




Individueller Schlussbericht

(Struktur abgeleitet aus gemeinsamen Schlussbericht des Gesamtkonsortiums)

EEmotion Projekt

Zuwendungsempfänger / Förderkennzeichen (FKZ)	
Infineon Technologies AG (kurz IFAG) <u>Konsortialführung</u> Am Campeon 1-15 85579 Neubiberg FKZ: 19A21038A	
Vorhabenbezeichnung: Verbundprojekt: „Embedded Excellence - Fahrdynamik mit KI“	
Laufzeit des Vorhabens: 01.09.2020 bis 31.08.2024	
Berichtsdatum 25.02.2025	
Vorgelegt durch: Minira Prosser Projektleitung IFAG ATV MC TM PEW Technical Marketing Automotive Microcontrollers	

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages



Inhaltsverzeichnis

EEmotion.....	0
1 Kurze Darstellung der Aufgabenstellung, der Voraussetzungen, der Planung und des Ablaufs des Teilvorhabens	3
1.1 Aufgabenstellung	3
1.1.1 Problembeschreibung	3
KI zur Aktuatorensteuerung.....	3
Grundfunktionalität für „Intelligentes Fahren“.....	4
Was ist künstliche Intelligenz?.....	4
Dezentrale KI für autonome, eigensichere Fahrzeuge	4
Grenzen klassischer Verfahren	5
Freie Bahn für KI-Fahrdynamik-Potenziale	5
1.2 Voraussetzungen, unter denen das Vorhaben durchgeführt wurde	6
1.2.1 Motivation.....	6
1.2.2 Bezug des Vorhabens zu den förderpolitischen Zielen	7
1.3 Planung und Ablauf des Vorhabens	7
1.3.1 Projektkonzept	7
1.3.2 Ablauf des Vorhabens	10
1.4 Stand der Technik, an den angeknüpft wurde	11
1.5 Zusammenarbeit mit anderen Stellen.....	12
2 Eingehende Darstellung der erzielten Ergebnisse und des voraussichtlichen Nutzens..	12
2.1 Überblick Gesamtvorhaben	12
2.2 Teilvorhaben Infineon Technologies AG.....	15
2.2.1 AP1 Applikationsanforderungen, Spezifikation KI-Fahrdynamik	15
2.2.2 AP2 Systemarchitektur KI-Fahrdynamik	17
2.2.3 AP3 KI-HW und Applikationsfunktionen - AD/ADAS	24
2.2.4 AP4 KI-SW – Verfahren, Methodik, eingebettete Algorithmen	32
2.2.5 AP5 KI-Kommunikation – secure und funktional-sicher	36
2.2.6 AP6 Simulation, Data Handling, KI-Training	40
2.2.7 AP7 HW/SW-Codesign, Werkzeugumgebung, Integration in ECU, HIL-Test...43	
2.2.8 AP8 Demonstration, Test und Evaluierung KI-Fahrdynamik-System Definition der Demo-Szenarien & Konzept zum KPI-Nachweis	45
2.2.9 Zusammenfassung des Teilvorhabens	47
3 Verwertbarkeit des Ergebnisses und der Erfahrungen.....	48
3.1 Infineon Technologies AG	49



Projekt: **EEmotion** / Individueller Schlussbericht

4	Während der Durchführung des Vorhabens dem Zuwendungsempfänger bekannt gewordenen Fortschritts auf diesem Gebiet bei anderen Stellen	50
5	Erfolgte oder geplante Veröffentlichungen der Ergebnisse	50
5.1	Veröffentlichungen	50
5.2	Vorträge	51
5.3	Demonstratoren	51
5.4	Masterarbeiten	51
6	Abbildungsverzeichnis	55

1 Kurze Darstellung der Aufgabenstellung, der Voraussetzungen, der Planung und des Ablaufs des Teilvorhabens

1.1 Aufgabenstellung

1.1.1 Problembeschreibung

Auch wenn die Transformation des Automobils in einen zukunftsfähigen Allrounder Fahrt aufnimmt, einige zentrale Systemfragen bleiben unbeantwortet. So mögen leistungsfähige Server-Computer über Deep Learning Fahrzeuge und Assistenzsysteme zu immer besserer Performance trainieren. Was fehlt, ist, diesen Vorgang ins Fahrzeug selbst zu verlegen.

Nur wenn die komplexe Fahrdynamik über Embedded Systeme vor Ort und unabhängig von der Cloud gesteuert wird, können Autos wirklich autonom und eigensicher agieren. Schon die Abhängigkeit von externer Infrastruktur birgt über deren potenzielle Störanfälligkeit erhebliche Risiken.

Die Herausforderung liegt in der optimalen Nutzung von KI-Systemen an Bord für die Umsetzung von AD/ADAS-Funktionen wie Adaptive Cruise Control (ACC) und Auto-Pilot-Funktionen. Allein die begrenzt verfügbaren Kapazitäten wie Energie, Rechenleistung oder Datenmenge erfordern neue Ansätze, um derartige KI-Funktionen in Echtzeit unabhängig, zuverlässig und sicher zu realisieren. Die AD/ADAS Funktionen, energie-effizientes ACC und Auto-Pilot werden im Folgenden in der Vorhabensbeschreibung mit „KI-AD/ADAS Fahrdynamik-System“ bezeichnet.

EEmotion zielte auf KI-optimierte AD/ADAS-Funktionen mit Fokus auf Fahrdynamik direkt im Auto unter Virtualisierung von Hardwarekomponenten ab. Virtuelle Sensoren etwa, deren nichtlineare Optimierung bessere Ergebnisse bringt als zusätzliche reale. Es geht also um inkrementelles Lernen, um Prädiktion und Entscheidung auf Embedded Systemen.

Somit lautete das Hauptziel von EEmotion: ein Cloud-unabhängiges, echtzeitfähiges embedded KI-Fahrdynamiksystem in der dreijährigen Projektlaufzeit zu implementieren und evaluieren. Dies begann mit dem Profil des Konsortiums, das aus ZF Friedrichshafen, b-plus, samoconsult, RWTH Aachen und Universität zu Lübeck bestand und das von Infineon koordiniert wurde. Die Projektstruktur von EEmotion gliederte sich in neun korrelierte Arbeitspakete (AP). AP2 „Systemarchitektur des KI-Fahrdynamiksystems“ kam die übergreifende Funktion zu, die Arbeit über die Projektebenen Anforderung, Komponentenebene und System iterativ zu steuern.

KI zur Aktuatorensteuerung

Kernbereich des Projekts war die Regelung der Basisfunktionalität eines Fahrzeugs. Es ging um die Anwendbarkeit von KI-Verfahren für die Steuerung sämtlicher Aktuatoren wie Antriebstrang, Bremsen, Stoßdämpfer oder Federung - kurz: die Fahrdynamik-Steuerung. Die Fahrdynamik umfasste die Steuerung der Längsdynamik (Antrieb, Bremsen, Fahrwiderstand, Verbrauch etc.), der Querdynamik (Lenken, Kurven, Kippsicherheit etc.) sowie der Vertikaldynamik (Komfort, Ladegutbeanspruchung, Fahrbahnbeanspruchung etc.). Ziel war es, die klassische Regelungstechnik, die nach derzeitigem Stand der Technik an ihre Grenzen stößt, durch geeignete KI-Verfahren zu ergänzen, zu optimieren oder zu ersetzen.

Grundfunktionalität für „Intelligentes Fahren“

Letztlich wird damit die neue Grundfunktionalität bereitgestellt, auf der künftige Applikationen für automatisiertes Fahren, ADAS-Systeme oder energieeffiziente Betriebsstrategien aufbauen. Damit adressierte EEmotion im Förderaufruf vorwiegend die Schwerpunkte *A) KI-Verfahren für automatisierte Fahrfunktionen* und *B) KI-Verfahren für einen optimierten Betriebszustand und eine energieeffiziente Betriebsstrategie*. Die Aufgaben spiegelten sich im Profil des Konsortiums. Das Zusammenspiel von Automotive-Systemanbietern und KI-Experten ermöglichte eine OEM-offene Erforschung der KI-Fahrdynamik und eröffnete eine große Anwendungsbreite, mit der sich deutsche Zulieferer und KMUs eine führende Position als Wegbereiter für „Intelligentes Fahren“ im internationalen Wettbewerb sichern können. Künftige Fahrzeuge erfordern eine Mischung aus Agilität, Sicherheit und Komfort auf bislang unbekanntem Niveau.

Was ist künstliche Intelligenz?

Da der Begriff Künstliche Intelligenz (KI) mittlerweile vielfältig verwendet und uneinheitlich definiert wird, sei die Wortkombination „KI-System“ im Sinne von EEmotion für den Anwendungsfall Fahrdynamikregelung mit KI als Embedded-Automotive-KI-System konkretisiert. Ein System also, das in ein Fahrzeug eingebettet ist und in begrenztem Umfang eigenständig neue Erkenntnisse aus seiner Umgebung gewinnt, bewertet und in einem vorgegebenen Handlungsraum in Echtzeit adaptierte nachvollziehbare, plausible Entscheidungen für den weiteren Fahrverlauf bzw. Betriebszustand trifft. Umgesetzt wird das KI-System mittels Machine-Learning-Algorithmen und Methoden aus dem Bereich der schwachen KI, d.h. Fähigkeiten des Systems bezüglich Prädiktion, Bewertung und Merkmal-Extraktion werden mit Hilfe von mathematischen Algorithmen wie künstliche neuronale Netzwerke (KNN) simuliert.

Dezentrale KI für autonome, eigensichere Fahrzeuge

Eine über KI-Verfahren optimierte Leistung und Sicherheit der Fahrdynamik bei gleichzeitiger Unabhängigkeit von potenziell störanfälligen Cloud-Verbindungen ist zugleich Grundlage für eine höhere Nutzerakzeptanz. Die im Projekt beabsichtigte Entwicklung entsprechender Rechenplattformen zielte mit minimierten Latenzen auf ein autonomes und eigensicheres Funktionieren von Fahrzeugen ab. Signifikante Fortschritte waren abgesehen von Leistung und Sicherheit bei Energieeffizienz sowie Ressourcenschonung zu erwarten. Erzielt wurden sie durch KI-basierte Abstimmungen von Regler und Funktionen, schnelle Entscheidungen auf dem Steuergerät, eine intelligente Ansteuerung der Aktuatoren sowie KI-Beschleuniger-Hardware für Echtzeit-Applikationen. Ein KI-System lernt aus Beispielen (Trainingsdaten) und kann nach Abschluss der Trainingsphase verallgemeinern. Hierfür wird basierend auf mathematischen Algorithmen ein statistisches Modell aufgebaut, das seinerseits in der Lage ist die angelernten Muster und Gesetzmäßigkeiten auf unbekannte Daten anzuwenden. Die entsprechenden Algorithmen liefern mathematisch geschlossene Lösungen aber aus Sicht der Datenverarbeitung sind diese nicht zu einhundert Prozent vorhersehbar. Um die geforderte Eigensicherheit der Systemfunktionalität erreichen zu können, wurde besonderes Augenmerk auf die Vorhersehbarkeit der entsprechenden mathematischen Algorithmen gelegt.



Grenzen klassischer Verfahren

Mit Blick auf die Anforderungen beim assistierten bzw. autonomen Fahren sind Planung und Umsetzung der von der zentralen Perzeption-Funktionseinheit vorgegebenen Trajektorien wesentlich für das Fahrwerkregelsystem. Bei der Entwicklung und Anwendung von Funktionen zur Trajektorien-Regelung waren sämtliche Fahrsituationen zu berücksichtigen – vom Stadtverkehr über die Autobahn bis zum unwegsamen Gelände, und das bei jedem Wetter. Qualität und Leistungsprofil mussten dabei angesichts der zahlreichen Einflussfaktoren stets gleichbleiben.

Eine Herausforderung war, dies für den gesamten Einsatzbereich und die Lebensdauer eines Fahrzeugs zu gewährleisten. Wenn der dafür nötige Aufwand mit der Anzahl der Regelungsparameter und Einflussgrößen exponentiell steigt, kann die Leistungsfähigkeit der Regelungsstruktur mit klassischen Parametrierungsverfahren nicht ausgenutzt werden. Reinforcement Learning indes bietet das nötige Potenzial, was es letztlich ermöglicht, auch komplexe Funktionen dem Massenmarkt zur Verfügung zu stellen.

Zentrale Aufgabe des Fahrwerkregelsystems ist die Planung und Umsetzung der von der zentralen Perzeption Funktionseinheit vorgegebenen groben Trajektorien. Je genauer dies erfolgt, desto besser die gesamte Performance der Fahrdynamik. Fahrwerkregelungen auf dem Stand der Technik allerdings sind in der Hinsicht limitiert; sie beruhen auf linearen Regelungskonzepten, deren Parameter anhand von heuristischen Methoden an die zugehörige Fahrsituation angepasst werden.

Freie Bahn für KI-Fahrdynamik-Potenziale

Zur Beseitigung dieser Einschränkung entwickelten die EEmotion-Projektpartner ein Regelsystem, das auf Machine-Learning-Algorithmen basiert. Mit den Algorithmen und den zugehörigen Trainingsmethoden wie Reinforcement Learning ließ sich der mit jeder Fahrsituation einhergehende kinematische Fahrzeugzustand vorausberechnen. Die Ergebnisse wiederum erlaubten es, die linearen und nicht linearen Regelalgorithmen optimal zur Fahrsituation zu parametrisieren. Alternativ wurde untersucht, ob die beschriebenen Regelkonzepte vollständig durch Machine Learning basierende Regelkonzepte ersetzt werden können - all dies unter den Aspekten Echtzeitfähigkeit und funktionale Sicherheit. Die entsprechenden Algorithmen sollten auf dem Embedded System im Fahrzeug selbst ausgeführt und trainiert werden, was die Entwicklung von Edge Machine Learning Methoden erforderte.

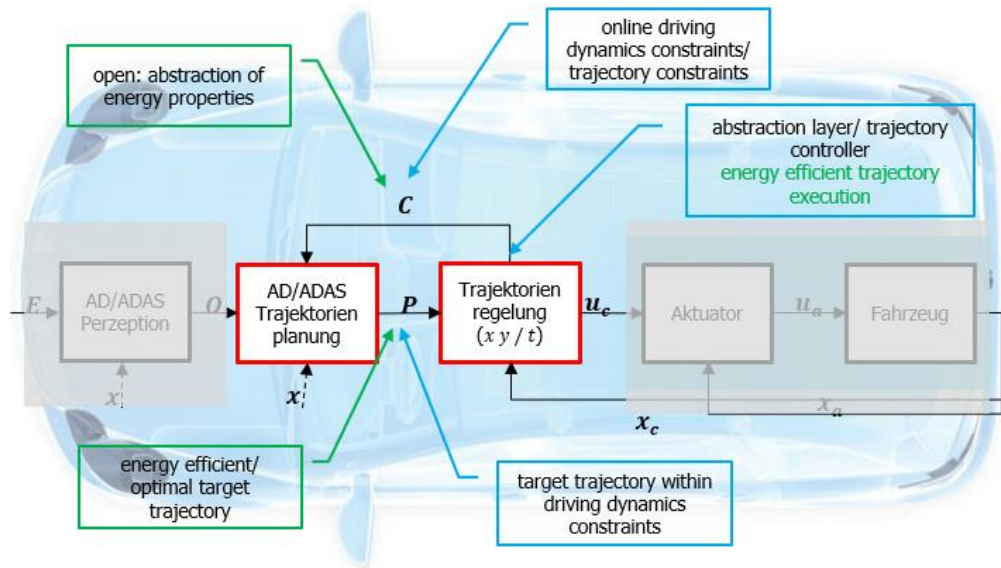


Abbildung 1: KI-basierte energieeffiziente Trajektorienplanung und -regelung

1.2 Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

1.2.1 Motivation

Forschungsleitende Hypothese: Die Einführung autonomer Fahrfunktionen erfordert den Übergang von klassischen regelbasierten Systemen zu KI-Systemen. Eingebettete KI-basierte Systeme im Automobil sind insofern eine Innovation - umso mehr, wenn sie im Normalbetrieb „Standalone“, ohne permanente Cloud-Verbindung arbeiten und zudem inkrementell lernen.

Ausgangssituation: Grundlegende KI-Verfahren werden seit einigen Jahren etwa für Big-Data-Anwendungen (TRL7+) erforscht und produktiv eingesetzt. Die Herausforderung in EEmotion war eine technisch und wirtschaftlich optimale Portierung ins Fahrzeug mit allen gegebenen Limitierungen: Energie, Rechenleistung, Kommunikationsbandbreite, Bauraum, Echtzeit, Funktions- und Sicherheitsanforderungen. Zu erarbeiten waren dabei sowohl die HW-Voraussetzungen, wie für KI geeignete Rechen- und Speicherressourcen, z.B. hinreichend große CNN-Netze, darauf angepasste Algorithmen, und auch geeignete Kommunikationswege.

Lösungsansatz: Das größte Potenzial für effiziente KI-Fahrdynamiklösungen im Fahrzeug versprach eine über mehrere Steuergeräte und Fahrzeugzonen verteilte echtzeitfähige und funktional sichere embedded KI-Architektur. Auch dies war eine Innovation. Erforscht und demonstriert wurde eine derartige KI-Systemlösung im HW/SW-Algorithmen-Codesign. Beginnend beim technologischen Reifegrad TRL2-3 wurde im Projektergebnis TRL6 angestrebt. Der Nachweis der Qualifizierbarkeit wurde insbesondere auf die Sicherheit im Verkehr erbracht. Letztlich müssen KI-Systeme für automatisierte Fahrfunktionen nach SAE Level 3 und höher „fail operational“ – agieren und damit ASIL-D qualifiziert sein. Erforscht wurde eine OEM-offene KI-Fahrdynamik für alle.

Auch in den verschiedenen Arbeitspaketen spiegelte das aktuelle Technology Readiness Level (TRL) die zu bearbeitenden Technologien wider und lag bei 2-3 zu Beginn des Projektes. Mit einem angestrebten Level von TRL6 handelte es sich somit bei EEmotion sowohl um eine Technologieentwicklung, als auch um eine Technologiedemonstration. Die grundsätzliche Funktionsfähigkeit der eingesetzten Technologien, wie z. B. der kombinierten Fahrwerksentwicklung und Fahrwerkssimulation wurde unter Beachtung von KI-Aspekten im Projekt nachgewiesen.

Kerninnovationen: Aus der folgenden Tabelle sind die Kerninnovationen des Projekts mit dem Technologiereifegrad am Start und am Ende des Projekts zu entnehmen.

Kerninnovation im Projekt	Stand der Technik zu Projektbeginn (mit Angabe des TRL-Levels)	Angestrebter Innovationshub (mit Angabe des TRL-Levels)
KI-Algorithmus auf automobilen eingebetteten Systemen (Ziel 6,7)	TRL 3:	TRL 6: Fahrzeugdemonstrator
KI-basierte MPC (Model Predictive Control) Ansätze (Ziel 1, 2, 4)	TRL 2	TRL 6: Fahrzeugdemonstrator
Abgesicherte Kommunikation mittels KI (Ziel 10)	TRL 3	TRL 6: Fahrzeugdemonstrator
Simulationsbasiertes Training und Validierung von KI-Algorithmen (Ziel 2, 5, 9, 10)	TRL 4	TRL 5: Machbarkeit für EEmotion-System nachgewiesen

Abbildung 2: Kerninnovationen mit dem Technologiereifegrad am Start und Ende des Projekts

1.2.2 Bezug des Vorhabens zu den förderpolitischen Zielen

Mit Erforschung eines Cloud-unabhängigen, echtzeitfähigen embedded KI-Fahrdynamiksystems, das die klassische Regelung der Aktuatoren im Fahrzeug um die Vorteile der KI erweitert, adressierte EEmotion im Förderaufruf die Schwerpunkte *A) KI-Verfahren für automatisierte Fahrfunktionen* und *B) KI-Verfahren für einen optimierten Betriebszustand und eine energieeffiziente Betriebsstrategie*. Beim Schwerpunkt *A)* konnte EEmotion in das Themengebiet *Optimierte Fahrmanöver durch Kommunikation und Kooperation* eingeordnet werden. Beim Schwerpunkt *B)* konnten Forschungsziele von EEmotion als Teil von *Vorausschauende und intelligente Navigation* ausgelegt werden.

Die Ergebnisse von EEmotion als eines Forschungsprojekts aus dem Förderaufruf „Künstliche Intelligenz als Schlüsseltechnologie für das Fahrzeug der Zukunft“ können als operativer Ausdruck des BMWi-Fachprogramms „Neue Fahrzeug- und Systemtechnologien“ betrachtet werden. Damit trägt das Forschungsvorhaben zur Umsetzung des Aktionsplans *Forschung für Autonomes Fahren* sowie der Strategien *Künstliche Intelligenz* und *Hightech-Strategie der Bundesregierung* bei.

1.3 Planung und Ablauf des Vorhabens

1.3.1 Projektkonzept

EEmotion war genau auf das Hauptziel hin konzipiert: ein Cloud-unabhängiges, echtzeitfähiges embedded KI-Fahrdynamiksystem in der dreijährigen Projektlaufzeit zu implementieren und evaluieren.

Dies begann mit dem Profil des Konsortiums. Die Projektpartner ZF Friedrichshafen, b-plus, samoconsult, RWTH Aachen und Universität zu Lübeck wurden von Infineon koordiniert. Die Projektstruktur gliederte sich in neun korrelierte Arbeitspakete (AP).

Projekt: **EEmotion** / Individueller Schlussbericht

Entsprechend der Theorie des sogenannten „V-Modells“ (Vorgehensmodell oder Wasserfallmodell) von Forschungs- und Entwicklungsprojekten erfüllten AP1 bis AP3 in EEmotion konzeptionelle (und zum Teil implementierende) Funktionen: Systemanforderungen (AP1), Systemarchitektur (AP2) und Konzept (AP3). AP4 und AP5 beinhalteten sowohl konzeptionelle/implementierende, als auch verifizierende und validierende Funktionen: Implementierung der SW und HW sowie Test der Komponenten. AP6 bis AP8 dienten der Aufgabe der Verifizierung und Validierung: Test der Subsystemintegration (AP6), Test der Systemintegration (AP7) und Test des Systems (AP8).

Demzufolge wurden im AP1 „Applikationsanforderungen, Spezifikation KI-Fahrdynamiksystem“ Anforderungen an die Trajektorienplanung und -regelung definiert und das KI-Fahrdynamiksystem wurde spezifiziert. Im AP2 „Systemarchitektur des KI-Fahrdynamiksystems“ wurde die Systemarchitektur des KI-AD/ADAS-Fahrdynamiksystems definiert. AP2 kam außerdem die übergreifende Funktion zu, die Arbeit über die Projektebenen Anforderung, Komponentenebene und System iterativ zu steuern. Im AP3 „KI-HW und Applikationsfunktionen AD/ADAS“ ging es darum, eine stabile und effiziente Trajektorienplanung und -regelung mehrerer Aktuatoren zu entwickeln (Vorder-, Hinterachslenkung, Bremse, E- und/oder Verbrennungsmotor, Dämpfer etc.). Die Planung und Ausführung einer vorgegebenen Trajektorie diente als Basis für AD/ADAS-Systeme, wie beispielsweise das energieoptimale ACC oder der Auto-Pilot. Das KI-basierte Gesamtsystem musste auf vorhandener Hardware integrierbar und sicher ausführbar sein. Im AP4 „KI-SW: Verfahren, Methodik, embedded Algorithmen“ wurden KI-Methoden, die es ermöglichen, auf eingebetteten Systemen im automobilen, sicherheitskritischen Umfeld zu operieren, entwickelt, verbessert und optimiert. AP5 „KI-Kommunikation: secure und funktional-sicher“ fokussierte sich auf die Interaktion der Systemkomponenten und insbesondere deren Überwachung mit KI-Methoden.

