Abbildung 17: Auflistung der einzelnen Fahrten eines BEVs.

Neben den eigenen Lösungen wurden auch viele Beiträge der Partner integriert. Abbildung 18 zeigt wie alle Komponenten zusammenarbeiten um die vollständigen Demonstrator zu realisieren, wie er auch funktionsfähig und live beim finale Reviewmeeting in Best/Eindhoven vorgeführt wurde.

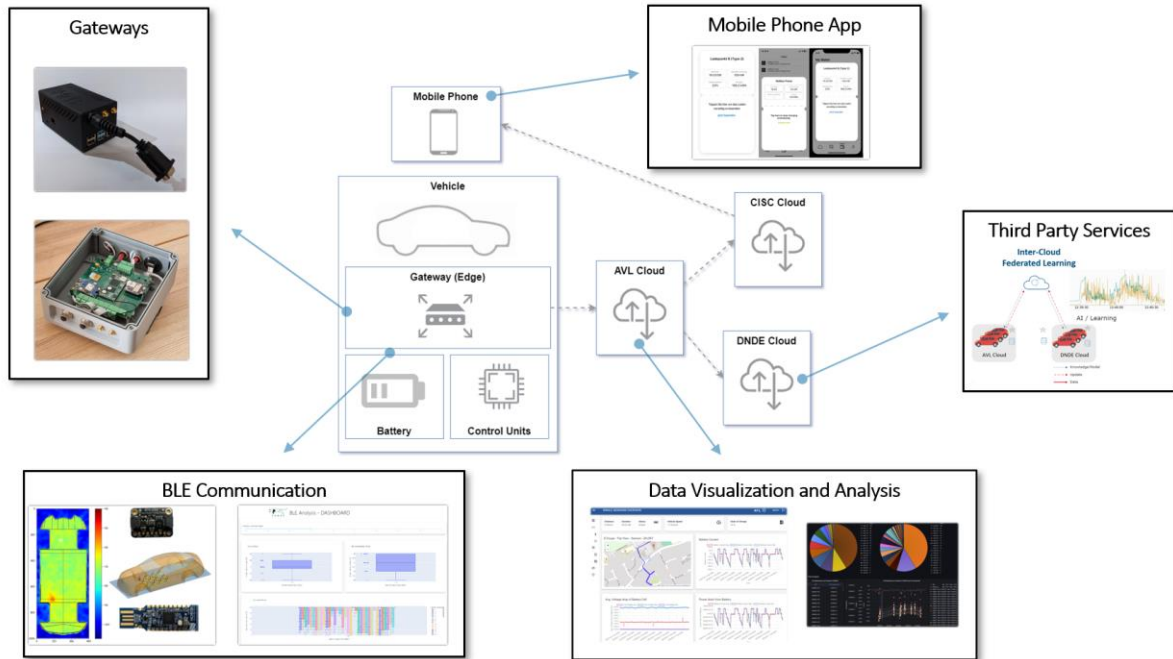


Abbildung 18: Vollständig integrierter Demonstrator.

Die Aufgabe der Gateways wurde bereits erklärt. Das Fahrzeugsystem wurde um BLE Sensoren erweitert und können Messdaten an die Gateways weiterleiten. Dies soll in Zukunft die Kommunikation zwischen den einzelnen Batteriemodulen mit der Batteriekontrolleinheit ermöglichen und dabei auf das kostenintensive verkabeln beim Zusammenbau der Batterie zu verzichten. Das setzt jedoch eine verlässliche Kommunikation voraus. Hierfür wurden intensive Simulationen in einer Kooperation zwischen TUG, IESE und GUT durchgeführt. Die Integration des BLE Sensoren erfolgte exemplarisch (s. Abbildung 19).




Abbildung 19: Integration der BLE Sensoren und Empfängermodul mit dem Gateway.

Die Daten in der Cloud wurden selektiv einerseits an DNDE weitergegeben, wo die Daten genutzt wurden um eine KI zu trainieren. Hierbei wurde auch ein Federated Learning Ansatz verwendet um die erzeugten Daten durch Testfahrzeug und öffentlich zugänglichen Daten zu kombinieren.

Andererseits wurden auch bestimmte Daten an CISC weitergeleitet, um Fahrzeuginformationen und Warnungen über eine Mobilphone App dem Fahrer zu Verfügung zu stellen (s. Abbildung 20).




Abbildung 20: Mobilphone App zur Kommunikation mit dem Fahrer.