Für „AI on the Edge“ basierte Fahrdynamik-Algorithmen im Fahrzeug war eine sichere und verlässliche Kommunikation der einzelnen Aktoren, Sensoren und Steuergeräte ein substanzieller und essenzieller Bestandteil der dezentralen intelligenten Systeme. Im AP6 „Simulation, Data Handling, KI-Training“ wurde das Fahrdynamiksystem hinsichtlich Simulation und KI-Algorithmen für die Anwendungsfälle ACC/ ADAS definiert. Der im AP8 geplante Demonstrator wurde im AP6 auf den Ebenen Applikationsanforderungen, System, Konzept und Implementierung simuliert und damit verifiziert. Der Fokus von AP7 lautete „HW/SW-Codesign, Werkzeugumgebung, Integration in ECU, HIL-Test“. Ausgehend vom Anwendungsszenario "Fahrdynamik" nebst eingesetzter KI-Methoden (AP3/4) erfolgte hier die Ableitung einer dedizierten HW/SW-Partitionierung ausgehend von der ermittelten Basisarchitektur (AP1/2). Hierbei wurden die abzubildenden Algorithmen in geeigneter Weise partitioniert und auf einer entsprechend parametrisierten Hardware abgebildet. Dem AP8 „Demonstration, Test und Evaluierung KI-Fahrdynamiksystem“ kam eine validierende Rolle der KI-basierten Funktionen in einer Fahrzeuganwendung unter realistischen Bedingungen zu. Hier wurden zwei Use Cases – das energie-effiziente ACC und ein Auto-Pilot (KI-AD/ADAS Fahrdynamiksystem) - auf Demonstratorfahrzeugen definiert, realisiert und präsentiert. Ferner wurden MIL- und HIL-Prototypentests und deren Evaluierung spezifiziert und durchgeführt. Das AP9 diente dem Projektmanagement.

Der Projektstruktur-Abbildung ist zu entnehmen, dass Arbeitspakete unterschiedliche Ebenen eines Systems repräsentieren: Anforderungen, Komponente und System.

(ACC - Adaptive Cruise Control
AD – Autonomous Driving
ADAS – Advanced Driver Assistant System)

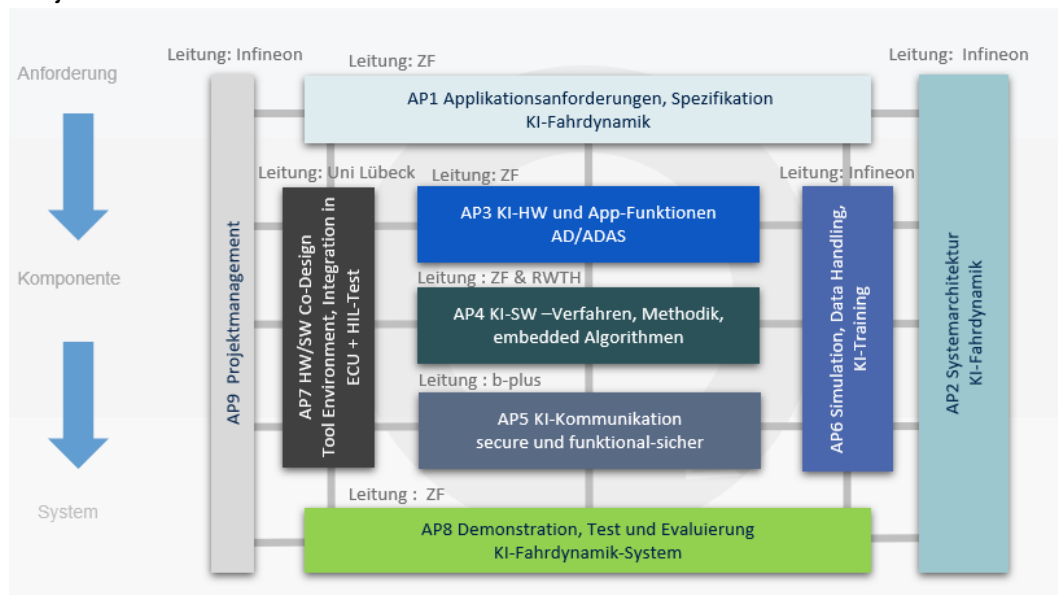


Abbildung 3: Projektstruktur und Arbeitspakete unterschiedlicher Ebenen

Nr.	Meilenstein	Beschreibung	AP	Fällig	Projektphase
M1	Anforderungen an das Konzept der KI-Trajektorienregelung definiert	Systemspezifikation und -architektur der KI-Funktionalität, Software und Funktionaler Sicherheit sowie zugehörige Schnittstellen mit entsprechender Kommunikationsarchitektur sind definiert	Aus AP 1,2	Q4 Jahr 1	Anforderungen
M2	Konzept für KI-Trajektorienregelung definiert und seine Machbarkeit überprüft	<p>Methoden der energieeffizienten und lernenden KI-Trajektorien-Regelung sind definiert</p> <p>KI-Kommunikationsarchitektur zur Anomalieerkennung ist definiert</p> <p>Erste Version KI-Fahrdynamik-Systempartitionierung in HW- und SW-Komponenten ist vorhanden</p> <p>Initiale Version der Regelungs- und KI-Architektur sowie der zugehörigen KI-Komponenten inklusive klassischer Regelung ist definier</p>	Aus AP 2,3,4,5,7	Q2 Jahr 2	Konzept & Machbarkeit

M3	Simulation für KI-Trajektorienregelung implementiert	Simulationsumgebung wurde vorbereitet für Funktions-/ KI-Training	AP 6	Q2 Jahr 2	Implementierung
M4	Konzept für KI-Trajektorienregelung validiert	Finale Version KI-Algorithmen mit Sicherheitsgarantien auf Ziel-HW und Prototype ist implementiert und validiert KI-Kommunikationsarchitektur zur Anomalieerkennung ist implementiert und validiert	Aus AP 4,5,7	Q4 Jahr 3	Validierung
M5	Konzept für KI-Trajektorienregelung demonstriert	Energie-effizientes ACC und Auto-Pilot in Fahrzeug wurde demonstriert	AP 8	Q4 Jahr 3	Demonstration

Abbildung 4: Arbeitspakete und Meilensteine des Projekts

1.3.2 Ablauf des Vorhabens

Zur Entwicklung des definierten Systems zum autonomen Fahren war das Projekt nach einem Jahr Laufzeit auf eine agile Projektmanagement-Methode umgestiegen, mit deren Hilfe es mehrere Forschungs-/Innovationszyklen durchlief. Die erste Phase entsprach den Arbeiten im AP1, mit dem initiale technische Randbedingungen geschaffen wurden. Anschließend wurde im Rahmen des AP2 die Systemarchitektur festgelegt. In AP4 und AP6 wurden ODD und Fahrscenarien definiert und modelliert. Im nächsten Schritt wurden die klassischen Algorithmen zur Trajektorienplanung und -regelung sowie zur Anomalieerkennung definiert, implementiert und ins Testfahrzeug integriert. Die klassischen Ansätze wurden durch KI-Algorithmen erweitert, ergänzt und in die bestehende Testfahrzeuginfrastruktur und -umgebung integriert, um diese zu testen und zu validieren. Durch das Testen wurde das Verbesserungspotenzial der entwickelten Lösung hinsichtlich Robustheit und Sicherheit vom autonomen Fahren überprüft. Anschließend wurde die Lösung generalisiert und durch erweiterte Datensätze weiterentwickelt. Die erforschte Lösung wurde im Testfahrzeug demonstriert.

KI-Algorithmen sind datenorientierte Ansätze. Die kontinuierliche Validierung im Testfahrzeug ermöglichte eine schrittweise Verbesserung der Datenqualität, die für die Generalisierung der KI-Ansätze essentiell notwendig war. Dieser Ansatz des kontinuierlichen Validierens und Testens in Innovationszyklen – über die Arbeitspakete 3 bis 8 hinweg, entlang des V-Modells – konnte nur durch den Umstieg auf die agile Projektmanagement-Methode ermöglicht werden. In Kombination mit der bestehenden Projektplanung in den Arbeitspaketen der VHB ergab sich somit ein hybrider Ansatz, der sich als essentiell für den Projekterfolg herausstellte.

1.4 Stand der Technik, an den angeknüpft wurde

Mit dem Ziel, die klassische Regelungstechnik durch KI-Verfahren nicht nur zu ergänzen und zu optimieren, sondern möglichst zu ersetzen, betrat EEmotion weitgehendes Neuland, in dem es bis dahin noch keine vergleichbaren Ansätze gab. Der bisherige wissenschaftlich-technische Stand bewegte sich allenfalls im Vorfeld, beruhte aber hauptsächlich auf linearen Verfahren.

So hatte es bei der jüngsten rasanten Entwicklung autonomer Fahrfunktionen erhebliche Fortschritte auch im Bereich Trajektorienplanung und -regelung gegeben. Neben klassischen Verfahren wie Pure Pursuit Control und Lookahead Steering wurden auch Ansätze der modellprädiktiven Regelung (Model Predictive Control) intensiv untersucht. Die Vorteile von MPC lagen neben der intuitiven Anwendung in der Möglichkeit der direkten Spezifikation eines Kostenkriteriums, welches unter der Einhaltung gegebener Randbedingungen optimiert wird. Die Praxistauglichkeit wurde in zahlreichen Projekten bewiesen.

Dennoch blieben wichtige Fragen in Bezug auf das Potenzial von MPC offen: Wie kann der Regler sein Verhalten an ein bestimmtes Einsatzszenario anpassen und sich dabei kontinuierlich optimieren? Wie sehen die Schnittstellen zu den anderen Modulen der autonomen Fahrfunktionen aus? Hierzu wurden im Projekt Antworten gesucht. Bei den zu erforschenden Lösungen wurde natürlich auf die Gewährleistung der Reglersicherheit geachtet.

MPC war beispielhaft für ein lineares Modell (Rossiter J., A First Course in Predictive Control, Boca Raton: CRC Press, 2018), das sich bei EEmotion im Bereich der Optimierung durch KI-Verfahren bewegte. Bezüglich der Fahrdynamik waren diese Prädiktions-Konzepte, bei denen Parameter anhand heuristischer Methoden an die zugehörige Fahrsituation angepasst wurden, in ihrer bisherigen Form limitiert.

Während die Trajektorien-Regelung bislang auf klassischen regelungsbasierten Verfahren beruhte, fanden sich bei der Trajektorien-Planung bereits erste KI-basierte Ansätze, bei denen die geplante Trajektorie mittels KI an die Umfeldbedingungen bzw. Objekte angepasst wurde. Bei regelungsbasierten Verfahren indes wurden KI-basierte Ansätze bis zum Projektbeginn nur in Grundlagenstudien betrachtet und einzelne Verfahren vorgeschlagen, wie einzelne Modellparameter aus den Umfelddaten erlernt werden können. In diesem Kontext wurden auch einzelne Anwendungen theoretisch betrachtet, allerdings nur im Kontext von MPC. Für den Einsatz in der Fahrdynamikregelung waren diese KI-basierten Ansätze völlig neu.

Ausgehend vom generellen Stand von Wissenschaft und Technik, bei dem grundlegende KI-Verfahren in der Regel für Big-Data-Anwendungen (TRL7+) erforscht und eingesetzt werden, suchte man im EEmotion-Projekt Wege, im Bereich Fahrdynamik ein neues Kapitel aufzuschlagen - mit der Option einer optimalen Portierung in Fahrzeuge.

Alle EEmotion-Partner verfügten über die notwendige Expertise und die Ressourcen, das Projekt erfolgreich durchführen zu können und hatten dies in Grundlagenforschungsprojekten (TRL2-5) auf nationaler und europäischer Ebene unter Beweis gestellt (s. auch 4. Verwertungskonzept). Auf dieser technologischen Basis setzte EEmotion auf: **EMC2** „Embedded Multi-Core Systems for Mixed Criticality Applications in Dynamic and Changeable Real-Time Environments“ (Artemis-JU), **ARAMIS I und Aramis II** „Automotive, Railway and

Projekt: **EEmotion** / Individueller Schlussbericht

Avionics Multicore Systems“ (BMBF), **iFuse** „Intelligente Fusion von Radar- und Videosensoren für anspruchsvolle hochautomatisierte Fahrsituationen“ (BMW), **KI-ASIC** „KI-Prozessorarchitekturen für Radarmodule im autonomen Fahrzeug“ (BMBF), **KI-Flex** „Rekonfigurierbare Hardwareplattform zur KI-basierten Sensordatenverarbeitung für das autonome Fahren“ (BMBF), **AutoDrive** „Hochzuverlässige Elektroniksysteme und Architekturen für das Autonome und Elektrische Fahren“ (ECSEL-JU), **SecForCARS** „Sicherheit für vernetzte, autonome Fahrzeuge“ (BMBF), **DecADe** „Decentralized Anomaly Detection“ (BMBF), **VITAF** „Vertrauenswürdige IT für autonomes Fahren“ (BMBF) und **3F** "Fahrerlose und Fehlertolerante Fahrzeugsysteme" (BMW).

1.5 Zusammenarbeit mit anderen Stellen

Mit spezifischen Kompetenzen ergänzten sich die Verbundpartner und gewährleisteten, dass die beschriebenen Themenfelder umfassend und effizient erforscht und verifiziert wurden. Hier ermöglichte das Zusammenspiel von Automotive-Systemanbietern und KI-Experten eine OEM-offene Erforschung der KI-Fahrdynamik und eröffnete eine große Anwendungsbreite, mit der sich deutsche Zulieferer und KMUs eine führende Position als Wegbereiter für „Intelligentes Fahren“ im internationalen Wettbewerb sichern können.

2 Eingehende Darstellung der erzielten Ergebnisse und des voraussichtlichen Nutzens

2.1 Überblick Gesamtvorhaben

Schlüsselinnovation: Die Erweiterung der Fahrdynamikregelungen mit KI-Methoden ermöglicht die Prädiktion des kinematischen Fahrzeugzustandes, was dazu führt, dass die entsprechenden Aktuator-Systeme wie Antriebsstrang, Bremse, Lenkung an die aktuellen Bedingungen der Umgebung angepasst werden können. Damit wird erreicht, dass die von der zentralen Perceptionseinheit vorgegebenen Fahrmanöver sehr präzise umgesetzt werden können, was einerseits zu einer Verbesserung des Fahrkomforts und andererseits zu einer Verbesserung der Energieeffizienz beiträgt. Bei konventionellen Antriebskonzepten führt das zu einer Reduktion der Emissionen. Bei batterieelektrischen Fahrzeugen wird die Reichweite erhöht.

Zusätzlich zu den technischen Errungenschaften ergab sich im EEmotion-Projekt auch ein wirtschaftlicher Vorteil: durch die KI wurde eine bessere Anpassbarkeit der Entwicklungssysteme an andere Fahrzeugtypen ermöglicht, was zu kürzeren Entwicklungszeiten beitrug.

Im Testfahrzeug demonstrierte technische Ergebnisse im Überblick:

- Es wurden 5 unterschiedliche Ansätze zur KI-erweiterten Trajektorienregelung entwickelt, die mittels echtzeitfähigem Mikrocontroller in das Testfahrzeug integriert wurden: Baseline-Controller, Residual PPO Agent, AI-enhanced PID, Data-driven MPC und Approximate Model Inversion using RBFNs. Außerdem

wurden KI-Methoden (Bayesische Optimierung als Klasse von Methoden) zur Parametrisierung des Baseline-Controllers verwendet.

- Es wurden vier unterschiedliche Ansätze zur KI-erweiterten modellprädiktiven Trajektorienplanung entwickelt und mittels echtzeitfähigem Mikrocontroller in das Testfahrzeug integriert: Advanced energy efficient MPC, AI-Clone of MPC for longitudinal Trajectory Planning, Reinforcement Learning for Decision-making und Trajectory Planning, Reinforcement Learning for adaptive MPC.
- Die um KI erweiterten Standardregler zeigten auf der Teststrecke eine Verbesserung der lateralen Regelabweichung von der vorgegebenen Trajektorie um bis zu 50% (anstatt der ursprünglich angenommenen 20 Prozent), was zu einer signifikanten Verbesserung des Fahrkomforts vom autonomen Fahrzeug führt.
- Die um KI erweiterten Standardplaner zeigen eine Verbesserung der Energieeffizienz für den Fall der Adaptiven Cruise Control um bis zu 14%.
- Es wurde gezeigt, dass die KI-basierten Ansätze zur Trajektorienregelung und -planung die Anpassung an unterschiedliche Fahrzeugtypen erleichtern, da die KI die Bestimmung der benötigten Parameter übernimmt, wodurch die Entwicklungszeit signifikant reduziert werden kann.
- Zur Absicherung der fahrzeuginternen Kommunikation wurden KI-basierte Ansätze zur Anomalie-Erkennung entwickelt und sowohl mittels echtzeitfähigem Mikrocontroller als auch mit einer Edge Computing Plattform in das Testfahrzeug integriert.
- Die im Testfahrzeug verwendete Architektur des Prototypensystems beruht auf einer Zonen-Architektur. Die Kommunikation zwischen den einzelnen Steuergeräten beruht auf der Zukunftstechnologie 10Base-T1S.
- Es wurde eine automatisierte und sichere Applikation des Baseline-Controllers mit Hilfe von einer methodisch neu entwickelten sicheren Variante von Bayes'scher Optimierung (KI-Verfahren) demonstriert.

Technisch-methodische Ergebnisse im Überblick:

- Der Einsatz von Simulationen zur Entwicklung von Fahrassistenzsystemen ist ein bewährter Ansatz. Mit der Integration von MATLAB und CarMaker in AP3/AP4 über die FMI-Schnittstelle konnten die Algorithmen verifiziert und festgezogen werden. Dieser Ansatz bot viel Flexibilität und war erstaunlich anpassbar während der Benutzung, insofern man die Hardware-Restriktionen außer Acht ließ. Um diese Einschränkung zu beseitigen, wurde das ECU-System für die Steuerung mit einer virtuellen Plattform (VP) nachgebildet. Diese umfasste das TriCore-AURIX-System sowie den Beschleuniger für die KI-Applikation in der Synopsys TC4.9x-VDK. Das System zeigte die Laufzeiten und die Performance für die integrierte Software, so wie sie auch auf der realen Hardware läuft. Um das Übertragen der Daten in der FMI-Umgebung mit CarMaker auszutauschen, wurde die für MATLAB definierte Schnittstelle in eine VP integriert. So war es möglich, die Hardware-optimierten Algorithmen in derselben Co-Simulation (CarMaker/VP) zu testen. Es wurde eine weitere Fahrdynamik-Simulation integriert, sodass eine Carla/VP-Co-Simulation lief. Darüber hinaus verwendete die VP-Simulation dieselbe Schnittstelle - ein Ethernet-Paket-Austauschformat, das auch der reale Demonstrator nutzte, sodass es in einem vHIL-Ansatz verwendet werden konnte. Dies konnte wegen der späten Fertigstellung der VP nicht mehr vollständig getestet

werden. Trotz einiger Herausforderungen konnte hier erfolgreich eine Methodik für die Benutzung von virtuellen Plattformen und vHIL-Co-Simulationen aufgezeigt werden.

- KI Algorithmen sind datengesteuerte Ansätze, deren Generalisierung direkt von der Wahl der „richtigen“ Trainings- und Testdaten abhängt. Um dies für die im Projekt entwickelten KI-Algorithmen zu gewährleisten, wurde eine Simulationsumgebung bestehend aus CarMaker und MATLAB entwickelt. Mit dieser Simulationsumgebung wurden die im Projekt verwendeten Daten zum Modellieren, Trainieren und Testen der entwickelten KI-Algorithmen bereitgestellt. Um die Richtigkeit der generierten Daten sicherzustellen, wurde eine auf die im Projekt festgelegten Anwendungsfälle angepasste Operational Design Domain (ODD) definiert. Die ODD beschreibt alle Betriebsbedingungen, unter denen ein bestimmtes Fahrautomatisierungssystem funktionieren soll. In unserem Fall wurde eine ODD wie folgt definiert: geradeaus fahren, auf einer mehrspurigen Straße fahren, ein innerstädtisches Szenario, keine Kreuzungen. Entsprechend dieser Definition haben wir eine Reihe von Basisszenarien entwickelt, die als Grundlage für die Erstellung von Trainings-, Test- und Validierungsszenarien dienen. Auf Grundlage dieser ODD sind 20 Basisszenarien definiert worden. Als Basisszenarien versteht man elementare Fahrscenarien wie einen Spurwechsel. Diese Basisszenarien wurden in der CarMaker-Umgebung modelliert und in einem XML-ähnlichen Format dargestellt. Damit wurde ein Ansatz entwickelt, der sehr einfach um weitere Basisszenarien erweitert werden kann. Diese generischen Basisszenarien werden mit Hilfe eines MATLAB-Modells so parametrisiert, dass Use-Case-spezifische Daten für Fahrscenarien generiert werden. Mit diesem beschriebenen Ansatz werden realistische Basisszenarien anhand von realen Fahrzeugdaten parametrisiert, und daraus wurden dann eine Vielzahl von synthetischen Fahrscenarien erzeugt (das Assessment-Center für die Trajektorienregelung umfasste zu Projektabschluss insgesamt 50 verschiedene Szenarien). Damit wurde die Datenqualität zur Entwicklung der KI-Algorithmen sichergestellt.
- Entwicklung von sechs neuartigen Varianten der Bayes'schen Optimierung und Mitentwicklung von 2 Deep Reinforcement Learning Algorithmen sowie deren Publikation in 5 Veröffentlichungen.
- Die Sicherheit (i.S.v. Safety) des betrachteten Fahrdynamiksystems wurde aus der Perspektive des Multi-Aspect Safety-Engineerings untersucht. D.h., es wurde eine ganzheitliche Sicht auf das Thema Sicherheit eingenommen, bei der sowohl die Sicherheit bei Fehlern und Ausfällen (funktionale Sicherheit), als auch das sichere Nominalverhalten und die Sicherheit trotz funktionaler Unzulänglichkeiten (SOTIF) betrachtet wurde. Hierzu wurden die aktuell gültigen Standards (ISO 26262, ISO 21448) als auch der querschnittlich orientierte DRAFT Standard ISO/PAS 8800 „Safety and Artificial Intelligence“ betrachtet. Dabei wurden u.a. folgende technisch-methodische Ergebnisse erzielt:
 - Festlegung von high-level Sicherheitszielen sowie von abgeleiteten, konkreten Sicherheitsanforderungen für zwei exemplarische KI-Komponenten (MPC-basierter Trajektorienplaner, MPC-TP; Querregler zur Trajektoriensteuerung)

Projekt: **EEmotion** / Individueller Schlussbericht

- Eruierung des ISO/PAS 8800 Entwicklungsprozesses und Identifikation der relevanten AI-Properties für den Querregler zur Trajektoriensteuerung
- Durchführung einer SOTIF-Analyse des MPC-TP mit Dokumentation der Functional Insufficiencies und Triggering Conditions
- Ableitung einer verbesserten Architektur des MPC-TP
- Konkretisierung der Vorgehensweise zum Umgang mit SOTIF-Elements out of Context (SOTIF-EooC).
- Evaluierung einer Vorgehensweise zur ODD-basierten Strukturierung der Sicherheitsnachweisführung

Zusammengefasst wurden die angestrebten TRL-Level der Kerninnovationen im Projekt erreicht:

Kerninnovation im Projekt	Stand der Technik zu Projektbeginn (mit Angabe des TRL-Levels)	Angestrebter Innovationshub (mit Angabe des TRL-Levels)
KI-Algorithmus auf automobilen eingebetteten Systemen (Ziel 6,7)	TRL 3:	TRL 6: Fahrzeugdemonstrator
KI-basierte MPC (Model Predictive Control) Ansätze (Ziel 1, 2, 4)	TRL 2	TRL 6: Fahrzeugdemonstrator
Abgesicherte Kommunikation mittels KI (Ziel 10)	TRL 3	TRL 6: Fahrzeugdemonstrator
Simulationsbasiertes Training und Validierung von KI-Algorithmen (Ziel 2, 5, 9, 10)	TRL 4	TRL 5: Machbarkeit für EEmotion-System nachgewiesen

Abbildung 5: Angestrebte TRL-Level der Kerninnovationen im Projekt

2.2 Teilvorhaben Infineon Technologies AG

Als Projektkoordinator war Infineon an allen Arbeitspaketen beteiligt, beginnend mit der Leitung von AP2 (Systemarchitektur für KI-Fahrdynamik). Hierin ging es um die Applikationsanforderungen zur Trajektorienplanung und -regelung und das Überführen der Ergebnisse in eine funktionale Systemarchitektur. Die Einzelteile wurden in funktionale Module aufgeteilt und die funktionalen Schnittstellen wurden festgelegt. In den anderen APs wurde unter anderem die Anwendbarkeit von KI-Methoden, zum Beispiel von Deep Neural Networks (DNN), auf die Komponenten der Trajektorienplanung und -regelung untersucht. Des Weiteren konzentrierte sich das Infineon-Team auf die Echtzeitfähigkeit von Funktionen auf einem Embedded-System, dessen Hardware-Architektur ausgearbeitet wurde, um einen Prototypen zu entwickeln.

2.2.1 AP1 Applikationsanforderungen, Spezifikation KI-Fahrdynamik

Das Ziel vom AP1 war die Schaffung einer einheitlichen Grundlage für die Entwicklung des KI-optimierten Fahrdynamik-Systems für Autonomous Driving (AD) und das Advanced Driver

Projekt: **EEmotion** / Individueller Schlussbericht

Assistance System (ADAS) in Form eines umfassenden Anforderungskatalogs. Hierzu wurden die Funktionen auf verschiedenen Abstraktionsebenen definiert und hinsichtlich ihrer Anforderungen analysiert.

2.2.1.1 AP1.1 Definition der Anforderungen auf Fahrzeugebene

Im Rahmen von AP1.1 konzentrierte sich das Infineon-Projektteam auf die Umsetzung der Anforderungen an die KI-Systeme auf Fahrzeugebene. Die Experten formulierten lösungsunabhängige Anforderungen und passten diese an die KI-Systeme an. Insbesondere die KPIs wurden entsprechend den Erfordernissen angeglichen, damit sie für die KI-Methoden nutzbar waren.

Im Detail wurden die KPIs und Leistungsanforderungen für Lösungen für Adaptive Cruise Control (ACC) und Autopilot spezifiziert. Das Infineon-Team konzentrierte sich darauf, Prototypen- und Demonstrator-Szenarien zu beschreiben und Anforderungen zu analysieren. Es priorisierte Anforderungen zur Realisierung des Prototyps und Demonstrator-Systems. Weiterhin wurde der funktionale und nicht-funktionale Betrachtungsumfang charakterisiert und eine Basis zur Zerlegung der Anforderungen für Subsysteme bereitgestellt. Das Ergebnis von AP1.1 war die Spezifikation der Anwendungsfälle und betrachteten Applikationen zusammen mit den notwendigen KPIs auf Fahrzeugebene. Diese dienten im weiteren Projektverlauf als Basis, um daraus KI-basierte Algorithmen zu entwickeln.

2.2.1.2 AP1.2 Definition und Beschreibung der Funktionen des KI-Systems

Die im AP1.1 erstellten Fahrzeuganforderungen wurden im AP1.2 genutzt, um die Anforderungen an die KI-Verfahren auf der Systemebene zu präzisieren. Um die Funktionssicherheit zu gewährleisten, erstellte das Projektteam Sicherheitsanforderungen, die von den im AP1.1 definierten Anforderungen abgeleitet und aufbereitet wurden. Das Ergebnis war die Dokumentation und Verwaltung der funktionalen Anforderungen auf der Systemebene, sodass sie für KI-Verfahren nutzbar wurden.

2.2.1.3 AP1.3 Definition und Beschreibung der SW/HW-Komponenten

Nach der Spezifikation der Systemebene, unterstützte das Infineon-Projektteam die Ableitung der Anforderungen auf Software- und Hardware-Ebene. Diese Anforderungsebene diente als Basis zur Erstellung der Systemarchitekturen in AP2 sowie der Implementierung der gesamten SW- und KI-Funktionen. Einen maßgeblichen Anteil trug die Spezifikation der Basis-Software sowie der Hardware-Komponenten bei.

2.2.1.4 AP1.4 Spezifikation der Simulationsumgebung

Die im Projektverlauf getroffenen Entscheidung zur Nutzung der IPG Carmaker Simulation hatte Auswirkungen auf die Spezifikation der Simulationsumgebung. Der wesentliche Aspekt der Spezifikation lag in der Bereitstellung von entsprechenden Fahrdynamik- und Umgebungsinformationen, um ein umfassendes Training und Testen der entwickelten KI-Komponenten zu ermöglichen. Hierbei wurde ein Schwerpunkt auf die Spezifikation einer

Projekt: **EEmotion** / Individueller Schlussbericht

automatisierten Generierung von spezifischen Fahrscenarien gelegt, um die geforderten Anwendungsfälle abzubilden. Entsprechende Szenarien-Parameter wie Fahrgeschwindigkeit, Beschleunigungsverhalten sowie Szenentopologie erforderten hierbei eine zufallsgesteuerte Parametrisierung, um eine generalisierte KI-Lösung zu ermöglichen.

2.2.2 AP2 Systemarchitektur KI-Fahrdynamik

Die Aufgabe des Infineon-Projektteams im AP2 "Systemarchitektur KI-Fahrdynamik" war die Analyse und Partitionierung der in AP1 definierten Anforderungen und Anwendungsszenarien zur Trajektorienplanung und -regelung. Basierend auf dieser Partitionierung wurde eine funktionale, logische und physikalische Systemarchitektur entworfen.

Durch eine abgestimmte Auswahl und Analyse von repräsentativen Anwendungsfällen konnten das Systemverhalten und die äußeren und inneren Systemschnittstellen näher charakterisiert und spezifiziert werden. Im weiteren Projektverlauf überführten die Infineon-Entwickler in Zusammenarbeit mit den Projektpartnern ZF Friedrichshafen und b-plus die funktionale und logische Systemarchitektur des KI-Fahrdynamiksystems in eine zonenbasierte E/E-Architektur.

2.2.2.1 Definition der funktionalen KI-Fahrdynamik-Systemarchitektur und Integration in die funktionale Fahrzeuggesamtarchitektur

Das Design der funktionalen und logischen Systemarchitektur wurde nach dem etablierten Prozessmodell SysML durchgeführt*. In Abbildung 9 wird der Prozessfluss zur Ableitung der gesamten Systemarchitektur schematisch illustriert.

Im ersten Schritt wurde auf Basis der in AP1 spezifizierten funktionalen und nicht-funktionalen Anforderungen der System-Kontext inklusive Auflistung der involvierten Akteure seitens ZF erstellt. Anschließend wurden prägnante User-Stories bestimmt, welche das gewünschte Gesamtverhalten des zu entwickelnden Systems optimal abdecken (bspw. „Driving Home“). Eine entsprechende User-Story wurde nun in entsprechende Szenarien untergliedert, welche die Grundlage für die sukzessive Erstellung von funktionaler und logischer Systemarchitektur bildeten. Das Infineon-Projektteam übernahm hierbei die weitere Erstellung der logischen Systemarchitektur.

Zur weiteren Illustration des Designprozesses diente das Szenario „Spurwechsel auf einer mehrspurigen Straße“.

Use Cases + Actors

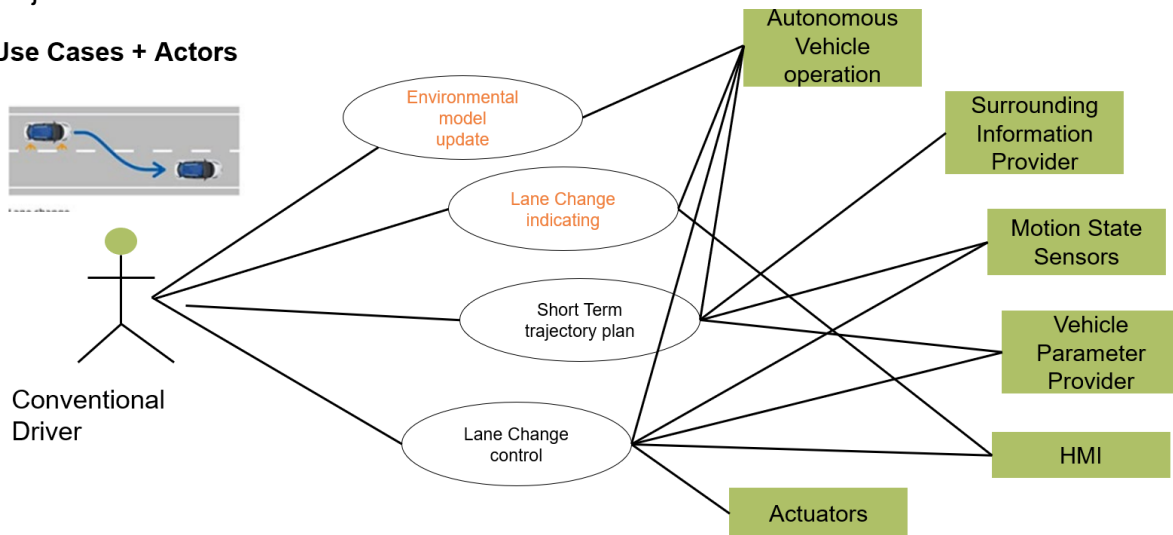


Abbildung 6: Szenario „Spurwechsel auf einer mehrspurigen Straße“ unterteilt in beteiligte Anwendungsfälle und Akteure

In der detaillierten Analyse der einzelnen Anwendungsfälle ließen sich das Verhalten (siehe Abbildung 7 „Aktivitätsdiagramm“) als auch Interaktionen zwischen dem System und den beteiligten Akteuren durch definierte Methoden bestimmen.

Activity Diagram
(with object flow)

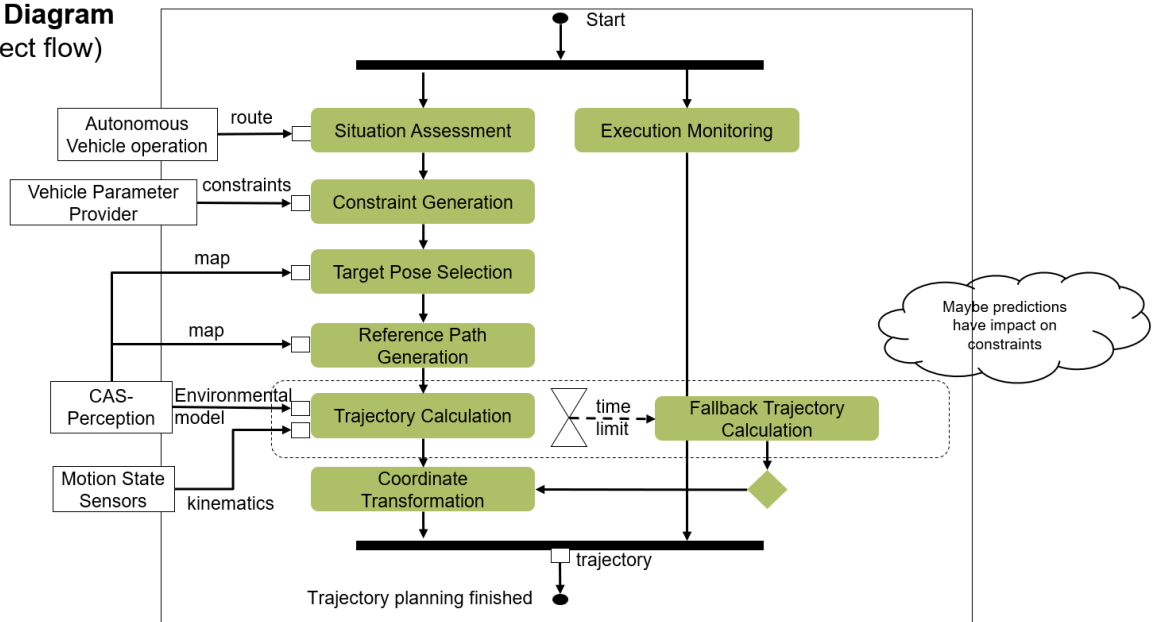


Abbildung 7: Aktivitätsdiagramm zum Anwendungsfall "Short term trajectory plan"

Bei der weiteren Betrachtung der internen System-Interaktionen für jeden Anwendungsfall wurden in einem kreativen Prozess die internen logischen Komponenten sichtbar (Abbildung 8). Anschließend konnten sie iterativ detaillierter definiert werden.

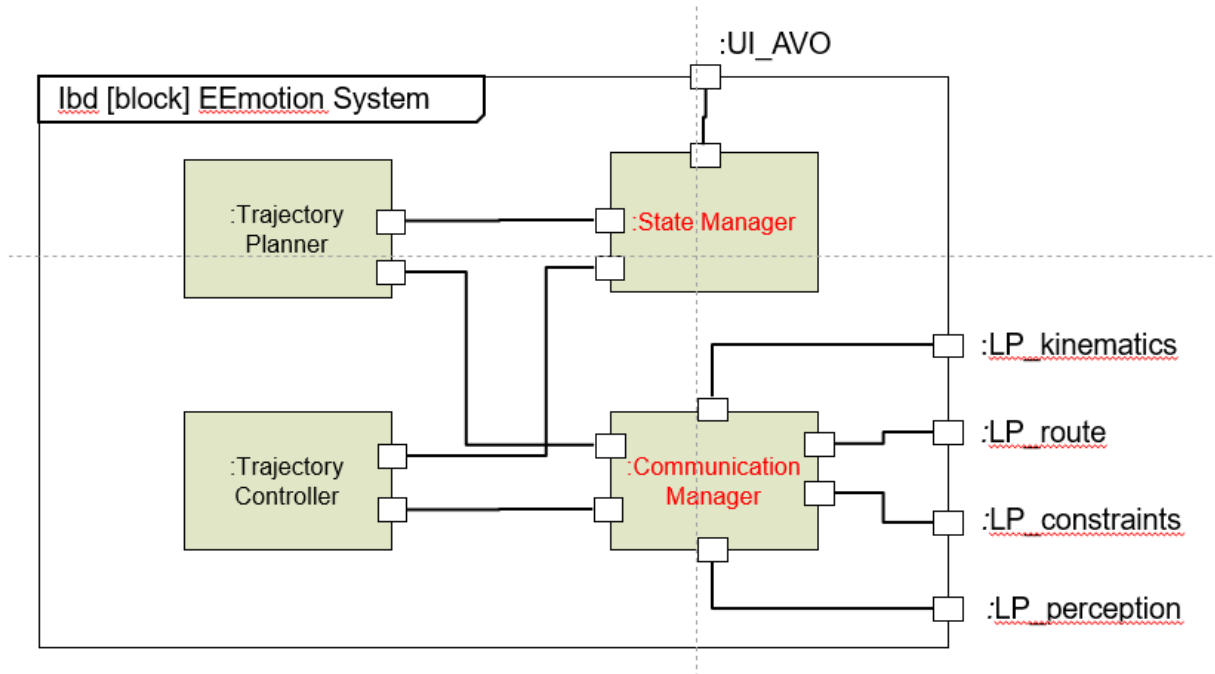


Abbildung 8: Logische Systemstrukturen für Szenario „Spurwechsel auf einer mehrspurigen Straße“

Nach Analyse aller gewählten Szenarien und zugehörigen Anwendungsfälle vervollständigte sich die komplette logische Architektur. Sie bildete den Ausgangspunkt zur Bestimmung der physikalischen Architektur, welche die reale Partitionierung der Systemsoftware- und Hardware-Komponenten spezifizierte.

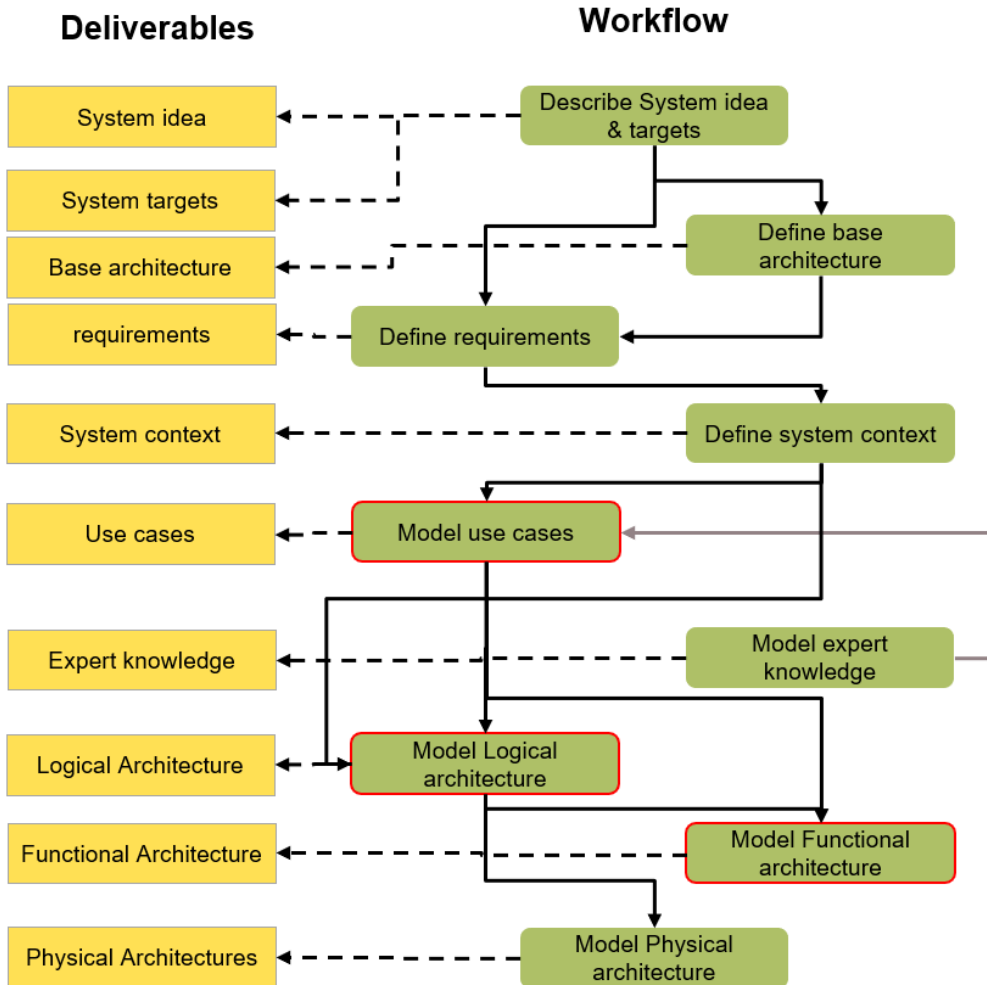


Abbildung 9: Erstellung der funktionalen, logischen und physikalischen Systemarchitektur nach SysML

2.2.2.2 Definition der physikalischen KI-Fahrdynamik Systemarchitektur und Integration in eine nach dem Stand der Technik definierte Elektrik-/Elektronikarchitektur

Nach eingehender Analyse der funktionalen und logischen Architektur zusammen mit den nicht-funktionalen Anforderungen an Hardware- und Softwarekomponenten konnte die physikalische Architektur abgeleitet werden. Diese Entscheidung wurde in einem iterativen Prozess verfeinert, da sich teilweise erst durch Implementierung und Validierung die notwendigen Schlüsse ziehen ließen. Beispielsweise wurde die Anomalie-Erkennung auf einem separaten AURIX-Microcontroller integriert, um eine exklusive Nutzung des AI-Beschleunigers (PPU) zu ermöglichen (Siehe Abbildung 10).

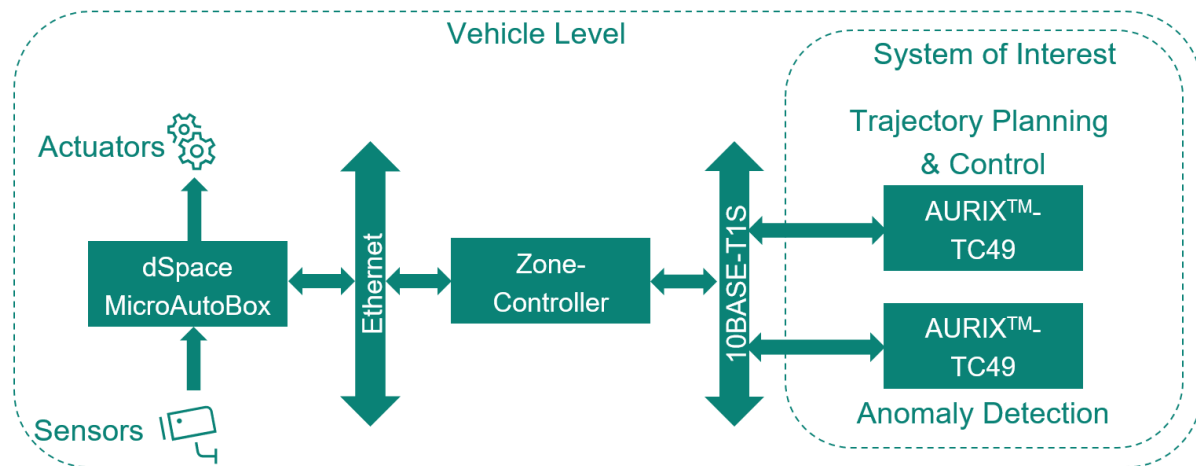


Abbildung 10: Physikalische Architektur (vereinfacht) für das zu entwickelnde System

2.2.2.3 Partitionierung der in AP2.1 definierten modularen Systemarchitektur auf KI-basierte Komponenten bestehend aus HW/SW-Funktionsblöcken

Auf Basis der definierten System-Architektur leitete das Infineon-Projektteam zusammen mit den Projektpartnern die weitere Software- und Hardware-Architektur sowie die Schnittstellen für das zu entwickelnde System ab.

Da die Ziel-Hardware des Systems als Projektanforderung bereits definiert war (AURIX™-TC4x), ergaben sich nur geringere Freiheiten in der Gestaltung der Hardware-Architektur. Die Software-Architektur wurde über einen Modell-getriebenen Entwicklungsansatz innerhalb des Software-Werkzeugs MATLAB/Simulink abgebildet. Somit konnten eine inhärente Software-Architektur und -Implementierung sichergestellt werden. Durch eine Integration der Zielhardware war es zudem möglich, die einzelnen Software-Komponenten auf die entsprechenden Hardware-Komponenten (CPU, KI-Beschleuniger, Speicher) zu partitionieren. Abbildung 11 lässt erkennen, wie sich am Beispiel der Trajektorien-Planung und -Regelung alle System-relevanten Funktionen auf den einzelnen Hardware-Komponenten des AURIX abbilden lassen. Hierbei wurden die konventionellen Algorithmen der Trajektorien-Planung und -Regelung auf der skalaren TriCore-CPU und die KI-Algorithmen (z.B. ein Neuronales Netz) auf dem Beschleuniger (PPU) verteilt. Das Infineon-Projektteam erarbeitete eine Vorlage, durch welche sich die System-Software aus der Simulink-Umgebung generieren und auf der Zielhardware integrieren und testen ließ.

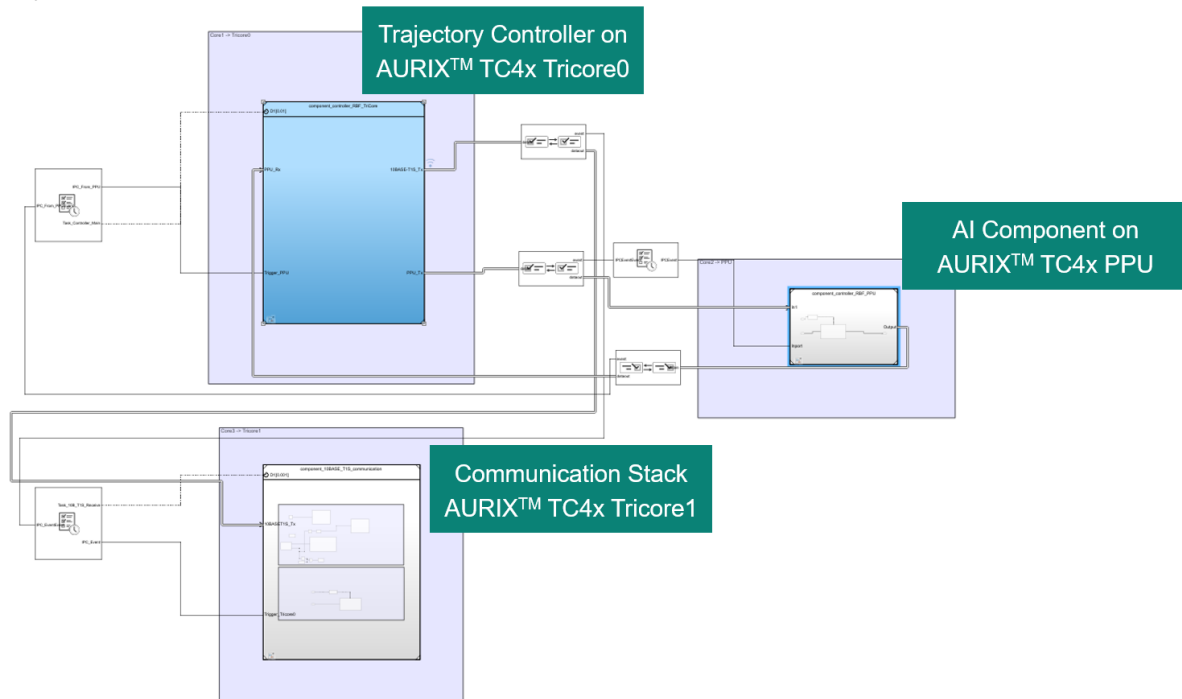


Abbildung 11: Partitionierung der Software-Komponenten zur Trajektorien-Planung und -Regelung auf der Ziel-Hardware

Die in AP1 gewonnenen Software-Anforderungen wurden ebenfalls durch das Infineon-Team mit den entsprechenden Software-Komponenten innerhalb des Simulink-Modells verknüpft, sodass eine nahtlose Abbildung zwischen Anforderungs-, Architektur- und Implementierungsebene analog zur linken Seite des V-Modells hergestellt werden konnte (Abbildung 12).