Die gesamte Livedemonstration war ein sehr großer Erfolg für alle beteiligten Partner. Die Gutachter des Projekts beim finalen Reviewmeeting hatten die Leistung auch im vollen Umfang anerkannt und gelobt. Es ist auch besonders hervorzuheben, dass im Laufe des Projekts auch eine Validierung des Systems bezüglich Verbesserung der Sicherheit möglich war, indem eine defekte Batteriezelle identifiziert werden konnte.

2.1.6 AP6: Management, Community-Building und Verwertung

AVL hat an sämtlichen Grand Assembly Meetings und Reviewmeetings teilgenommen.

Weitere Ergebnisse in diesem Arbeitspaket finden sich unter „2.3 Verwertbarkeit der Ergebnisse“ und „2.5 Veröffentlichungen“.

2.2 Bezug auf zahlenmäßigen Nachweis

Die Personenaufwände sind aus den dargestellten Ergebnissen ersichtlich.

Materialaufwände entstanden primär durch die Entwicklung der Gateways und der Integration des Demonstrators.

Reisekosten entstanden durch die Teilnahme hat an sämtlichen Grand Assembly Meetings und Reviewmeetings.

2.3 Verwertbarkeit der Ergebnisse



AVL hat bereits kurze Zeit nach Abschluss des Projekts die entwickelte „DECL“ Plattform weiterentwickelt und bereits auf weitere Anwendungsfälle ausgedehnt. Darüber hinaus konnten auch schon Kundenprojekte gewonnen werden, welche durch die Plattform schnell und kostengünstig realisiert werden können. Dadurch ist AVL in diesem Sektor konkurrenzfähig. Aktuell entwickelt AVL die Plattform immer noch weiter und vermarktet diese aktiv.

2.4 Fortschritte durch Dritte

Fortschritte durch Dritte sind hier nicht bekannt, oder haben keinen Einfluss auf das hier beschriebene Unterfangen.

2.5 Veröffentlichungen

2022

- Masterarbeit von Annalena Belnarsch: „Development of a Federated Learning Based Framework for Lifetime Prediction of Li-Ion Batteries,“
- SIMVEC Konferenz, Paper ist über DOI 10.51202/9783181024072-103 auffindbar.

2023

- YouTube Video zum Thema Federated Learning und Vorhersage der Batterielebensdauer (https://www.youtube.com/watch?v=QMqYvJoD_HY)
-
- TRANSACT Blog Post (<https://transact-ecsel.eu/2023/04/distributing-battery-management-of-electric-vehicles-over-the-cloud-to-edge-continuum/>)
- AVL Interner Innovation Day, Ausstellung von BMcB mit Frontend
- Paper zusammen mit TU München (<https://doi.org/10.1016/j.etrans.2023.100294>)
- AVL Methodik Symposium in Wiesbaden: Präsentation Teile der Arbeiten aus TRANSACT
- AVL Press Release: <https://www.avl.com/en/press/press-release/avl-rd-prediction-vehicle-battery-lifetime-thanks-ai>
- Interview im österreichischen Radio aufgrund des Press Release
- Automotvie World: <https://www.automotiveworld.com/news-releases/avl-in-rd-prediction-of-vehicle-battery-lifetime-thanks-to-ai-federated-learning/>
- Masterarbeit von Lucas Tzyy Lip Lee: „Development of a vehicle fleet simulation model for fleet monitoring solutions“

2.6 Quellen

Bibliography

H. Brendan McMahan, E. M. (2016). Communication-Efficient Learning of Deep Networks from Decentralized Data. doi:<https://doi.org/10.48550/arXiv.1602.05629>



- IREB. (kein Datum). *CPRE Foundation Level - Handbook*. Von <https://www.ireb.org/de/downloads/tag:foundation-level#top> abgerufen
- Kröger, T. B. (2023). Collaborative training of deep neural networks for the lithium-ion battery aging prediction with federated learning. *ETransportation*, 18, 100294. *ETransportation*, 18, 100294. doi:<https://doi.org/10.1016/j.etrans.2023.100294>
- Li, W., Sengupta, N., Dechent, P., Howey, D., Annaswamy, A., & Sauer, D. U. (2021). One-shot battery degradation trajectory prediction with deep learning. *Journal of Power Sources*, 506, 230024.
- Severson, K. A., Attia, P. M., Jin, N., Perkins, N., Jiang, B., Yang, Z., . . . Braatz, R. D. (2019). Data-driven prediction of battery cycle life before capacity degradation. *Nature Energy*, 4(5), 383-391.