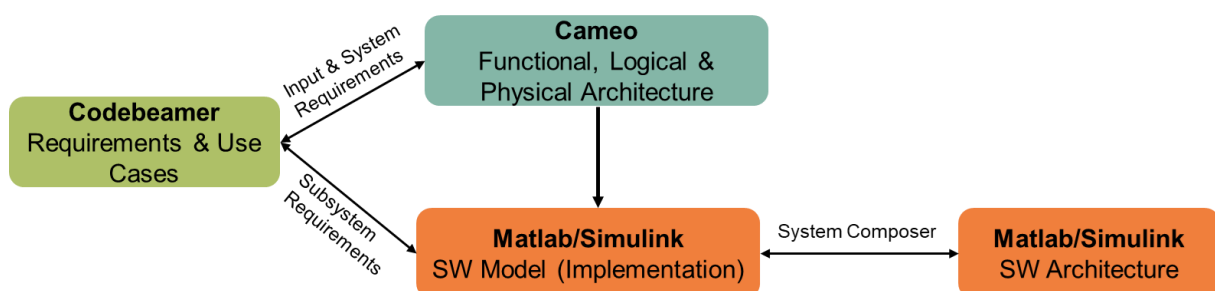


Abbildung 12: Verknüpfung der Anforderungen mit der Software-Architektur in MATLAB/Simulink

2.2.2.4 Absicherung des in AP2.1 und AP2.2 definierten KI-Fahrdynamiksystems aus Sicht der technischen Sicherheit

Zur Absicherung der entwickelten KI-Komponenten des KI-Fahrdynamiksystems wurde vom Infineon-Team ein mehrstufiger Analyseprozess unter Einbindung mehrerer Sicherheitsstandards vorgenommen (ISO 8800, ISO 26262, ISO 21448). Wie in der folgenden

Projekt: **EEmotion** / Individueller Schlussbericht

Abbildung dargestellt, wird hierbei ein zyklisch-iterativer Vorgang empfohlen, der sich über die Definition der Operational Design Domain (ODD), Selektion der Trainingsdaten, Training des KI-Modells sowie Prüfung einer generalisierenden Lösung durch das KI-Modell erstreckt. Da sich KI-basierte Systeme über ihre Trainingsdaten definieren, müssen im ersten Schritt die Daten-Vollständigkeit, -Integrität und Korrektheit sichergestellt werden. Zusätzlich muss die korrekte Auswahl der Trainingsdaten in Bezug auf die ODD sichergestellt sein. Innerhalb des laufenden Betriebs benötigt die KI-Komponente eine fortlaufende Überwachung zur Einhaltung der ODD-Grenzen (Abbildung 13).

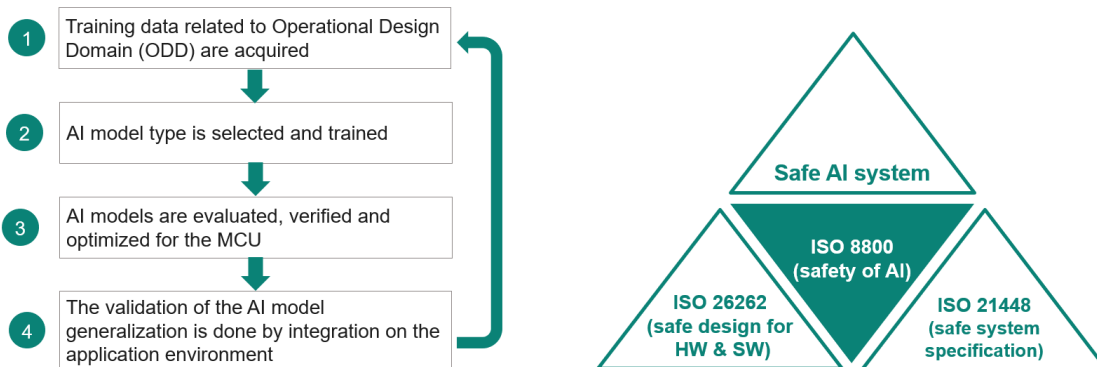


Abbildung 13: Zyklischer Prozess zur Absicherung von KI-basierten Komponenten

2.2.2.5 Erstellung eines Systemmodells zur Verifikation der in AP2.1 definierten Systemarchitektur

Für die im AP2.1 definierte modulare Systemarchitektur erstellte das Infineon-Team ein Simulationsmodell, das auch zur Verifikation der Aktivitäten im AP2.2, AP2.3 und AP2.4 verwendet wurde. Es beschreibt auf mathematisch abstrakter Ebene die Funktionsinhalte der einzelnen Systemarchitektur-Module und die zugehörigen funktionalen Schnittstellen. Für kollaboratives Arbeiten im Rahmen des EEmotion-Projekts setzte das Infineon-Team gemeinsam mit Projektpartnern das Software-Tool Cameo Systems Modeler ein.

Innerhalb der genutzten modellbasierten Entwicklungsumgebung MATLAB/Simulink konnte die korrekte Verknüpfung von Anforderungen und Softwarekomponenten mittels entsprechender Werkzeuge verifiziert werden (Abbildung 14).

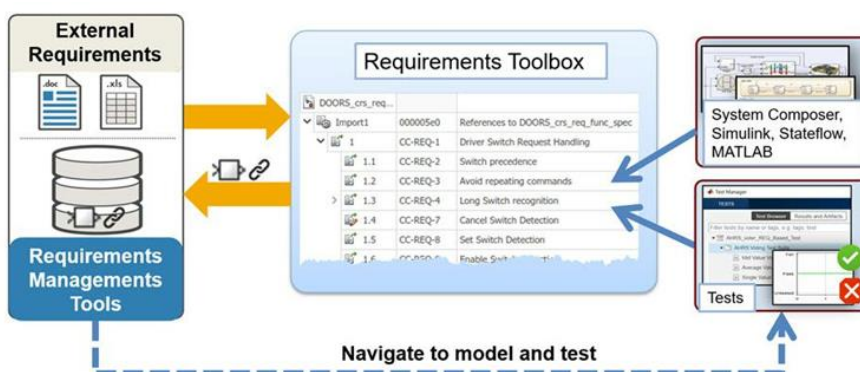


Abbildung 14: Prüfung der vollständigen Abbildung von Anforderungen und Architektur in MATLAB/Simulink

2.2.3 AP3 KI-HW und Applikationsfunktionen - AD/ADAS

2.2.3.1 AP3.1 2-Freiheitsgrad-Regelung und KI-Methode für optimale adaptive Trajektorien-Ausführung

In AP3 bestand die Aufgabe des Infineon-Teams darin, stabile und effiziente Algorithmen für die Trajektorienplanung und -steuerung zu entwickeln, um verschiedene Aktuatoren zu steuern (z. B. Lenkung der Vorder- und Hinterachse, Bremsen, Verbrennungsmotor oder Dämpfer). Die Planung und Ausführung einer vorgegebenen Trajektorie diente als Grundlage für AD/ADAS-Systeme wie den energieoptimierten ACC oder Autopiloten. Die geplante Trajektorie (Geschwindigkeitsprofil, Beschleunigungsprofil, Pfadprofil, Fahrzeugsteuerungs-Algorithmus) sollte zu einem effizienten Energieverbrauch (Benzinverbrauch) und einer signifikanten Steigerung des Fahrkomforts bei gegebener Fahrzeugkonfiguration führen. Ein wichtiger Aspekt, der bei der Entwicklung der Infineon-Lösung berücksichtigt wurde, war die Sicherheit der Fahrfunktion, die jederzeit und unter allen Umständen gewährleistet sein musste.

Eines der Hauptziele von WP3 war die Verbesserung konventioneller Trajektorien-Regelungsalgorithmen (modellprädiktive Regelung (MPC), PID) mit KI-Techniken. In einigen Fällen wurden Teile des Regelungsalgorithmus vollständig durch KI ersetzt, z. B. Austausch des MPC-Solvers durch einen Reinforcement-Learning-Agenten oder KI-gestütztes Tuning des konventionellen Regelungsalgorithmus.

2.2.3.2 AP3.2 Modellprädiktive Steuerung und AI-Methoden für optimale adaptive Trajektorien-Ausführung

Die Trajektorienregelung war der letzte Schritt in der Berechnungskette des automatisierten Fahrsystems und musste sicherstellen, dass das Fahrzeug der geplanten Trajektorie so genau wie möglich folgte. Konventionelle Regelungsalgorithmen leiden unter Einschränkungen wie mangelnder Anpassungsfähigkeit an dynamische Umgebungen, hohem Rechenaufwand und zeitaufwändigem Parametertuning. Im Rahmen des EEmotion-Förderprojekts haben wir sowohl konventionelle als auch KI-basierte Trajektorienregelungsansätze getestet.

Zu Beginn wurde der konventionelle PID-Algorithmus in der vom Projektpartner ZF bereitgestellten Simulationsumgebung abgestimmt. In der nächsten Entwicklungsstufe beschloss das Infineon-Team, die Regelungsalgorithmen in der CarMaker-Simulationsumgebung zu optimieren. Die Entwickler testeten die Leistung der entwickelten Algorithmen in einer unbekanntem Szenarien-Menge und sie beobachteten eine signifikante Verschlechterung der Reglerleistung.

Deshalb beschlossen sie, eine KI-Erweiterung in die konventionellen Regelungsalgorithmen einzuführen, um sie an unbekanntem Szenarien anpassbar zu machen. Grundsätzlich geht es bei künstlicher Intelligenz um Daten, die der Schlüssel zur Entwicklung dieser Art von Algorithmen sind. Da diese spezifischen Daten im Allgemeinen nicht öffentlich verfügbar sind, mussten sie in der Simulationsumgebung (CarMaker) gesammelt werden.

Das Team präsentierte einen KI-verbesserten Ansatz zur Trajektorienregelung, der die oben genannten Einschränkungen reduziert. Der KI-Einsatz ermöglichte es, einen klassischen PID-

Projekt: **EEmotion** / Individueller Schlussbericht

Regler adaptiv zu gestalten. Dazu wurde ein 3-Schichten-MLP trainiert, das Informationen über Szene, Manöver und dynamische Fahrzeugparameter in PID-Verstärkungen umwandelt (siehe Abbildung 15).

Die Kombination eines PID-Reglers mit einem kleinen neuronalen Netzwerk ist numerisch immer noch einfacher zu gestalten als ein komplexerer modellprädiktiver Regler und profitiert gleichzeitig von KI-Beschleunigern auf modernen automobilen MCUs wie der neuesten Generation von AURIX™.

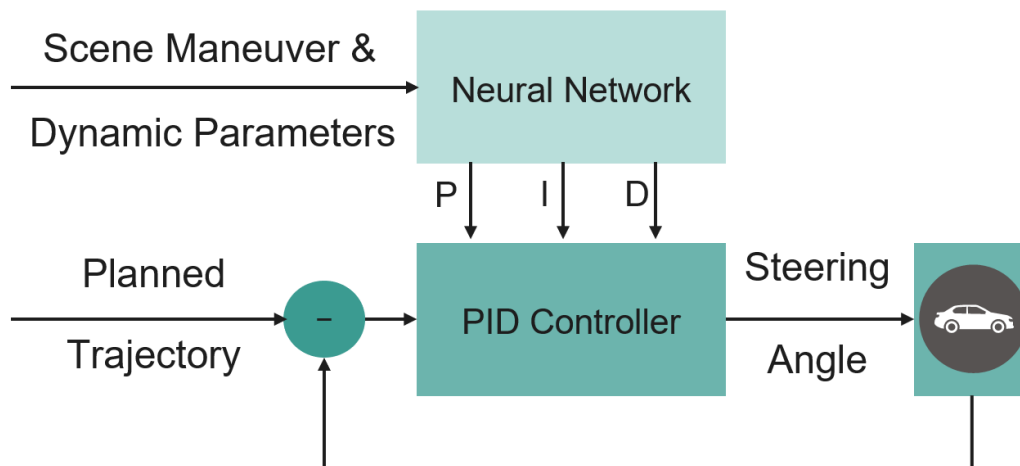


Abbildung 15: AI-Enhanced PID-Controller

Die vorgeschlagene Lösung wurde sowohl in der Simulationsumgebung als auch auf der Teststrecke getestet. Als Testszenario in der Simulation wählten das Team den Nürburgring und es verglich die Leistung der vorgeschlagenen Lösung mit einem herkömmlichen PID-Regler mit festen Parametern. In Abbildung 16 kann man erkennen, dass der vorgeschlagene Algorithmus eine Verbesserung des quadratischen Mittelwertfehlers des Querabweichungsfehlers um etwa 50 % im Vergleich zu einem herkömmlichen PID-Regler aufweist.

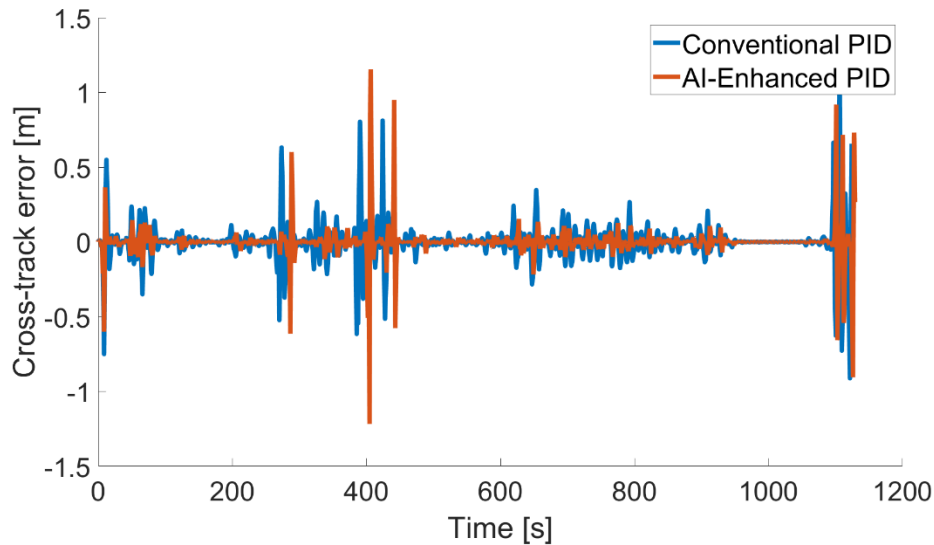


Abbildung 16: Tracking-Genauigkeit für konventionelle und AI-verstärkte PID-Verfahren auf dem Nürburgring in einer Simulationsumgebung

Als zweiter Ansatz wurde eine modell-prädiktive Trajektorienregelung (Model Predictive Control; MPC) vom Infineon-Team umgesetzt. Durch eine entsprechende KI-Erweiterung wurde die laterale Regelungskomponente in ihrer Regelungsgenauigkeit verbessert.

In Abbildung 17 wurde die grundlegende Funktionsweise dieses Ansatzes skizziert. Als Eingangsgrößen für den MPC diente die geplante Fahrtrajektorie. Der MPC berechnete dann eine entsprechende Prädiktionstrajektorie durch Nutzung eines Fahrmodells und Kontrollgrößen wie eine Serie aufeinander folgender Lenkwinkel. Iterativ wurde innerhalb einer Optimierung der Fehlerabstand zwischen Planungs- und Prädiktions-Trajektorie über eine Anpassung der Kontrollgrößen minimiert. Der finale optimale Lenkwinkel wurde anschließend an die Aktorik ausgegeben. Im folgenden Ansatz wurde das Fahrmodell (Einspurmodell) innerhalb des MPC durch ein neuronales Netz ersetzt. Hierdurch wurde eine bessere Beschreibung der Fahrdynamik erzielt.

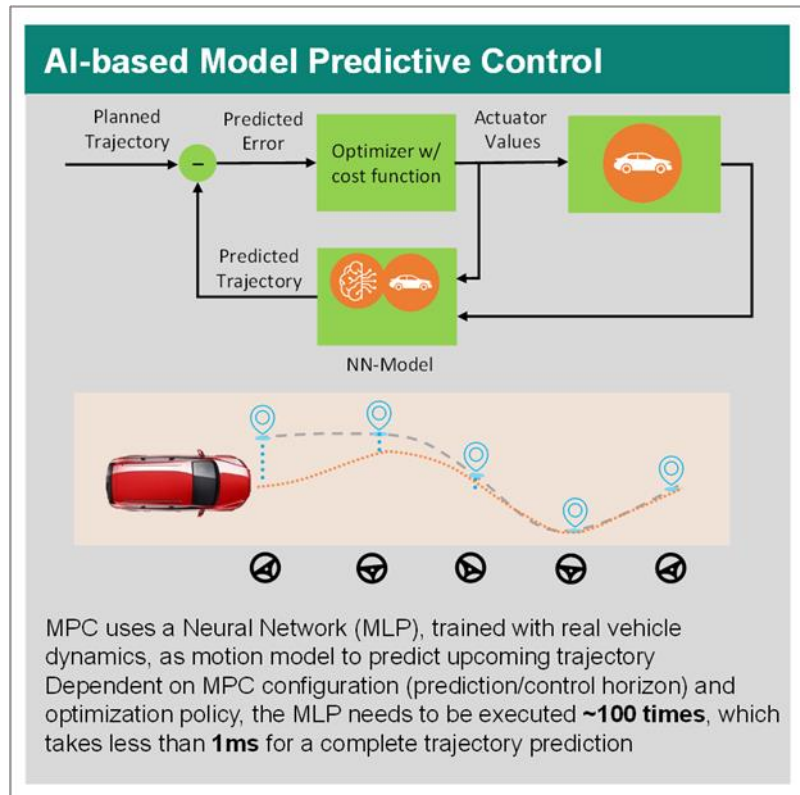


Abbildung 17: KI-gestützter Model-Predictive-Controller zur Querregelung

Zum Training der KI-Komponente (Fahrmodell) wurde die ODD-basierte automatisierte Szenarien-Generierung genutzt, um z.B. den Fall eines linken Spurwechsels spezifisch zu erlernen und zu erproben (siehe AP6). Um den ODD-Raum abzudecken, wurden die Fahrsimulation u.a. mit unterschiedlichen Start- und End-Geschwindigkeiten im Bereich zwischen 5 und 80 km/h durchgeführt. In Abbildung 18 sind die simulierten Fahrdynamiken erster und zweiter Ordnung sowie die entsprechenden Lenkaktionen dargestellt. Diese Wertetupel bildeten die Grundlage zum anschließenden Training des Neuronalen Netzes zur Modellierung der Fahrdynamik. Das so trainierte Neuronale Netz konnte klassische analytische Modellvorschriften zur Vorhersage der Fahrbewegung im MPC ersetzen bzw. durch Training mit realen Fahrdynamiken übertreffen.

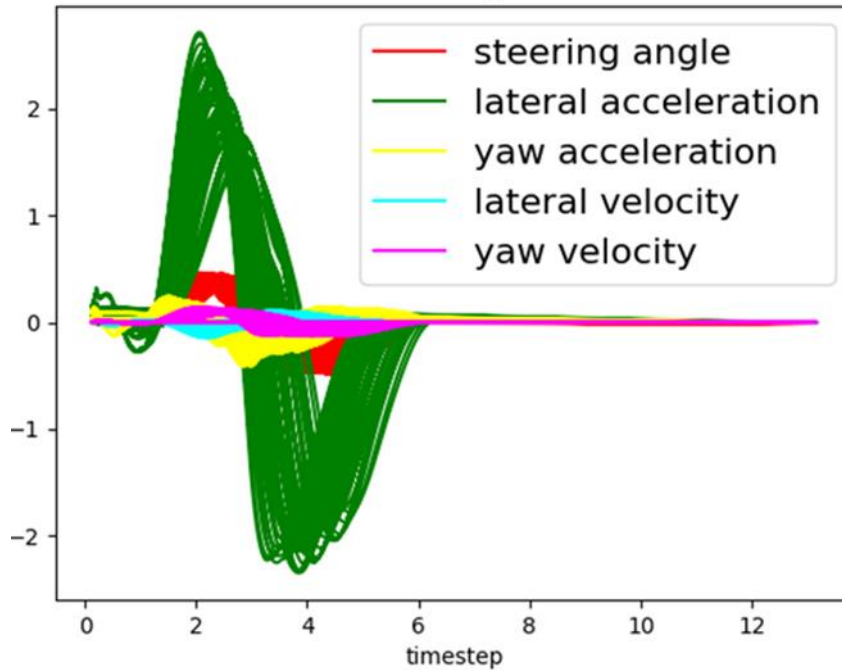


Abbildung 18: Simulierte Fahrdynamiken für die ODD des linken Spurwechsels

Diese Erwartung kann, wie es in Abbildung 20 dargestellt wird, bestätigt werden. Der laterale Versatzfehler (Offset Error) zur idealen Plantrajektorie fällt bei der Nutzung des trainierten Neuronalen Netzes zur Prädiktion der Fahrbewegung (AI MPC) geringer aus, als bei der Nutzung eines klassischen Einspurmodells (Conventional MPC). Eine mögliche Interpretation liefert der Verlauf der Lenkwinkel (Steering Angle). Der Lenkverlauf beim AI MPC muss weit weniger korrigiert werden als beim konventionellen MPC. Scheinbar stimmt die Prädiktion des Fahrverlaufs durch das Neuronale Netz besser mit dem realen Fahrverlauf überein, als die Schätzung durch das konventionelle Einspurmodell. Zur Einhaltung gerechter Vergleichbedingungen zwischen beiden Varianten wurden identische Implementierungen der MPC-Logik und Regler-Parameter verwendet. Zur Einordnung des MPC-Ansatzes in den aktuellen Stand der Technik wurde zudem ein dynamischer, lateraler Stanley-Controller aus der Automated Driving Toolbox von Matlab in den Vergleich mit einbezogen. In Abbildung 19 stellt sich der geringste laterale Versatzfehler für den AI-MPC im Vergleich zum konventionellen MPC dar (~22% geringerer CTE). Beide MPC-Varianten übertreffen in dieser Metrik den Stanley-Controller.

KPI	Stanley (Simulink)	MPC (conv.)	MPC (AI)
Max abs CTE [cm]	67.8	38.5	29.9

Abbildung 19: Geringster lateraler Versatzfehler für AI MPC im Vergleich zum konventionellen MPC

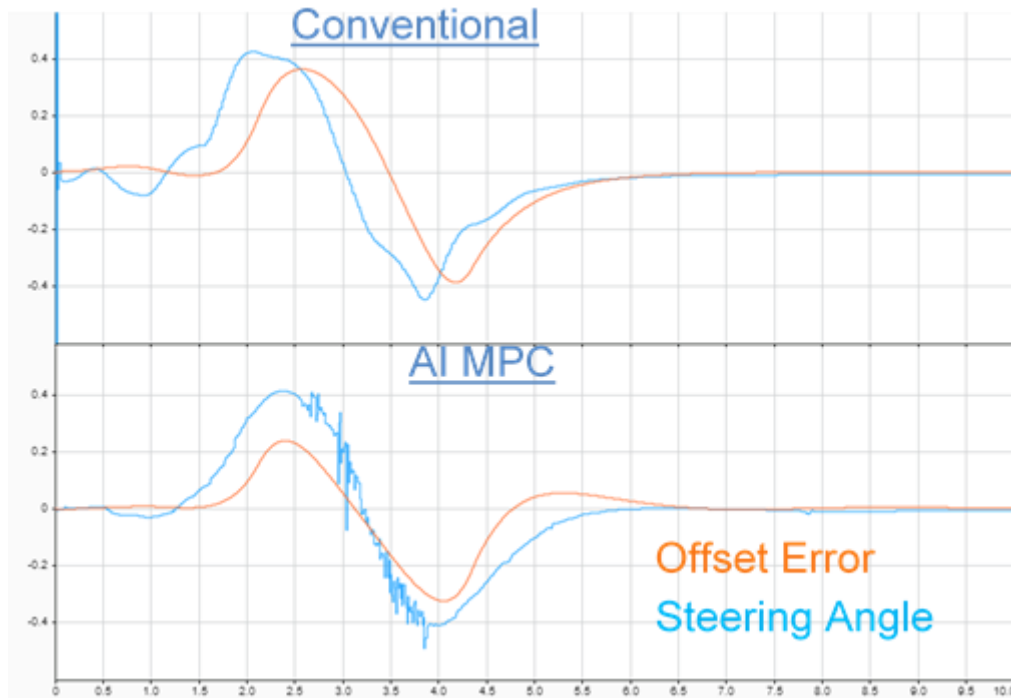


Abbildung 20: Vergleich konventioneller MPC und AI-gestützter MPC für Spurwechsel

2.2.3.3 AP3.3 KI-basierte Energie-optimale Längs-Trajektorieplanung

Unter Berücksichtigung des Umfangs und der bereits vorhandenen Ergebnisse anderer Arbeitspakete (APs) wurde vom Projekt-Team ein hybrider Ansatz entwickelt, der den klassischen Regelalgorithmus mit einer KI-Erweiterung kombiniert (Abbildung 21).

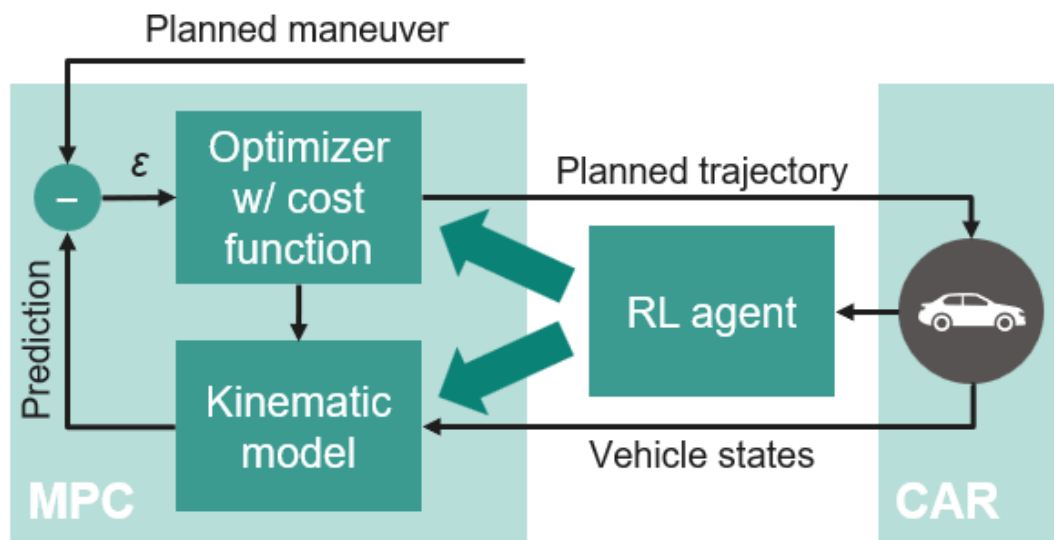


Abbildung 21: Diagramm des KI-basierten MPC

In diesem hybriden Ansatz wurde eine modellprädiktive Regelung (MPC) verwendet, um die geplante Trajektorie zu berechnen. Die KI-Erweiterung der MPC durfte nur kleine Anpassungen an den Optimierungsgewichten oder Parametern des kinematischen Modells

Projekt: **EEmotion** / Individueller Schlussbericht

der MPC vornehmen. Dies ermöglichte eine höhere Anpassungsfähigkeit, da die KI-Erweiterung in der Lage war, nichtlineare Verhaltensweisen des Systems zu erfassen, die möglicherweise nicht vom kinematischen System der MPC abgedeckt wurden. Wie später gezeigt wird, kann durch eine geeignete Zielfunktion die KI-Ergänzung sogar zur Optimierung der Energieeffizienz des Planers eingesetzt werden.

Der Reinforcement-Learning-Agent (RL) erlaubte, die MPC-Parameter für eine optimale Trajektorienplanung anzupassen, wodurch eine erneute Abstimmung für jedes neue Szenario überflüssig wurde. Die MPC lieferte die Trajektorie als eine Reihe von Punkten über den Vorhersagehorizont mit entsprechenden Koordinaten, Zeiten und Geschwindigkeiten. Das Ziel des RL-Agenten war es, dass diese Trajektorie zu einem möglichst geringen Kraftstoffverbrauch führte.

Die Aktion des Agenten wurde auf verschiedene MPC-Nebenbedingungen oder -parameter angewendet, einschließlich der Optimierung des kinematischen Modells, des Abstands zum vorausfahrenden Fahrzeugs in den Nebenbedingungen der Optimierung, der Gewichte, der Ausgabewerte und der modifizierten Variablen Gewichte. Die vielversprechendste Maßnahme in Bezug auf die longitudinale Energieeffizienz bestand darin, den Abstand zum vorausfahrenden Fahrzeug zu modifizieren, der als Nebenbedingung für die zukünftige Position des Ego-Fahrzeugs definiert war. Der RL-Agent passte den konstanten Teil des Folgeabstands an, während der variable Teil relativ klein gehalten wurde.

Zum Training des RL-Agenten und zur Bewertung des Konzepts wurde der in AP6.3 definierte Satz von Simulationsszenarien verwendet. Für die Bewertung der Energieeffizienz wurde ein spezieller Satz von Szenarien erstellt, der darauf abzielte, die longitudinalen Effekte zu verstärken. In diesen Szenarien wurde ein Stauaufbau mit Stop-and-Go-Verkehr simuliert. Der in AP6.3 definierte Szenariengenerator wurde verwendet, um die Szenarien in Bezug auf die Anfangsgeschwindigkeiten des Ego-Fahrzeugs und des vorausfahrenden Fahrzeugs sowie deren jeweilige Sollgeschwindigkeiten (ACC-Einstellung) zu parametrisieren (Abbildung 22).




Abbildung 22: Geschwindigkeitsprofil des Ego-Fahrzeugs und des führenden Fahrzeugs in einem Szenario mit Stauaufbau

Die Energieeffizienz wurde in zwei Fällen bewertet. Erstens wurde die nichtlineare MPC, die von der UzL entwickelt wurde und Energietermine enthält, durch den RL-Agenten ergänzt. Die Kostenfunktion des Agenten wurde so gestaltet, dass sie den Kraftstoffverbrauch und die Zielverfolgung kombiniert, um zu verhindern, dass das Ego-Fahrzeug zu langsam fährt oder vollständig stoppt. Der Effizienzgewinn durch den Einsatz des Agenten erreichte bis zu 3 %.

Projekt: **EEmotion** / Individueller Schlussbericht

Im zweiten bewerteten Szenario wurde die MPC vereinfacht, wobei alle Energieterme deaktiviert wurden. Die Kostenfunktion des RL-Agenten kombinierte erneut die Effizienz- und Zielverfolgungsterme. Dadurch stieg der Effizienzgewinn auf bis zu 10 %.

In beiden oben genannten Fällen wurde die Leistung auf einer Strecke fester Länge anhand eines festen Satzes von Szenarioparametern bewertet. Der geringere Kraftstoffverbrauch ging mit einer Verlängerung der Reisezeit einher.

Der Einsatz der nichtlinearen MPC erwies sich als unpraktikabel. In einem gemeinsamen Workshop zwischen IFAG und UzL wurde die MPC erfolgreich auf das Ziel-AURIX-Board implementiert, allerdings auf Kosten einer erheblichen Reduktion ihrer Parameter.

2.2.3.4 AP3.4 KI-basierte kombinierte Längs- und Quer-Trajektorieplanung für Auto-Piloten

Basierend auf den Erkenntnissen aus AP3.3 wurde eine neue adaptive MPC für die Zwecke der kombinierten longitudinalen und lateralen Trajektorienplanung implementiert. Eine adaptive MPC ist in Bezug auf die Rechenkomplexität viel einfacher als eine nichtlineare MPC, bietet jedoch nicht die gleiche Leistungsfähigkeit. Dies kann durch den Einsatz eines RL-Agenten und einer gut gestalteten Kostenfunktion kompensiert werden.

Die Kostenfunktion kann verschiedene Ziele widerspiegeln. Im Gegensatz zu AP3.3 wurde die Kostenfunktion in diesem Fall so entworfen, dass die Nachführgenauigkeit des Systems maximiert wurde, bestehend aus dem adaptiven MPC-Planer und dem von ZF bereitgestellten Basiskontroller. Darüber hinaus wurden hohe Werte des lateralen Rucks proportional bestraft, was zu einer geschmeidigeren Fahrzeugbewegung führte und potenziell den Fahrkomfort erhöhte.

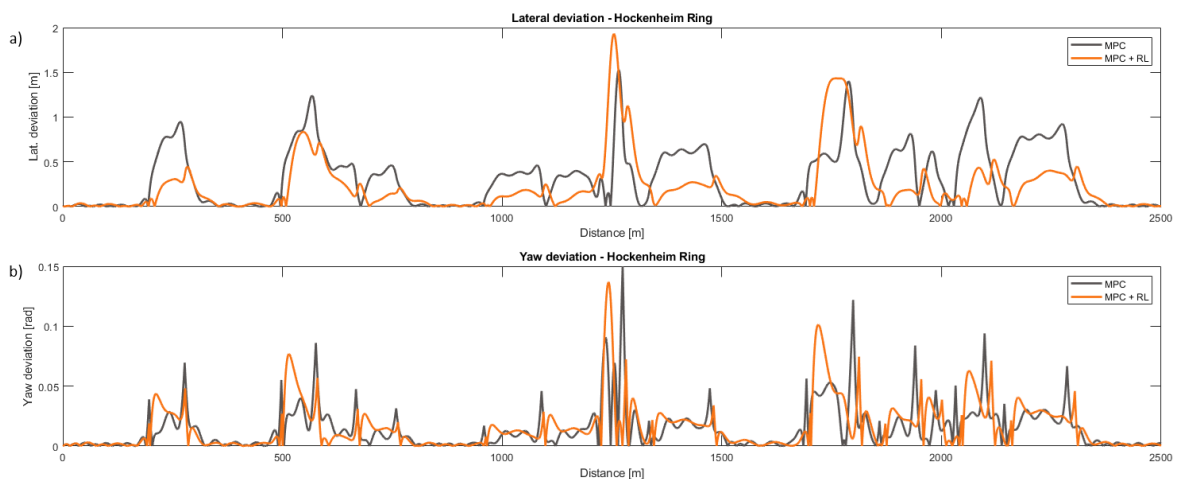


Abbildung 23: Vergleich der a) lateralen und b) Gierwinkel-Abweichungen entlang der Hockenheim-Rennstrecke zur Bewertung der Verfolgungsgenauigkeit von Basis-MPC und KI-gestütztem MPC

Wie in Abbildung 23 zu sehen ist, kann der RL-Agent die Amplitude und die Anzahl der Abweichungsspitzen im Vergleich zum reinen adaptiven MPC reduzieren. Die Fahrzeit der Runde unterschied sich nicht signifikant.

Ein Leistungsvergleich mit dem von UzL bereitgestellten nichtlinearen MPC konnte nicht durchgeführt werden, da der ODD des nichtlinearen MPC auf die longitudinale Planung beschränkt ist.

2.2.3.5 Konzeptentwicklung zur Überwachung und Absicherung der KI-basierten Module

Das Infineon-Projektteam orientierte sich bei der Entwicklung eines Absicherungskonzepts für die KI-basierten Module am Software-Entwicklungsprozess nach dem V-Modell (siehe Abbildung 24). Hierbei wurde konkret nur die linke Modellseite zur Spezifikation und Implementierung auf System- und Komponentenebene unter Bezugnahme der drei Industriestandards ISO 26262, ISO 21448 und ISO 8800 betrachtet.

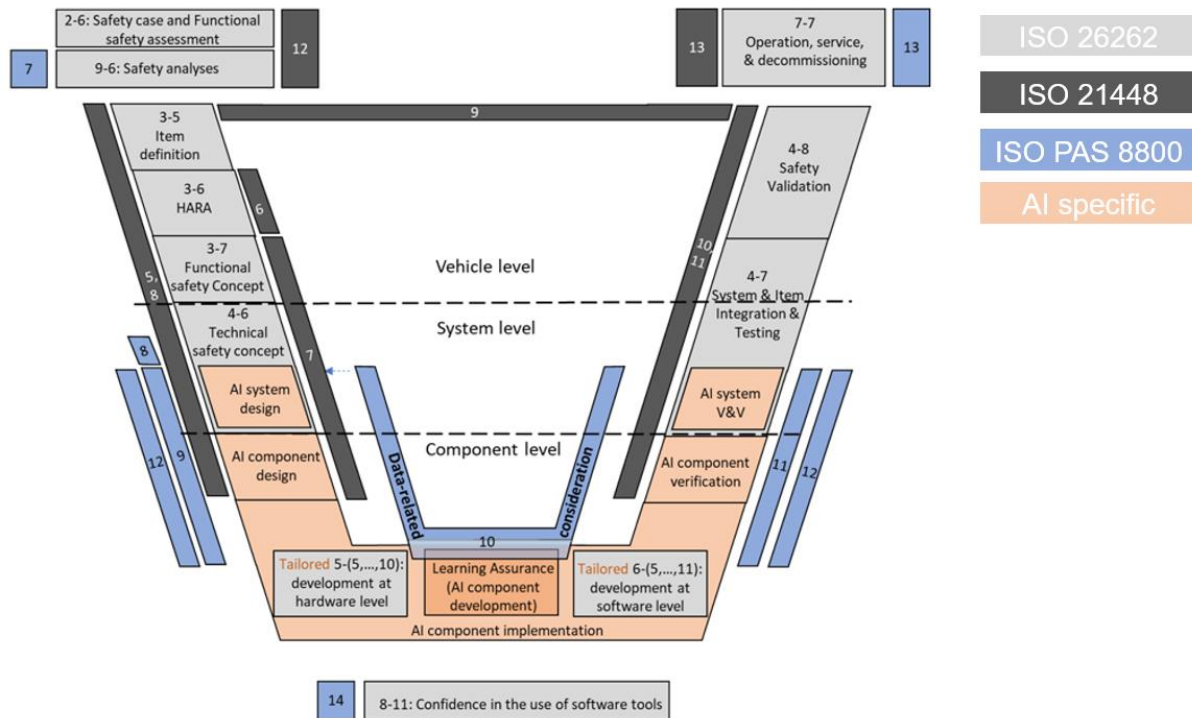


Abbildung 24: Entwicklungsprozess für sicherheitskritische KI-Anwendungen

2.2.4 AP4 KI-SW – Verfahren, Methodik, eingebettete Algorithmen

Das Ziel im AP4 war die Entwicklung und Optimierung von KI-Methoden für eingebettete Systeme im sicherheitskritischen Umfeld von Fahrzeugen. Das Infineon-Team fokussierte sich darauf, die Leistungsfähigkeit der Funktionen/Regler zu erhöhen und die Kosten für die Funktionsentwicklung und Parametrierung zu senken. Die Echtzeitfähigkeit der KI-Algorithmen und die Sicherheitsanforderungen an die KI-Methoden und das Gesamtsystem waren zusätzliche Herausforderungen für das Team, da die Methoden über klassische KI-Verfahren für die Fahrzeugtechnik hinausgingen. Die Aufgabe bestand darin, neue KI-Methoden für Planungs- und Regelungs-Funktionen sicherheitskritischer Anwendungen zu entwickeln, um die Kosten für Funktionsentwicklung und Parametrierung zu senken. Durch die Kombination von Komponenten klassischer Regelungstechnik mit KI-Algorithmen und -Verfahren konnten die Infineon-Entwickler die Leistungsfähigkeit existierender Architekturen und Verfahren signifikant steigern. Gleichzeitig gelang es ihnen, die Anforderungen an Echtzeitfähigkeit, Dateneffizienz und Sicherheit zu optimieren.

2.2.4.1 Entwicklung einer Architektur zur Kombination klassischer Regelung und KI-Komponenten

Die Infineon-Mitarbeiter untersuchten Model-based Reinforcement Learning als alternative Methode zur effizienten Einstellung von Parametern oder Teilkomponenten konventioneller Regler und Verfahren im Vergleich zu allgemeinen überwach-lernenden KI-Modellen und Architekturen wie Deep Neural Networks (DNN).

Die Entwickler brachten außerdem ihre Expertise aus dem Bereich der hardware-nahen Algorithmen-Entwicklung in das Arbeitspaket ein und untersuchten, welche der KI-Algorithmen sich für die Integration in ein Embedded-System eigneten. Sie analysierten die mathematischen Topologien der KI-Algorithmen und untersuchten deren Umsetzbarkeit in einem Embedded-System. Im Gegensatz zu cloud-basierten KI-Systemen sind Embedded-KI-Systeme bezüglich Rechenleistung und Speicherverfügbarkeit limitiert. Deshalb erarbeitete das Infineon-Team im Rahmen von AP4 KI-Methoden im Hinblick auf die Seriennutzung einer Embedded-Plattform.

Um den optimalen Einsatz von Reinforcement Learning zu ermitteln, entwarfen die Infineon-Entwickler eine dreistufige Architektur mit jeweils unterschiedlichen Ansatzpunkten von RL auf einen gegebenen konventionellen PID-Regler.

Im ersten Ansatz A wurde der PID-Regler komplett durch einen Reinforcement Learning Agenten ersetzt.

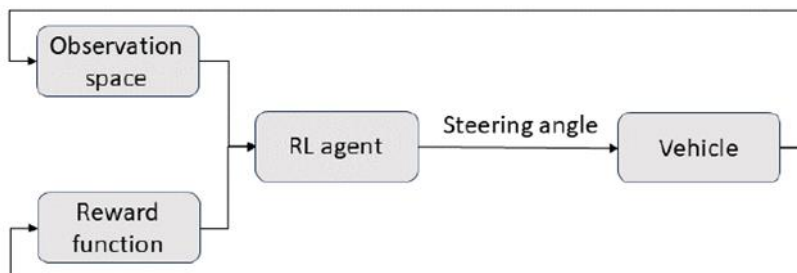


Abbildung 25: Ansatz A: Reinforcement Learning basierter Trajektorienregler

Im zweiten Ansatz B sollte ein zusätzlich zum PID-Regler eingesetzter RL-basierter Regler versuchen, den bestehenden Regelungsfehler durch ein Regelungsoffset zu kompensieren.

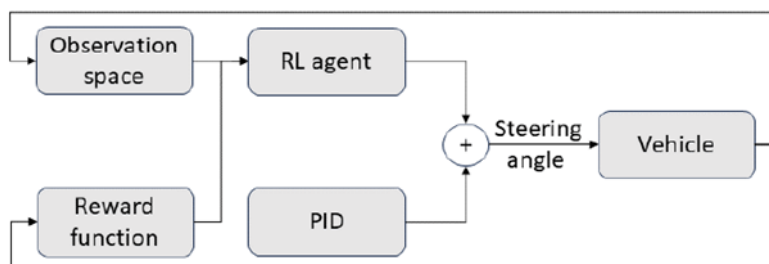


Abbildung 26: Ansatz B: RL-basierter Trajektorienregler als Ergänzung zum Basisregler

Im dritten Ansatz C wiederum wurde ein zusätzlicher RL-Agent verwendet, um die Parameterwerte des konventionellen PID-Reglers zur Laufzeit anzupassen.




Abbildung 27: Ansatz C: RL-basierte Parametrisierung des Basisreglers

2.2.4.2 Anwenden von KI-Verfahren

Die Infineon-Entwickler untersuchten drei verschiedene Ansätze, um das Problem der seitlichen Steuerung eines Fahrzeugs anzugehen. Zunächst verwendeten sie einen reinen Deep Reinforcement Learning (DRL)-Algorithmus wie Twin Delayed Deep Deterministic Policy Gradient (TD3) oder Soft Actor-Critic (SAC) als alleinigen Regler (Ansatz A (Abbildung 25)). Dieser Ansatz ermöglichte zwar eine gute Verallgemeinerung auf neue Straßen und Situationen, aber es fehlte die übliche Regelungs-Stabilität wie bei klassischen Regelungsverfahren. Daher kombinierten sie einen Proportional-Integral-Derivative (PID)-Regler mit RL in zwei verschiedenen Konfigurationen.

In der zweiten Konfiguration B wurde der RL-Algorithmus verwendet, um den aus dem PID resultierenden Fehler zu kompensieren. Der PID regulierte auch den RL-Suchraum, um mehr Stabilität zu erreichen (siehe Abbildung 26). Der zweite Aufbau beruhte auf PID als einzigem Regler. Das Infineon-Team verwendete jedoch RL als adaptiven und Online-Auswahlmechanismus für die PID-Verstärkungen (Abbildung 27).

Wie Abbildung 28 zeigt, bewiesen die Entwickler, dass die Kombination von DRL mit einem klassischen Controller, die Verfahren mit nur einem konventionellen PID-Regler bzw. mit nur einem RL-basierten Regler in der Genauigkeit (Cross Track Error; CTE) (Heading Angle Error; HAE) übertreffen. Zudem können höhere Geschwindigkeiten (mehr als 120 km/h) sicher erreicht werden, obwohl die Ansätze auf 80 km/h als Höchstgeschwindigkeit trainiert wurden. Der Rest-RL-Ansatz (Ansatz B) erreicht unter allen Reglern den besten Fahrkomfort mit geringerem Spurüberschreitungsfehler als PID- und reine RL-Regler. Wenn jedoch das Verfolgen der Trajektorie mit einem minimalen Fehler die Hauptanforderung ist, ist der RL-basierte PID (Ansatz C) die optimale Lösung.

	RL-based PID	Residual RL	Pure RL	PID
Max. CTE [m]	0.1438	0.1726	0.5272	0.2581
Max. HAE [rad]	0.1313	0.1475	0.1538	0.1554
Max. Yaw Acc. [rad/s ²]	2.8999	2.7392	3.3208	4.6729
Avg. CTE [m]	0.0004	-0.0001	-0.0208	0.0003
Avg. HAE [rad]	0.0009	0.0010	0.0010	0.0011
Avg. Yaw Acc. [rad/s ²]	0.0022	-0.0002	-0.0008	0.0017
RMSE CTE [m]	0.0228	0.0352	0.1454	0.0416
RMSE HAE [rad]	0.0172	0.0179	0.0233	0.0197
RMSE Yaw Acc. [rad/s ²]	0.3717	0.3166	0.3734	0.4404
Lap time [s]	1074.4	1058.2	1071.8	1076.7

Abbildung 28: Bewertung der drei Ansätze für eine simulierte Testfahrt. Der jeweils beste Werte ist hervorgehoben

2.2.4.3 Entwicklung von Sicherheitsgarantien

Im Rahmen der Bearbeitung von AP4.3 gingen die Entwickler zunächst die Definition von Sicherheits-Anforderungen und -Kriterien an die KI-Komponenten und die Gesamtarchitektur aus AP4.1 und AP4.2 an. Auf Basis dieser Anforderungen entwickelten sie Methoden zur Validierung der KI-Komponenten. Es schlossen sich Analysen an, aus denen das Zielverhalten von KI-Komponenten für Experten erklärbar ist („explainable AI“).

Es wurden zwei grundsätzliche Ansätze in Betracht gezogen. Der A-priori-Ansatz erlaubt, Sicherheitsanforderungen und Expertenwissen in den entsprechenden KI-Methoden und Architekturen per Design (a priori) abzubilden und einzubauen, z.B. die Einhaltung von Beschränkungen in puncto Zustand, Eingang oder Stabilitätsforderungen. Dazu wurden Ansätze wie Gauß-Prozessmodelle oder strukturierte neuronale Netze in Betracht gezogen und in Hinblick auf die spezifische Anwendung untersucht. Der A-posteriori-Ansatz bot die Möglichkeit, die Gewährleistung von Sicherheitsanforderungen und die Erklärbarkeit durch dem Training nachgelagerte Analysen (a posteriori) der gelernten Machine-Learning-Modelle sicherzustellen.

2.2.4.4 Dateneffiziente eingebettete Implementierung und Umsetzung für Serienentwicklung

Der verwendete RL-Aktor verbrauchte weniger als 68 % des Speicherplatzes der Parallel Processing Unit (PPU) des AURIX™-TC4x. Die Ausführungszeit des RL-Aktors für einen Regelungsschritt betrug etwa 0,2 % der maximal zulässigen Ausführungszeit von 10ms. Somit ist der effiziente Einsatz von RL-basierten Verfahren auf Serienprodukten wie dem AURIX™-TC4x möglich (Abbildung 29).

	Pure RL	Residual RL	RL-based PID
Total parameters	21891	21891	22159
Size [KB]	85.5117	85.5117	86.5586
Total cycles	4112	4112	4116
Runtime [μ s]	10.28	10.28	10.29

Abbildung 29: Laufzeit und Speicherverbrauch der RL-basierten Verfahren auf dem AURIX™-TC4x

2.2.5 AP5 KI-Kommunikation – secure und funktional-sicher

Das AP5 „KI-Kommunikation: secure und funktional-sicher“ fokussierte die Interaktion der Systemkomponenten und insbesondere deren Überwachung mit KI-Methoden. Für „AI on the Edge“ basierte Fahrdynamik-Algorithmen im Fahrzeug war eine sichere und verlässliche Kommunikation der einzelnen Aktoren, Sensoren und Steuergeräte ein substanzieller und essenzieller Bestandteil der entsprechend dezentralen intelligenten Systeme.

2.2.5.1 AP5.3 Modellierung Traffic und Präparation Trainingsdaten

Zum Training der getesteten Ansätze des maschinellen Lernens dienten Simulationsdaten verschiedener Fahrscenarien. Die Simulationsumgebung bildete dabei die Software IPG CarMaker (IPG Automotive GmbH) in Kombination mit einem digitalen Zwilling des Testfahrzeugs, implementiert in Simulink (MathWorks Inc.). Die ausgewählten Fahrscenarien definierten dabei die sogenannte Operational Design Domain (ODD), innerhalb derer die entwickelten Methoden des autonomen Fahrens sicher funktionieren sollten. Innerhalb des Konsortiums einigte man sich auf Varianten von Spurwechselszenarien. Die Simulation der definierten Szenarien wurde dabei weitestgehend automatisiert, um auf einfache Weise weite Bereiche der Szenarioparameter wie Anfangs- und Zielgeschwindigkeit oder Länge des Spurwechsels abzusampeln. Um die Generalisierbarkeit der entwickelten Methoden zu testen, wurden Simulationen auf dem Nürburgring verwendet.

Darüber hinaus wurden Methoden zur Injektion synthetischer Anomalien in die Simulationsdaten entwickelt, um Algorithmen zur Anomalieerkennung zu testen. Dabei wurden nicht nur einzelne Punkte der Trajektorie gestört, sondern die Trajektorie als Ganzes, um realistische Fehler in der Trajektorienplanung abzubilden.

2.2.5.2 AP5.4 Analyse, Evaluation und Konzeption von KI-Methodiken, approximative Ausprägung der Modelle

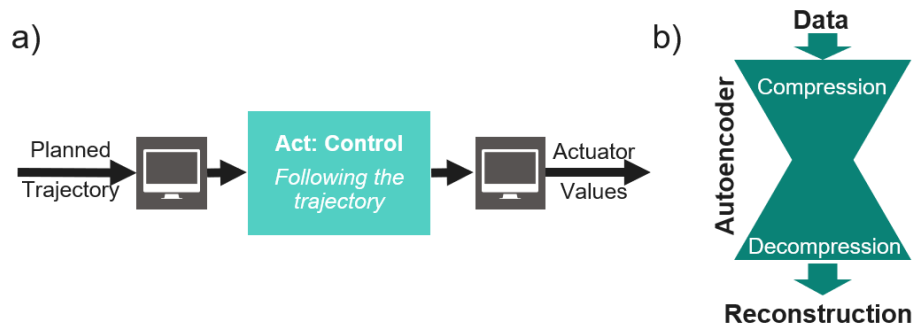


Abbildung 30: Abschlussteil der Berechnungskette des autonomen Fahrens mit Trajektorienregler. Am Ein- und Ausgang des Reglers ist ein Runtime-Monitor zur Überwachung des Datenstroms. b) Flaschenhals-Architektur eines Autoencoder-Netzwerkes zur Anomalieerkennung

Die Entwicklung von Methoden zur Anomalieerkennung auf Seiten von Infineon lagen bei der Überwachung der Netzwerk-Payloaddaten. Zum einen soll diese Überwachung sicherstellen, dass der Output von Regelungsalgorithmen limitiert ist auf sichere Aktuatorwerte. Zum anderen muss sichergestellt sein, dass die vom Trajektorienplaner berechnete Trajektorie vom Regler sicher ausgeführt werden kann. Beides wurde über je einen Runtime-Monitor sowohl an Input, als auch an Output des Trajektorienreglers realisiert (siehe Abbildung 30).

Der Trajektorienregler arbeitete in einem Intervall von 5 ms. Auf dieser Zeitskala und bei typischen Geschwindigkeiten verhält sich die Physik eines Fahrzeuges annähernd linear. Das heißt, anomale Regleroutputs, die deutlich vom linearen Verhalten abweichen, lassen sich mit einfachen, linearen Extrapolationsalgorithmen erkennen. Methoden des maschinellen Lernens boten hier keinen Vorteil, sondern zeigten sogar eine höhere Falsch-Positive-Rate und hatten damit einen negativen Effekt auf die Systemverfügbarkeit bei gleichzeitig hohem Rechenaufwand (siehe Abbildung 31).

Methodik	F1 Score	Falsch Positiv Rate
KI Ansatz	0.986	0.301
Lineare Extrapolation	0.997	0.057

Abbildung 31: Vergleich statistischer Metriken zur Anomalieerkennung von einem KI-Ansatz mit simpler linearer Extrapolation für den Output des Trajektorienreglers

Der Regler-Input umfasste die zu fahrende Trajektorie, die geplanten x&y-Positionen, deren Änderung und Krümmung, die Geschwindigkeit sowie die Beschleunigung und zusätzlich die aktuellen Fahrdynamikwerte. Die Daten zeigten teilweise komplexe Zusammenhänge, sodass einfache lineare Modelle nicht in der Lage waren, fehlerhafte Trajektorien sicher zu detektieren. Aus diesem Grund testeten und verglichen die Entwickler verschiedene Methoden des Maschinellen Lernens. Trainings- und Testdaten stammten hierbei wieder aus Simulationen, sowohl der oben beschriebenen ODD als auch des Nürburgringes.

Als Ansatz zur Anomalieerkennung diente ein rekonstruktionsbasiertes Modell, ein sogenannter Autoencoder. Das Prinzip eines Autoencoders besteht darin, dass er die

Projekt: **EEmotion** / Individueller Schlussbericht

Inputdaten komprimiert und wieder rekonstruiert und dadurch deren essenzielle Charakteristiken lernt (siehe Abbildung 31).

Das Training basierte dabei ausschliesslich auf anomaliefreien Daten. Anomalien weichen von den gelernten Charakteristiken ab, sodass der gelernte Kompressions-Rekonstruktionsansatz zu einem grossen Rekonstruktionsfehler führt. Anhand des Rekonstruktionsfehlers können Inputdaten klassifiziert werden. Als Vergleich zu den auf nichtlinearen neuronalen Netzen basierenden Autoencodern wurde als lineares Basismodell die Hauptkomponentenanalyse (Principal component analysis, PCA) verwendet.

Zusätzlich zum bereits getesteten Autoencoder wurde auch ein Variational Autoencoder getestet. Der Unterschied zwischen beiden Ansätzen bestand darin, dass der Variational Autoencoder als stochastisches Modell durch wiederholtes Sampling ein robusteres Ergebnis erzielte. Der Nachteil lag allerdings in einem höherem Berechnungsaufwand.

2.2.5.3 AP5.5 Zielverteilungs-Inferenzmodelle

Unter den Projektpartnern wurde entschieden, dass die Anomalieerkennung entgegen früherer Planungen ebenfalls im Testfahrzeug implementiert werden sollte. Der notwendige Integrationsaufwand verhinderte dabei die Weiterentwicklung der algorithmischen Methoden.

Vonseiten Infineons wurde der favorisierte Autoencoder in eine eingebettete Anwendung für den AURIX™ TC4xx integriert. Diese Anwendung vermittelte die Anbindung an das Kommunikationsnetz des Fahrzeugs via 10BASE-T1S, sodass die entsprechenden Inputdaten an den Autoencoder übergeben und das Ergebnis weiterverarbeitet werden konnte. Dabei wurde die Ausführung des Autoencoders auf der PPU implementiert um eine minimale Laufzeit sicherzustellen (Abbildung 32). Die ermittelten Werte lagen sowohl beim Speicherbedarf als auch bei der Laufzeit deutlich unter den Anforderungen und erlaubten somit ein Deployment im Testfahrzeug.

Modellgrösse	Speicherbedarf	Laufzeit
18 879 Parameter	~40 kb	~12µs

Abbildung 32: Grösse, Speicherbedarf und Laufzeit des favorisierten einfachen Autoencoder-Modells auf der PPU des AURIX™ TC4xx. Die Laufzeit wurde mit dem nSIM-Hardware-Simulator von Synopsis bestimmt

Das eigentliche Deployment der Anwendung zur Anomalieerkennung erfolgte beim Projektpartner ZF in Friedrichshafen. Die auf Seiten Infineons entwickelte Anwendung wurde bei ZF auf einem Hardware-in-the-Loop (HIL) System getestet und final angepasst um die Funktionalität sicherzustellen. Im Anschluss erfolgte die Integration im Testfahrzeug.

Zum Testen des Algorithmus stellte ZF eine Methode zur Verfügung, die einen definierten lateralen Fehler in die Positionsdaten des Fahrzeugs injizierte. Diese Anomalien konnten vom entwickelten Algorithmus zuverlässig erkannt werden (siehe Abbildung 33: Screenshot des zeitlichen Verlaufes des Rekonstruktionsfehlers (oben) und der binären Klassifizierung (unten). Das grüne Rechteck markiert die Detektion einer injizierten Anomalie

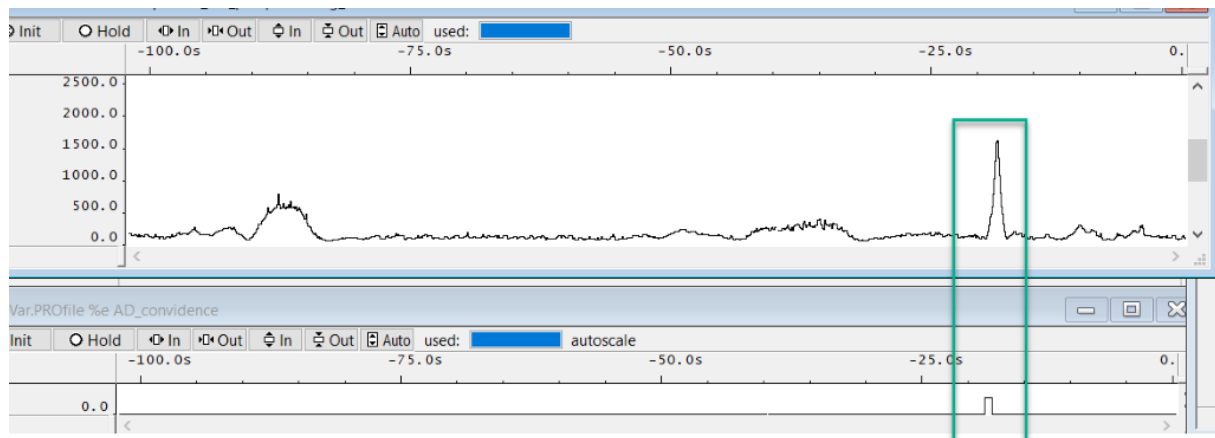


Abbildung 33: Screenshot des zeitlichen Verlaufes des Rekonstruktionsfehlers (oben) und der binären Klassifizierung (unten). Das grüne Rechteck markiert die Detektion einer injizierten Anomalie

2.2.5.4 AP5.6 Performance-Analyse und Validierung

Die Bewertung und Auswahl der drei getesteten Methoden erfolgte anhand von statistischen Metriken für die binäre Klassifikation. Die Klassifizierung der Inputdaten erfolgte basierend auf deren Rekonstruktionsfehlern. Da das Training aller Modelle auf defektfreien Daten beruhte, ist der Rekonstruktionsfehler für defektbehaftete Daten wie erwartet bei allen Methoden deutlich höher als bei defektfreien Daten (siehe Abbildung 34: Verteilung des Rekonstruktionsfehlers für die drei getesteten Modell-Architekturen: Hauptkomponentenanalyse als Baseline, einfacher Autoencoder und Variational-Autoencoder. Verteilungen für anomalielfreie (clean) und anomalieliebhaftete (defect) Testdaten

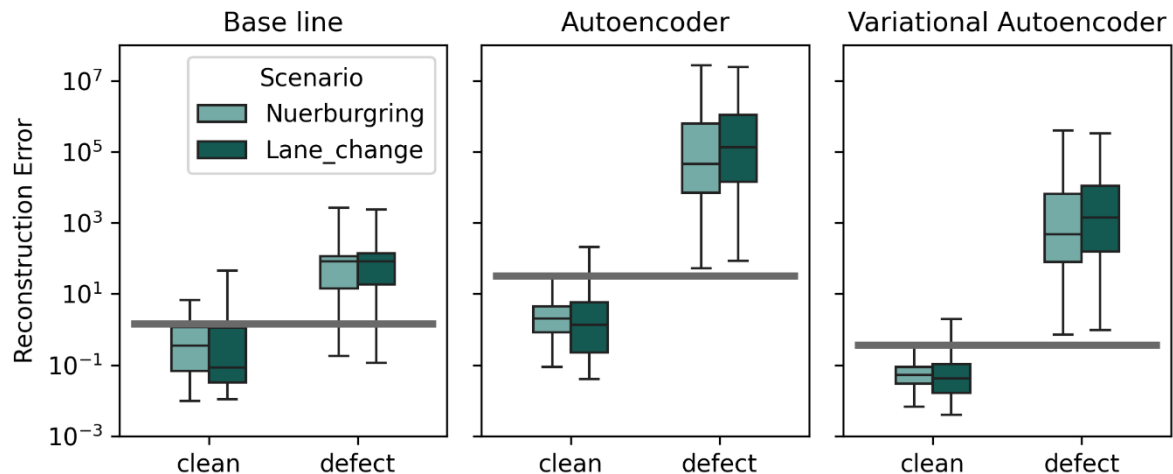


Abbildung 34: Verteilung des Rekonstruktionsfehlers für die drei getesteten Modell-Architekturen: Hauptkomponentenanalyse als Baseline, einfacher Autoencoder und Variational-Autoencoder. Verteilungen für anomaliefreie (clean) und anomaliebehaftete (defect) Testdaten

Die getesteten nichtlinearen, auf neuronalen Netzen basierenden Methoden, Autoencoder und Variational Autoencoder lieferten hohe Erkennungsraten gemessen mittels F1 Score. Das lineare Basis-Modell zeigte eine deutlich niedrigere Erkennungsrate bei gleichzeitig höherer Falschpositivrate. Der Autoencoder bot den Vorteil einer sehr guten Anomalieerkennung bei gleichzeitig hoher Systemverfügbarkeit durch wenige Falschpositive (siehe Abbildung 35). Der Variational Autoencoder zeigte keine signifikant höhere Erkennungsrate als der einfache Autoencoder und rechtfertigte somit nicht den höheren Rechenaufwand für eine Anwendung im Testfahrzeug.

Modell	F1 Train	F1 Gen	FPR Train	FPR Gen	FNR Train	FNR Gen
Baseline	0.945	0.934	0.1390	0.1840	0.0723	0.0701
Autoencoder	0.995	0.984	0.0087	0.0794	0.0082	0.0062
Variational Autoencoder	0.996	0.983	0.0091	0.0902	0.0058	0.0045

Abbildung 35: Statistische Metriken zur Anomalieerkennung der getesteten Methoden - Daten des Trainingszenarios Nürburgring (Train), Daten der Spurwechselszenarien, als Test der Generalisierung (Gen)

Als Test der Generalisierbarkeit des entwickelten Algorithmus wurden als Inputdaten Simulationen von Abschnitten des Nürburgringes bei unterschiedlichen Geschwindigkeiten verwendet. Auf Grund der Vielfältigkeit des Nürburgringes sind in diesen Daten Fahrsituationen enthalten, die sowohl innerhalb, als auch ausserhalb der Trainingsdaten und damit der Operational Design Domain (ODD) liegen.

Eine wichtige Erkenntnis war, dass für eine sichere Erkennung von Anomalien die Trainingsdaten eine hinreichende Variabilität aufweisen mussten. Ein Anomaliedetektor, der ausschließlich auf Daten von Spurwechselszenarien trainiert ist, kann nicht zu komplexeren Daten wie denen des Nürburgringes generalisieren. Im umgekehrten Fall eines Modells, das auf Daten des Nürburgringes trainiert ist, funktioniert die Generalisierung zu den Spurwechselszenarien sehr gut. Erkennbar ist dies gut an der vergleichbaren Verteilung der

Projekt: **EEmotion** / Individueller Schlussbericht

Rekonstruktionsfehler für beide Fahrscenarien. (Abbildung 34: Verteilung des Rekonstruktionsfehlers für die drei getesteten Modell-Architekturen: Hauptkomponentenanalyse als Baseline, einfacher Autoencoder und Variational-Autoencoder. Verteilungen für anomaliefreie (clean) und anomaliebehaftete (defect) Testdaten

Die Metriken zur Bewertung der Modelle zeigen in diesem Fall keinen großen Unterschied zwischen Trainings- und Generalisierungsszenario und bieten damit ein quantitatives Maß für die Generalisierbarkeit der Methoden (Abbildung 35).

2.2.6 AP6 Simulation, Data Handling, KI-Training

2.2.6.1 AP6.1 Definition der Anforderungen an die Simulation, Algorithmen und Virtualisierung von Fahrwerks-Entwicklungsfunktionen auf der Grundlage der verschiedenen Anwendungsfälle

Das Ziel von AP6 war es, eine Simulationsumgebung zu entwickeln, die aus CarMaker und Matlab bestand und zum Trainieren, Testen und Validieren der vorgeschlagenen Algorithmen diente. Um dieses Ziel zu erreichen, begannen die Entwickler mit der Definition der Operational Design Domain (ODD), d.h. der Betriebsbedingungen, unter denen ein bestimmtes Fahrautomatisierungssystem speziell funktionieren soll. In diesem Fall wurde ein ODD wie folgt definiert: geradeaus fahren, auf einer mehrspurigen Straße, innerstädtisches Szenario, keine Kreuzungen. Entsprechend dieser Definition wurden eine Reihe von Basisszenarien entwickelt, die als Grundlage für die Erstellung von Trainings-, Test- und Validierungsszenarien dienten.

2.2.6.2 AP6.2 Definition verschiedener Konzepte für Simulation und Virtualisierung

Wie bereits erwähnt, wurde zunächst eine ODD definiert. Auf der Grundlage dieser ODD definierte das Team eine Reihe von Basisszenarien (siehe Kapitel AP6.3 und AP6.4). Die Basisszenarien wurden in der CarMaker-Umgebung modelliert und in einem xml-ähnlichen Format dargestellt. Daher konnten sie leicht verändert werden. Im nächsten Schritt wurde ein Skript in Matlab erstellt, das die Basisszenarien modifizierte und synthetische Szenarien erzeugte.

2.2.6.3 AP6.3 Durchführung von Simulationen für die Entwicklung von Fahrwerkssystemen

Zunächst wurden die Daten in der Simulationsumgebung gesammelt. Hierzu entwickelte das Team einen Szenario-Generator, der es ermöglichte, synthetische Daten für das weitere Training, für Tests und für die Validierung zu erzeugen.

Für die Entwicklung des Szenario-Generators wählten die Projektmitarbeiter einen von Menzel et. al. vorgeschlagenen Ansatz, wonach sie eine Reihe von funktionalen, logischen und konkreten Szenarien entwickelten. Funktionale Szenarien bildeten die abstrakteste Ebene der Szenariendarstellung. Sie wurden in der Konzeptionsphase der ISO-Norm 26262 für die

Projekt: **EEmotion** / Individueller Schlussbericht

Definition von Gegenständen sowie für die Gefahrenanalyse und Risikobewertung verwendet. Sie waren sprachlich aufbereitet, damit menschliche Experten die vorhandenen Szenarien leicht verstehen, darüber diskutieren und neue Szenarien erstellen können. Das funktionale Szenario umfasste Betriebsszenarien auf einer semantischen Ebene. Die Entitäten der Domäne und die Beziehungen zwischen diesen Entitäten wurden mit Hilfe einer linguistischen Szenariennotation beschrieben. Die Szenarien waren konsistent. Das Vokabular, das für die Beschreibung der funktionalen Szenarien verwendet wurde, war spezifisch für den Anwendungsfall bestimmt, und die Domäne und konnte verschiedene Detailstufen aufweisen. Grundsätzlich ist ein funktionales Szenario auf der semantischen Ebene eine linguistische und konsistente Beschreibung von Entitäten (Fahrzeug, Verkehrsteilnehmer etc.) und Interaktionen zwischen ihnen.

Logische Szenarien stellen eine detaillierte Darstellung funktionaler Szenarien mit Hilfe von Zustandsraumvariablen dar. Diese Zustandsraumvariablen beschreiben die Entitäten und die Beziehungen zwischen diesen Entitäten. Logische Szenarien können verwendet werden, um während der Systementwicklungsphase Anforderungen für das Objekt abzuleiten und darzustellen. Zu diesem Zweck beschreiben logische Szenarien die Wertebereiche der Zustandsraumvariablen mithilfe einer formalen Notation. Logische Szenarien umfassen Betriebsszenarien auf einer Zustandsraumebene. Sie stellen die Entitäten und die Beziehungen zwischen diesen Entitäten mit Hilfe von Parameterbereichen im Zustandsraum dar. Die Parameterbereiche können optional mit Wahrscheinlichkeitsverteilungen angegeben werden. Außerdem können die Beziehungen zwischen den Parameterbereichen optional mit Hilfe von Korrelationen oder numerischen Bedingungen angegeben werden. Ein logisches Szenario enthält eine formale Notation des Szenarios.

Konkrete Szenarien beschreiben die Entitäten und die Beziehungen für diese Entitäten anhand bestimmter Parameter im Zustandsraum. Jedes logische Szenario kann in ein konkretes Szenario umgewandelt werden, indem ein konkreter Wert aus einem Parameterbereich ausgewählt wird. Konkrete Szenarien können als Grundlage für die Erstellung von Testfällen verwendet werden. Konkrete Szenarien bilden Betriebsszenarien auf der Ebene des Zustandsraums eindeutig ab. Sie stellen Entitäten und die Beziehungen zwischen diesen Entitäten mit Hilfe von konkreten Werten für jeden Parameter im Zustandsraum dar. Die konzeptionelle Sichtweise auf funktionale, logische und konkrete Szenarien ist in der folgenden Tabelle dargestellt (Abbildung 36).

Funktionale Szenarien	Logische Szenarien	Konkrete Szenarien
<u>Beschreibung des Szenarios:</u> Das Ego-Fahrzeug wechselt die Fahrspur und stößt mit einem Fahrzeug auf der Nachbarspur zusammen, das langsamer fährt,	<u>Beschreibung des Szenarios:</u> Ausgangsposition [0; 200] m Ausgangsgeschwindigkeit [0; 50] km/h Länge des Spurwechsels [10; 40] m	<u>Beschreibung des Szenarios:</u> Anfangsposition [100] m Anfangsgeschwindigkeit [30] km/h Länge des Spurwechsels [20] m Matlab-Skript, das die Parameter zufällig abtastet.

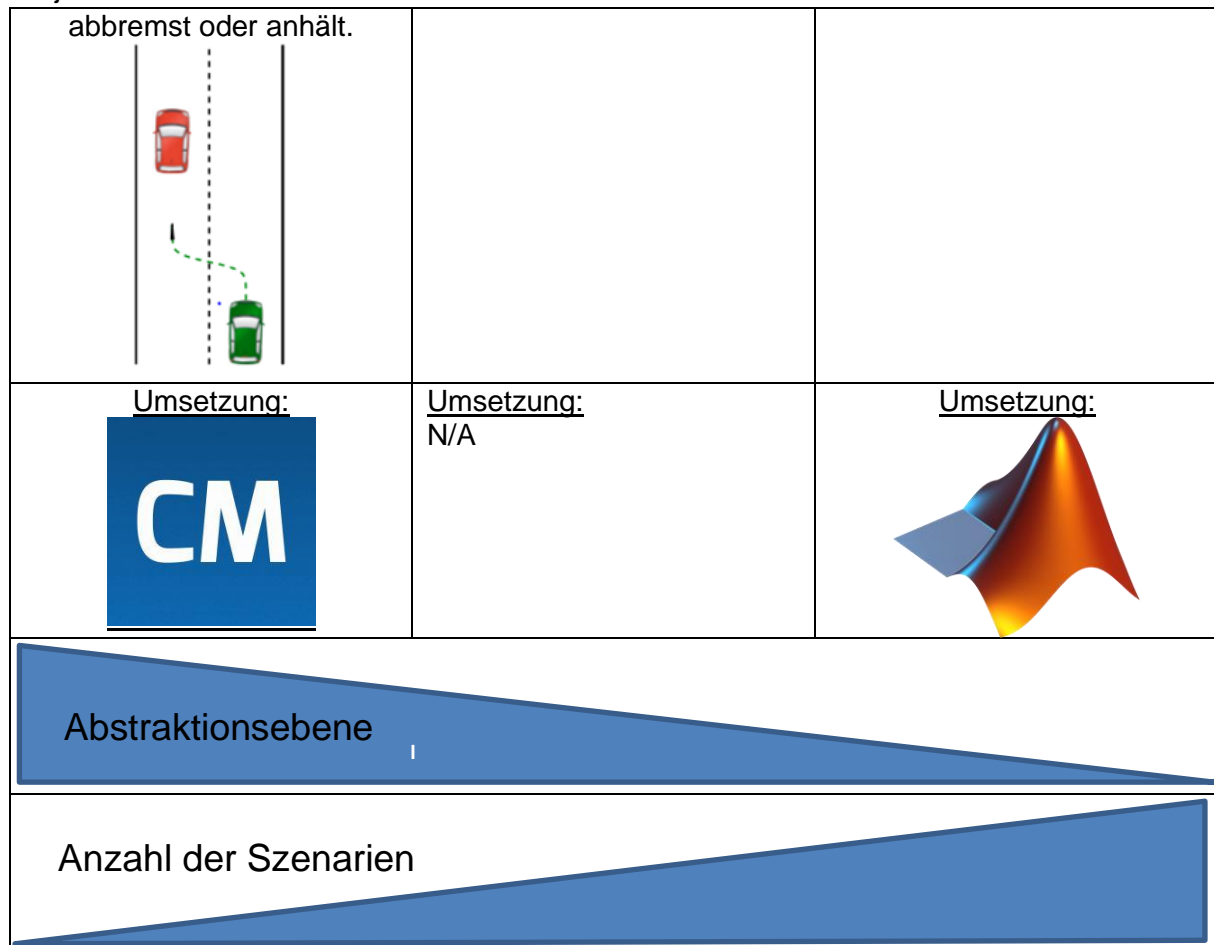


Abbildung 36: Konzeptionelle Sichtweise auf funktionale, logische und konkrete Szenarien

2.2.6.4 AP6.4 Training, Test und Validierung von KI-basierten Fahrfunktionen

Zusammenfassend wurden eine Reihe von Funktionsszenarien entwickelt (verbale und visuelle Beschreibung). Jedes funktionale Szenario wurde in der Simulationsumgebung CarMaker implementiert. Jedes in CarMaker implementierte Szenario bildete die Grundlage für logische und konkrete Szenarien. Im nächsten Schritt wurden die Parameter und die Bereiche bestimmt, die für das jeweilige Szenario relevant waren. Schließlich schrieben die Entwickler ein MATLAB-Skript, das die Parameter nach dem Zufallsprinzip auswählte und die Basisszenarien veränderte, um so neue synthetische Szenarien zu erstellen.

2.2.7 AP7 HW/SW-Codesign, Werkzeugumgebung, Integration in ECU, HIL-Test

2.2.7.1 HW/SW-Codesign

Im Rahmen von AP7 bildete das Infineon-Team alle Teilsysteme, wie z.B. die Trajektorien-Planung und -Steuerung, in Matlab/Simulink ab. Eine beispielhafte Implementierung ist in Abbildung 37 zu sehen.

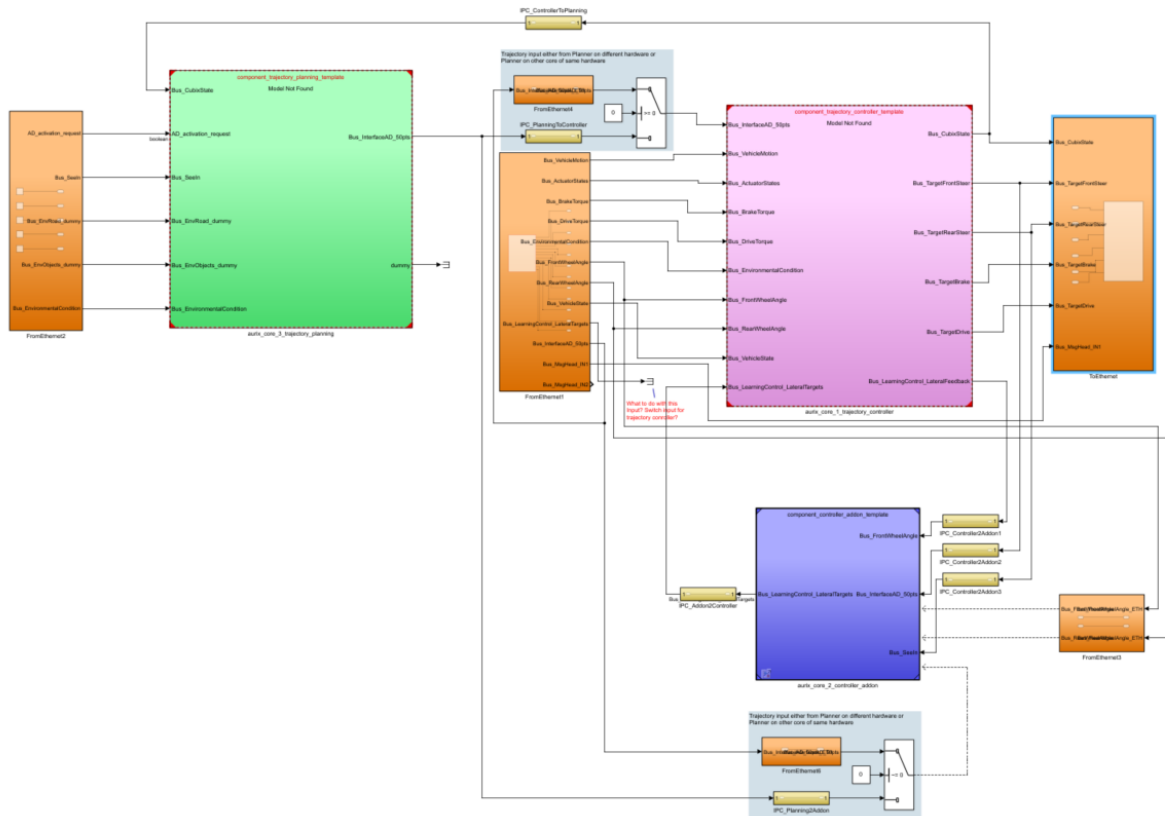


Abbildung 37: Abbildung der Trajektorien-Planung und -Steuerung in Matlab/Simulink

Im nächsten Schritt erstellten die Entwickler aus der Simulink-Simulation einen optimierten C-Code für Aurix TC49x, der die Trajektorien-Planung und -Steuerung implementierte. Der erzeugte C-Code wurde in die Aurix Development Studio Limited-Umgebung mit lwIP- und PPU-Funktionsaufrufen zur Implementierung von KI-Funktionen integriert. Schließlich stellte Infineon einen Projektentwurf zur Verfügung, der als Rückgrat für die Implementierung aller übrigen AI- und Nicht-AI-TP/TC-Ansätze diente.

2.2.7.2 Virtuelle Plattform

Der implementierte Code wurde erfolgreich getestet und auf dem Virtual Hardware Prototype eingesetzt. Das Team testete den entwickelten Controller in der Virtual Hardware Prototype-Umgebung und erzielte dabei dieselben Ergebnisse wie auf der echten Hardware. Die Implementierung eines Virtual Hardware-in-the-Loop-Testaufbaus war nicht möglich, da keine Ethernet-Schnittstelle implementiert war.

2.2.7.3 Tool-Umgebung

Wie bereits in AP6 angedeutet wurde durch das Infineon-Projektteam in Zusammenarbeit mit den Projektpartnern ein ganzheitlicher Simulations- und Entwicklungsansatz vorgeschlagen. Wie in Abbildung 38 dargestellt, deckte die simulationsgetriebene Entwicklung die ersten drei Entwicklungsstufen (Software-in-the-Loop, Virtual-Hardware-in-the-loop und Hardware-in-the-Loop) ab. Durch das verwendete Simulationsframework CarMaker konnten Fahr-Szenarien und fahrzeugrealistische Szenarien generiert und die nötigen Steuersignale der

Projekt: **EEmotion** / Individueller Schlussbericht

Systemapplikation zur Verfügung gestellt werden. Durch eine Rückgabe der berechneten Regelungswerte an die Simulation wurde der Regelkreis geschlossen. Der Vorteil dieses Ansatzes war der nahtlose Übergang und die Absicherung der entwickelten Software über die unterschiedlichen Integrationsstufen. Durch diesen effizienten Entwicklungsprozess wurde die finale Fahrzeugintegration vereinfacht, da weniger Tests innerhalb des Fahrzeugs notwendig waren.

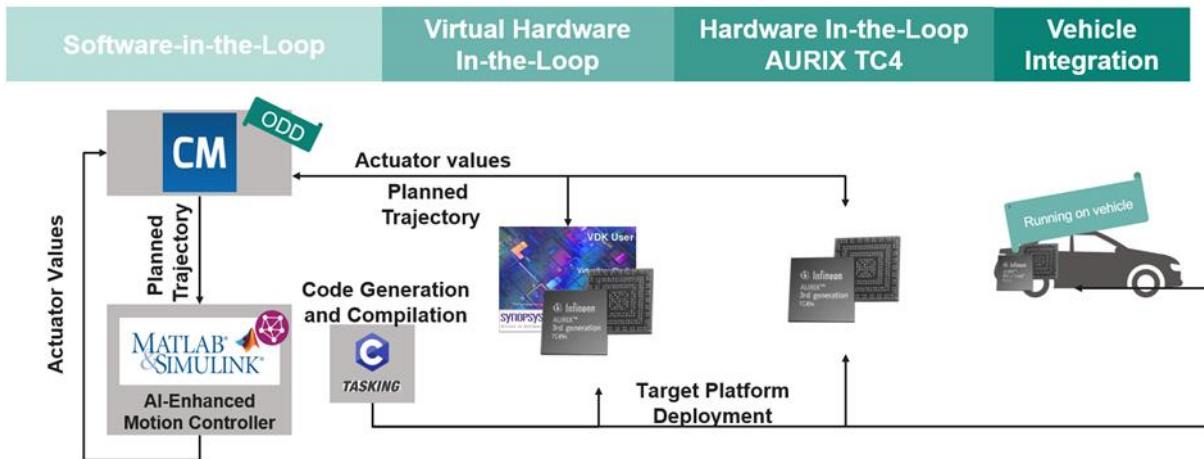


Abbildung 38: Kopplung der Simulationsumgebung mit der Applikations-Entwicklungsumgebung auf den unterschiedlichen Abstraktionsebenen

2.2.7.4 Hardware-Prototyp

Im Projekt wurde der Prototyp der sich in Entwicklung befindlichen nächsten AURIX-Generation verwendet. Dieser Chip zeichnet sich dadurch aus, dass ein auf Echtzeit optimierter Mikrocontroller wie AURIX zum ersten mal mit einem dedizierten KI-Beschleuniger, der sogenannten Parallel Processing Unit (PPU), ausgestattet wurde. Im Rahmen des Projektes wurde der Prototyp anhand der entwickelten KI-basierten Lösungen für Anomalie-Erkennung sowie Trajektorien-regelung und -planung auf seine Echtzeitfähigkeit untersucht. Anhand dieser Ergebnisse wurde die Softwareabstraktion des KI-Beschleunigers und die daraus resultierende Hardware-Software-Schnittstelle entwickelt. Zur Anwendung des Chips im HIL-System und im Testfahrzeug wurde ein entsprechendes Evaluierungsboard bereitgestellt. Die Ergebnisse der Evaluierung des KI- Beschleunigers flossen in die Produktdefinition der kommenden AURIX-Generation mit ein. Anhand der Projektergebnisse entstand ein skalierbares Konzept für die Parallel Processing Unit (PPU). Genauer gesagt, es entstanden daraus Varianten mit drei unterschiedlichen Leistungsklassen.

2.2.8 AP8 Demonstration, Test und Evaluierung KI-Fahrdynamik-System Definition der Demo-Szenarien & Konzept zum KPI-Nachweis

Zusätzlich zu den spezifischen Demo-Szenarien für das Testfahrzeug entwickelte Infineon virtuelle Testszenarien in IPG-CarMaker. Die Maximalgeschwindigkeit auf der Teststrecke war durch gesetzliche Rahmenbedingungen auf 50 km/h limitiert. Um die Anwendbarkeit der entwickelten KI-Algorithmen für höhere Geschwindigkeiten zu testen, hat Infineon die im Projekt definierten KPIs, wie beispielsweise die Abweichung von der Zieltrajektorie, anhand von virtuellen Teststrecken evaluiert.

2.2.8.1 Realisierung der Demonstrator-Aufbauten

Wie bereits im Kapitel AP7 beschrieben, entwickelte Infineon einen Projektentwurf, der den generierten Code aus Simulink, lwIP-Stack und PPU-Funktionsaufrufen integriert und ihn als Rückgrat für die Implementierung aller übrigen AI- und Nicht-AI-TP/TC-Ansätze nutzt.

2.2.8.2 AP8.3 Test und Evaluierung

Im Rahmen von AP8 wurde der KI-unterstützte PID-Regler auf dem AURIX™-TC4x eingesetzt, der in das ZF-Testfahrzeug integriert und anschließend mit der KI-unterstützten MPC auf einer realen Teststrecke verglichen wurde. Insbesondere testete das Infineon-Team den Algorithmus in Szenarien mit doppeltem Fahrspurwechsel. Aus Abbildung 39 geht hervor, dass die vorgeschlagene Lösung eine ähnliche Verfolgungsgenauigkeit wie die AI-enhanced MPC erreicht und gleichzeitig einen geringeren Rechenaufwand für eine effiziente Ausführung auf der MCU des Fahrzeugs benötigt.

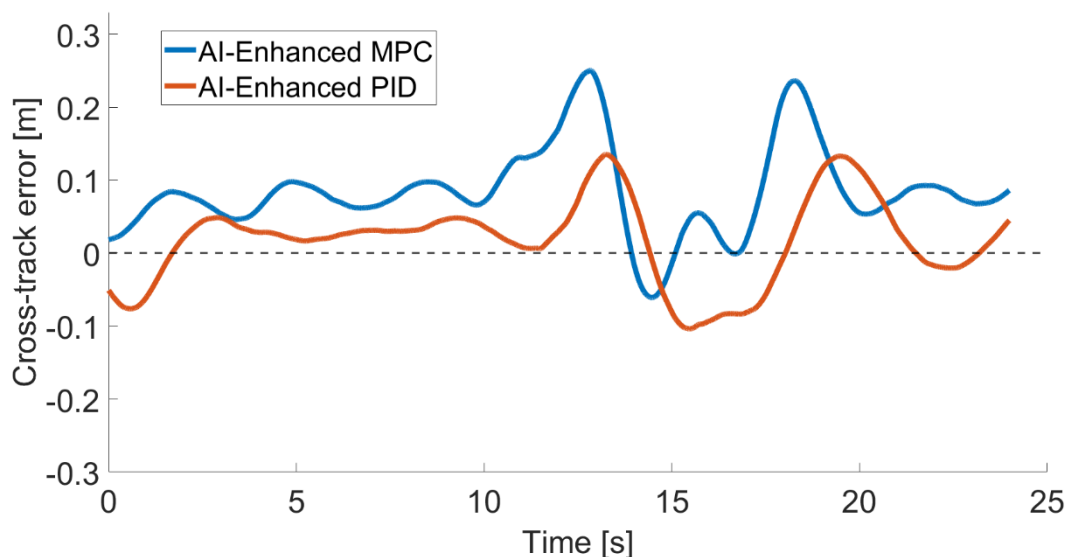


Abbildung 39: Tracking-Genauigkeit für KI-verbesserte MPC (blau) und KI-optimierten PID (rot) bei einem realen Doppelspurwechsel-Szenario auf der ZF-Teststrecke

2.2.8.3 AP8.4 Konzept zur Sicherheitsnachweisführung

Obwohl ursprünglich nicht geplant, wurden frühzeitig eine Reihe von EMV-Prüfungen an der Hardware durchgeführt um sicherzustellen, dass die regulatorischen Anforderungen erfüllt wurden und keine Störungen im Fahrzeug während des Regelbetriebs verursacht werden. Die intensive und positive Zusammenarbeit zwischen ZF und Infineon ermöglichte es, dass die HW-Integration im Fahrzeug sowie sämtliche EMV-Prüfungen bis zum Projektende erfolgreich abgeschlossen werden konnten. Diverse Laboraufbauten wurden seitens Infineon zur EMV-Messung realisiert und genutzt. Nachfolgend dargestellt ist der finale Versuchsaufbau zur Prüfung der EMV-Strahlung der 10BASET1S- und 100BASET1S-Kommunikation zwischen dem Fahrzeug-Gateway (Mockup durch Raspberry Pi), dem Zonen-Controller und dem AURIX™-TC499 (Abbildung 40, Abbildung 41).

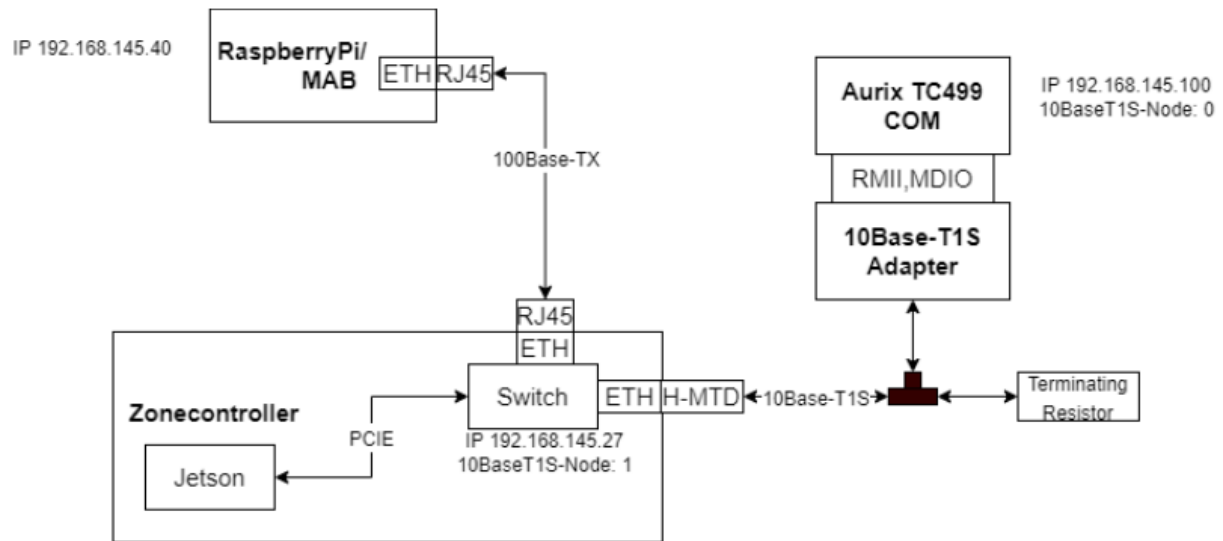


Abbildung 40: Schematische Darstellung des Laboraufbaus zur EMV-Messung



Abbildung 41: Konkreter Laboraufbau zur EMV-Messung

2.2.8.4 AP8.5 Kommunikation

Die Ergebnisse der mehrfachen EMV-Labormessungen wurden kontinuierlich im Kreis der AP8-Projektpartner geteilt und zur weiteren Auswertung und Abnahme genutzt.

2.2.9 Zusammenfassung des Teilvorhabens

Im Rahmen des EEmotion-Projekts wurde Künstliche Intelligenz für die Fahrdynamikregelung als Embedded Automotive-KI-System genutzt. Das System wurde in ein Fahrzeug eingebettet, um in Echtzeit nachvollziehbare, plausible Entscheidungen für den weiteren Fahrverlauf zu gewinnen, bewerten und adaptieren. Umgesetzt wurde das KI-System mittels Machine-Learning-Algorithmen. Mit Methoden aus dem KI-Bereich wurden die Fähigkeiten bezüglich Prädiktion, Bewertung und Merkmal-Extraktion mittels mathematischen Algorithmen wie Deep Neural Networks (DNN) oder tiefen neuronalen Netzwerken simuliert.

Projekt: **EEmotion** / Individueller Schlussbericht

Zentrale Aufgabe des Fahrwerk-Regelsystems war die Planung und Umsetzung von der Perzeptions-Funktionseinheit vorgegebener Trajektorien. Je genauer diese waren, desto besser war die gesamte Performance der Fahrdynamik. Fahrwerkregelungen auf dem Stand der Technik sind allerdings in dieser Hinsicht limitiert. Zur Beseitigung dieser Einschränkung wurde im EEmotion-Projekt ein Regelsystem entwickelt, das auf Machine-Learning-Algorithmen basiert. Zusammen mit Trainingsmethoden wie Reinforcement Learning (RL) ließ sich der mit jeder Fahrsituation einhergehende kinematische Fahrzeugzustand vorausberechnen. Die Ergebnisse erlaubten wiederum, die linearen und nicht linearen Regelalgorithmen optimal zur Fahrsituation zu parametrisieren.

Im Rahmen des EEmotion-Projekts wurden AURIX-MC-Boards, 10BASE-T1S Ethernet-Adapter-Boards und ein Zone-Controller von ZF, b-plus und Infineon in das Demonstratorfahrzeug eingebaut und während des Abschlusstreffens mit den Projektpartnern am 18.07.2024 demonstriert. Für Fahrten mit dem Fahrzeug auf dem ZF-Testgelände in Friedrichshafen war im Vorfeld eine Überprüfung der elektromagnetischen Verträglichkeit (EMV) der eingebauten Komponenten notwendig, die über die geplanten Arbeiten hinausging.

Erheblich erleichtert wurden die Projektaktivitäten durch eine enge Zusammenarbeit mit den Partnern, die bereits in einer frühen Projektphase begann. Dies erlaubte auch, Arbeiten auszuführen, die über die spezifizierten Anforderungen hinausgingen. Unterstützend wirkte der hybride Ansatz eines Continuous Integration (CI) Entwicklungs-Prozesses. Der CI-Ansatz erlaubte den Infineon-Entwicklern, kontinuierlich Code bereitzustellen, an dem automatisierte Tests (Software-in-the-Loop; (SIL)) durchgeführt wurden, um HW- und SW-Fehler im Fahrzeug schneller zu erkennen und frühzeitig zu beheben. CI war die Antwort auf die Herausforderungen traditioneller Entwicklungsprozesse, wie z.B. beim Wasserfall-Modell mit einem sequentiellen Projektmanagement-Ansatz auf Grundlage fest vorgegebener Termine und Anforderungen. Die von Infineon entwickelten KI-basierten Funktionen wurden unmittelbar nach ihrer Bereitstellung getestet und direkt anschließend in das Demonstratorfahrzeug integriert. Bei positiven Resultaten konnten sich die Entwickler sofort den nächsten Softwaremodulen widmen.

Die Resultate bewiesen, dass die Projektanforderungen erfüllt, alle Projektziele erreicht und das Projekt erfolgreich abgeschlossen wurde. Durch die engagierte Zusammenarbeit aller Partner konnten die geplanten Meilensteine termingerecht realisiert und die gewünschten Ergebnisse erzielt werden. Die gewonnenen Erkenntnisse und Erfahrungen bieten wertvolle Impulse für zukünftige Projekte.

3 Verwertbarkeit des Ergebnisses und der Erfahrungen

Organisatorische, finanzielle Kapazitäten zur Markteinführung und Einbindung von Nutzern/Betreibern

Die Marktchancen im Bereich KI bieten den Projektpartnern bestes Verwertungspotenzial. Zum einen sichert deren Verwendung bereits bei Fahrerassistenz-Systemen im Vergleich zu rein autonomen Ansätzen wirtschaftliche Vorteile; Grund ist die schnellere Realisierung und Validierung. Zum anderen verfügen die beteiligten Partner ebenso über Kompetenzen in der Entwicklung und Applikation von Trajektorien-Regelungsfunktionen mittels KI für

Projekt: **EEmotion** / Individueller Schlussbericht

automatisierte und assistierte Fahrzeuge. Zusammen mit ihren Vertriebsorganisationen ist dies eine ideale Ausgangsposition zur Einbindung von Nutzern und Betreibern sowie eine weitreichende Vermarktung, was sich u.a. in einzelnen Verwertungsplänen Partner zeigt. Mit diesem Top-Know-How in der Automobil- und Halbleiterindustrie hat Deutschland eine optimale Ausgangsposition für das Projektvorhaben, was sich auch in Umsätzen und Wirtschaftswachstum niederschlagen wird.

Verwertungsplanung sowie Einführungs- und Diffusionsstrategien

Der Fokus im Projekt lag auf der Entwicklung von echtzeitfähigen KI-Ansätzen für Trajektorienregelung und -planung im Kontext vom automatisierten Fahren (L2+). Im Besonderen wurden im Projekt die energie-effiziente Adaptive Cruise Control (ACC) Anwendung und eine Auto-Pilot Anwendung für Automatisiertes Fahren betrachtet. Im Projekt ist gezeigt worden, dass die um KI erweiterten Standardregler eine Verbesserung der lateralen Regelabweichung von der vorgegebenen Trajektorie um bis zu 50% (anstatt der ursprünglich angenommenen 20%) auf der Teststrecke erreichen, was zu einer signifikanten Verbesserung des Fahrkomforts von der Anwendung des Auto-Pilots eines autonomen Fahrzeug führt. Die um KI erweiterten Standardplaner zeigen eine Verbesserung der Energieeffizienz für die Anwendung ACC um bis zu 14%. Es wurde ebenso gezeigt, dass die KI basierten Ansätze zur Trajektorienregelung und -planung die Anpassung auf unterschiedliche Fahrzeugtypen erleichtern, da die KI die Bestimmung der benötigten Parameter übernimmt, wodurch die Entwicklungszeit signifikant reduziert werden kann.

Aufgrund neuer Regulierungsanforderungen werden aktuell autonome Fahrfunktionen von L2+ eingeführt, um Sicherheit im Straßenverkehr zu erhöhen. Somit werden diese zu Standardfunktionen des zukünftigen Fahrzeuges und ergeben ein großes wirtschaftliches Potential für die im Projekt entwickelten echtzeitfähigen KI-Ansätze für Trajektorienregelung und -planung.

Die Ergebnisse werden in der Vorserienentwicklung der Industriepartner verwendet:

- Die ZF Friedrichshafen AG wird mit den Ergebnissen des Projektes ihr Fahrregelungssystem cubiX um KI-basierte Ansätze erweitern.
- Die Infineon Technologies AG wird anhand der gewonnenen Ergebnisse die KI-Fähigkeit seiner zukünftigen AURIX™ Produktfamilie erweitern und die erarbeiteten KI-Ansätze in Kooperationen mit OEMs weiterentwickeln.
- Die Samoconsult GmbH und die b-plus technologies GmbH werden die Ergebnisse des Projektes nutzen, um ihre zukünftigen Entwicklungsdienstleistungen um das Thema KI in sicherheitskritischen und echtzeitkritischen Mobilitätsanwendungen auszubauen.

Forschungspartner werden ihre Ergebnisse und Lehre und Forschung verwerten.

Die Pressemitteilung zu den Projektergebnissen wurde in mehr als 20 nationalen und internationalen online Fachmagazinen veröffentlicht. Die beteiligten Projektpartner bekommen Kooperationsanfragen von nationalen und internationalen Automobilherstellern und deren Zulieferern.

3.1 Infineon Technologies AG

Durch die vorwettbewerbliche Zusammenarbeit konnte Infineon auf die Kompetenz der Partner zurückgreifen und die im komplexen Umfeld notwendigen Synergien zur Optimierung des Gesamtsystems nutzen. Somit hat Infineon durch die Erforschung der Anwendbarkeit der KI-Algorithmen für die nächste AURIX™ Generation eigene Systemkompetenz als Halbleiterhersteller erfolgreich stärken können, was eine starke Marktposition für das zukünftige Software-Defined-Vehicle und das autonome Fahren ermöglicht.

Die bereits erfolgten Kooperationsanfragen mit Automobilherstellern bestätigen das OEM offene Konzept des Projektes. Im Rahmen der Kooperationsanfragen wird eine Weiterentwicklung der erarbeiteten KI-Ansätze angestrebt. Aus Sicht des OEM Innovationszyklus muss der aktuell von EEmotion erzielte TRL6 von KI-Ansätzen über die TRL7 und TRL8 hinweg weiterentwickelt werden, bis es frühestens in 3,5 Jahren – je nach des Innovationszyklus eines bestimmten OEMs – in einem bestimmten Fahrzeugtyp auf den Markt kommt.

Ferner wird Infineon die erzielten Projektergebnisse für eine bessere Vermarktung der nächsten AURIX™ Generation – derzeit in Entwicklung - nutzen. Die nächste AURIX™ Generation wird mittels der neu integrierten Kerninnovation Parallel-Processing-Unit eine beschleunigte und ressourcenschonende Ausführung von KI-Modellen unterstützen. Diese signifikante Kostenreduktion auf der Seite eines OEMs ermöglicht Serieneinsatz der KI-Ansätze nicht nur in der Applikation der Fahrdynamik. Die deutliche Verbesserung der Genauigkeit der Trajektorienregelung und -planung – speziell in EEmotion - schafft Wert für OEMs durch erhöhten Fahrkomfort, Energieeffizienz und einfachere Anpassung an unterschiedliche Fahrzeugmodelle.

Zu guter Letzt wird Infineon die Forschungserkenntnisse zu applikationsoptimierten AI-Modellen, ihrer Topologie, Trainingsmethoden und insbesondere der Software-Schnittstelle zur Hardware-Architektur in weiterführenden Projekten der übernächsten AURIX™ Generation nutzen. Damit verspricht sich Infineon einen Wissensvorsprung zur Erweiterung der heterogenen Automotive-Multicore-Prozessoren.

4 Während der Durchführung des Vorhabens dem Zuwendungsempfänger bekannt gewordenen Fortschritts auf diesem Gebiet bei anderen Stellen

Es sind während der Projektlaufzeit keine neuen Erkenntnisse von dritter Seite bekannt geworden, die für die Durchführung des Vorhabens relevant waren.

Projekt: **EEmotion** / Individueller Schlussbericht

Trotz projektbegleitender Recherche hat es sich während des Projektes gezeigt, dass der Ansatz der KI-Erweiterung von klassischen Reglern und klassischen modellprädiktiven Regelung und Planungsalgorithmen ein weitgehend unerforschtes Feld ist.

Zusätzliches zentrales Forschungspotential nach Projektende: Der Fokus im Projekt lag auf der Entwicklung von echtzeitfähigen KI Ansätzen für Trajektorienregelung und -planung im Kontext von automatisiertes Fahren (L2+). Um die datengesteuerten KI-Ansätze auch in die Richtung des autonomen Fahrens (L3-L5) zu bringen, ist es notwendig, dass es klare und einheitliche Definitionen zu Sicherheit von KI-Algorithmen gibt. Damit würden sich neue Möglichkeiten rund um das Thema Imitation Learning und Lernen im regulären Fahrbetrieb ergeben. Damit lassen sich nochmals signifikante Verbesserungen im Bereich Energieeffizienz, Fahrkomfort und Verkürzung des Innovationszyklus erreichen.

5 Erfolgte oder geplante Veröffentlichungen der Ergebnisse

Im Rahmen des Projekts sind folgende Veröffentlichungen der Projektpartner entstanden bzw. geplant, die im Folgenden aufgelistet sind:

5.1 Veröffentlichungen

Mohamed Abouelnaga, Mathias Haberjahn, Daniel Markert, Alejandro Masrur, "**Hardware-Compatible Deep Reinforcement Learning-Based Lateral Trajectory Controller**", 2024 IEEE 27th International Conference on Intelligent Transportation Systems (ITSC), September 24- 27, 2024, Edmonton, Canada.

Stephan Baumgärtner, Mateusz Chmurski, Mathias Haberjahn, Lukas Marik, Jürgen Schäfer, Daniel Scholz, „**Embedded AI enables next level of safe, comfortable and energy efficient automated driving**“, 2024, The Autonomous Expert Circle Safety for Embedded AI Report <https://www.linkedin.com/feed/update/urn:li:activity:7242114378186010624>

Tobias Ehlgén, Minira Prosser, Juergen Schaefer, Elena Sapozhnikova, „**Mehr Komfort, Effizienz und Flexibilität: KI-Algorithmen optimieren autonomes Fahren**“. Heft-im-Heft in ATZ, ATZelektronik und MTZ, 2025.

Infineon und ZF (Pressemitteilungen), „**Automatisiertes Fahren: ZF und Infineon optimieren mit KI-Algorithmen Software und Steuergeräte für Fahrdynamik**“/ „**Automated driving: ZF and Infineon use AI algorithms to optimize software and control units for driving dynamics**“, 2024.

<https://new-origin.infineon.com/cms/en/about-infineon/press/press-releases/2024/INFATV202409-139.html>

Infineon, „**Increased driving safety with AI: Improving driving performance combined with lower computing power demands**“, 2024.

<https://www.linkedin.com/feed/update/urn:li:activity:7240011531969560579/>

5.2 Vorträge

“Safety of Embedded AI”, Expert Circle at The Autonomous Main Event, Wien, September 2022, Thomas Schneid, Jürgen Schäfer, Florian Hauer (alle Infineon Technologies AG)

“Safety of Embedded AI”, Expert Circle at The Autonomous Main Event, Wien, September 2023, Thomas Schneid, Jürgen Schäfer (beide Infineon Technologies AG), Stephan Baumgärtner, Mateusz Chmurski, Mathias Haberjahn (alle drei Infineon Technologies GmbH & Co. KG, Dresden)

“Safety of Embedded AI”, Expert Circle at The Autonomous Main Event, Wien, September 2024, Minira Prosser, Thomas Schneid, Jürgen Schäfer (alle drei Infineon Technologies AG), Stephan Baumgärtner, Mateusz Chmurski, Lukas Marik (Infineon Technologies GmbH & Co. KG, Dresden), Lucas Garcia (MathWorks Inc.)

“How to Develop Model-Based AI Software for AURIX TC4x in MATLAB and Simulink”, MathWorks Automotive Conference, Stuttgart, Juli 2023, Mateusz Chmurski (Infineon Technologies GmbH & Co. KG, Dresden)

“AI-Driven Software Design and Development for AURIX TC4x in MATLAB and Simulink”, MathWorks Automotive Conference, Stuttgart, Mai 2024, Mateusz Chmurski (Infineon Technologies GmbH & Co. KG, Dresden)

“The role of embedded AI for autonomous driving”, Embedded World 24, Nürnberg Mai 2024, Jürgen Schäfer (Infineon Technologies AG)

“Safe and Energy-efficient Trajectory Planning and Control for Autonomous Driving on AURIX™-TC4x”, DRAIVING Conference, Dresden, Oktober 2024, Jürgen Schäfer (Infineon Technologies AG)

5.3 Demonstratoren

“AURIX™-TC4x Trajectory Control & Planner Demonstrator”, The Autonomous Main Event, Wien, September 2024

“AURIX™-TC4x Virtualized Trajectory Control & Planner Demonstrator”, Embedded World, Nürnberg, März 2025

“AURIX™-TC4x Virtualized Trajectory Control & Planner Demonstrator”, IPG Open House Germany, Karlsruhe, März 2025

5.4 Masterarbeiten

“Machine Learning Based Anomaly Detection System for in-vehicle Communication Networks” von Kazi Kowshin Raihana. Betreut von Prof. Bernard Bäker (Technische Universität Dresden) und Dr. Stephan Baumgärtner (Infineon Technologies GmbH & Co. KG, Dresden).

“Neural Network-based hardware anomaly detection for 10BASE-T1S communication with AURIX™ TC4xx” von Simon Jarc. Betreut von Prof. Andreas Herkersdorf (Technische Universität München), Dr. Stephan Baumgärtner (Infineon Technologies GmbH & Co. KG, Dresden) und Jürgen Schäfer (Infineon Technologies AG).



Projekt: **EEmotion** / Individueller Schlussbericht

“Hardware-Compatible Deep Reinforcement Learning-Based Lateral Trajectory Controller” von Mohamed Abouelnaga. Betreut von Prof. Dr.-Ing. Alejandro Masrur (Technische Universität Chemnitz) und Dr. Mathias Haberjahn (Infineon Technologies GmbH & Co. KG, Dresden).

Problem Statement

Customer Problems

High effort and cost to realize AD / ADAS functions on different vehicles due to **required vehicle specific adaptations and tuning**

Design objectives like **trajectory tracking, energy-efficiency, comfort and motion sickness prevention** are not met by existing trajectory control functions

Project Targets

- Improve **tracking accuracy by 30 %** (compared to baseline controller)
- Reduce **application effort by 50 %** due to increased flexibility & sensitivity compared to classical control approaches
- Cost **benefits** due to faster application projects (15 % or more)
- Explicitly address **auxiliary design goals** like energy efficiency, motion sickness, driving comfort, and fault-tolerant control

Approach

SW: Combining latest AI development with mature control structures for powerful embedded control functions

HW: Utilizing new ALURX TC4x with PPU

Summary and Outlook

Summary

- Successful vehicle implementation of Zone Controller and ALURX boards with PPU
- Development of various AI-enhanced trajectory control functions
 - AI enhanced PID
 - Residual PPO
 - Data-driven MPC
 - Approximate Model Inversion using RBNs
- Extensive scenario-based testing in simulation incl. robustness and disturbance injection testing
- Vehicle testing with ZF experimental vehicle up to 50 kph

Project target achieved!

- Tracking accuracy improved by > 30 %
- Controller application effort reduced by > 50 %

Testing Results

Scenario with double lane change at 50 kph and light low speed curve and medium speed curve with lateral acceleration up to 5 m/s²

Approaches and Solutions

Online Approximate Model Inversion

Radial Basis Function network used to approximate model inversion surface

Value-add:

- Higher tracking accuracy esp. at high dynamics
- Automatic adaption to the specific vehicle
- Very low tuning effort < 50 %; correction is learned automatically

Achievements

- Large RBFN with > 1000 center points to achieve accurate representation of approximate inverse model
- Verified robustness and stability of online adaption
- Extensive vehicle testing
- Tracking performance improved by 35 % after 4 laps for fasttrack

Summary

SW: Tooling to deploy Simulink models on ALURX and PPU successfully tested

HW: Implementation on ALURX TC4x with PPU

Model Predictive Trajectory Control

Simple kinematic vehicle model with no unknown parameters

Model correction based on function approximators like Radial Basis Function network, feedforward neural nets and polynomials

Value-add:

- Higher tracking accuracy esp. at high dynamics
- Automatic adaption to the specific vehicle
- Explicit consideration of actuator magnitude and rate limits
- Very low tuning effort < 50 %; Correction is learned automatically

Achievements

- Medium RBFN to represent model correction
- Verified robustness and stability of online adaption
- Extensive vehicle testing
- Tracking performance improved by 50 % for fasttrack scenario

Summary

SW: Tooling to deploy Simulink models on ALURX and PPU successfully tested

HW: Implementation on ALURX TC4x

Residual PPO Agent for Trajectory Control

Residual Reinforcement Learning (RL) trains an agent (Neural Network) in simulation on random tracks to add a correction to the output of baseline-controller

Value-add:

- Higher tracking accuracy for higher vehicle speed
- Learning-based controller can adapt to changing environments

Achievements

- hyperparameter tuning in the cloud
- optimized hyperparameters **improve stability** of training
- optimized reward function leads to better performance
- smooth actions through action regularization
- adaption to highly delayed environments (up to 100 ms) by domain randomization and observation stacking
- Integration of the trained agent into Simulink model
- assessment on 28 tracks in CarMaker and Matlab simulations

Summary

SW: Adapt robust and generalizing behavior of RL

- Extend baseline-controller to track good in unknown scenarios

HW: Deployment on ALURX TC4x

Safe Bayesian Optimization

Safe Bayesian Optimization

Experimental evaluation

Baseline controller with parameters ϵ

Tracking performance $K(\epsilon)$

Safety constraints $s_i(\epsilon)$

Goal: Find optimal parameters that maximize tracking performance without violating the safety constraints in any iteration

Value-add:

- Automate and speed-up controller parameter tuning
- Theoretical safety guarantees
- Black-Box optimization → applicable to arbitrary controllers and vehicles

Achievements

- Design of optimization problem in close collaboration with ZF
- Two new safe BO algorithms** were developed and submitted for publication
- More **interpretable safety guarantees** compared to the state of the art
- Vehicle experiments** demonstrating safe parameter tuning
 - Improved trajectory tracking performance
 - No safety violations** in the tuning process

Summary

SW: Development of new safety mechanism for Bayesian Optimization

- Extension to multiple safety constraints

HW: Deployment and evaluation on real vehicle using Prototyping system and a Python interface

AI-Enhanced Trajectory Controller

Using MLP to learn mapping between scene maneuver and optimal controller parameters (PID) for current driving scenario contained inside ODD

Polynomial interpolation of the **planned trajectory ahead**, vehicle dynamics

Value-add:

- PID enhanced by AI techniques can outperform complex MPC

Achievements

- Application of AI techniques enables adaptation to unknown scenarios
- AI-Enhanced PID controller outperforms** the baseline controller by roughly 40%
- Simple Neural Network - MLP significantly improves the tracking performance of the controller
- Collected a representative dataset

Summary

- Linearized controller can be improved introducing ML covering **non-linear behavior** or **stable adaptation** to unknown scenarios
- AI-Enhanced controller outperforms** the baseline
- Memory footprint: 25 KB
- Inference time: 2800 cycles ~5.6 μ s
- AI-Enhanced controller deployed in the car


Conclusion

To increase **Energy Efficiency** for Vehicle Motion, AI should be applied on longitudinal **Trajectory Planning**.

To increase **Tracking Accuracy** for Vehicle Motion, AI should be applied on lateral **Trajectory Control**.

Abbildung 42: Übersicht der Anforderungen und Ergebnisse der Projektpartner (1)

Trajectory Planning



Problem Statement

Customer Problems

Trajectory Planning needs to optimize a complex multi objective function under timely bounded constraints.



Model Predictive Control has been established as appropriate approach to handle this challenge. But sophisticated MPC setups suffer in high computational costs running on energy expensive central processing units only.

Project Targets

- Adaption to vehicle and environmental parameters changes via machine learning for trajectory planning
- Improvement of real-time capability and reduction of computational costs for trajectory planning utilizing machine learning
- Improve the overall energy efficiency for the driving by up to 5% (compared to state-of-the-art MPC trajectory planning)
- Reduce application effort by 50 % due to increased flexibility & scalability compared to classical approaches

Approach

SW
 Combining latest tools and methods for AI development with mature approaches for trajectory planning for powerful embedded trajectory planning functions

HW
 Utilizing new AURIX TC4x with FPU

Summary and Outlook

Summary

- Development of various AI-enhanced trajectory planning functions
 - Advanced energy efficient MPC
 - AI-Clone of MPC for longitudinal Trajectory Planning
 - Reinforcement Learning for Decision-making and Trajectory Planning
- Approaches developed and verified in a closed Software-in-the-Loop setting using IPG Carmaker and Matlab Simulink and ODD driven scenario generation
- Partially deploying and testing of approaches on AURIX™ TC4x

Project target achieved!
 → Improved energy efficiency > 10 %
 → Application effort reduced by > 50 %
 → Reduced complexity to execute the function on AURIX™ TC4x

Testing Results

Planner	Fuel consumption in 500m	Fuel savings
MPC	29.21 (m)	-
FFMPC	25.06 (m)	14.3%
MPC + RL	28.3 (m)	3.1%
FFMPC + RL	24.79 (m)	15.2%


LUIGI Energy Efficient MPC

Outlook

- SW**
 Further improvement of AI-enhanced functions to mimic/support MPC
- HW**
 Deployment of software with new AURIX™ TC4x with FPU

Approaches and Solutions

MPC for Trajectory Planning



- Planned maneuver: The desired speed on the lane for longitudinal and lateral planners
- Value-add:** Integrate ML into the planner to increase fuel efficiency
 - Considering the safety, comfort, and input constraints in the longitudinal and lateral planners
 - Applying a general fuel map for the combustion engine and electrical cars and integrating it into the longitudinal MPC


Achievements

- Design of a decision-making algorithm to decide the desired maneuver considering the energy consumption aspect
- Integration of the longitudinal and lateral MPCs into main Trajectory Planner-Simulink model
- Evaluation of the longitudinal and lateral MPCs in different test scenarios including velocity tracking and lane change
- Design of a baseline MPC planner without energy consideration
- Evaluation of the longitudinal energy-efficient MPC and the baseline MPC from an energy perspective

Summary

- Applying the decision-making algorithm leads to selecting the lane with less energy consumption
- The longitudinal and lateral MPCs are able to perform safe and driving comfortable maneuvers.
- The energy-efficient MPC saves ~9% fuel consumption compared to the baseline MPC for the considered test scenario.
- The results are published as a journal paper [1].

RL for Decision-making and Trajectory Planning



- Value-add:**
 - Considering the energy consumption, safety, and input constraints
 - Applying a general fuel map for the combustion engine and electrical cars and integrating it into the reward function
 - Considering the interaction of the ego with other vehicles


Achievements

- Design of an intelligent decision-making to decide the maneuver, e.g. lane keeping or lane change considering the energy aspect
- Integrating the decision-making and planner into one component
- Evaluation of the designed algorithm in different test scenarios
- Design of a baseline planner without energy consideration
- Evaluation of the energy-efficient approach and the baseline from an energy perspective

Summary

- Applying the decision-making algorithm leads to selecting the lane with less energy consumption.
- It is possible to reach a reasonable trade-off between energy saving and the travel time with selecting an appropriate reward function.
- This paper based on the results is currently being prepared.

AI-enhanced MPC for Trajectory Planning



- Conventional MPC is supplemented by RL agent for continuous estimation of optimal parameter values of MPC during runtime
- Value-add:**
 - Added adaptivity for optimization of conventional MPC
 - Simple MPC brought on a level of more complex one

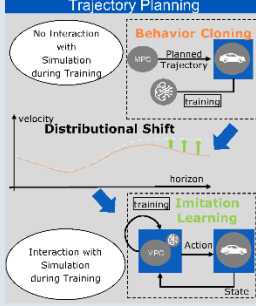
Achievements

- Energy efficiency studied on a simulated congestion build-up
 - Longitudinal control for ACC use case considered
 - DDPG agents trained using a combination of fuel efficiency and velocity tracking reward terms to balance the trade-off
-
- Confirmed that higher efficiency comes at a cost of time (speed)
 - Optimization of MPC output variable weights and following distance tested

Summary

- Non-optimized MPC can be improved by over 3 %**
- Baseline MPC to be simplified for HW and more room for improvement as a next step

AI-Clone of MPC for longitudinal Trajectory Planning



Goal

- Training of MPC based AI-clone (IL)
- Creation of deployable AHL model
- Execution Time evaluated on AURIX TC4x

Achievements

- Training and Testing of AI in open loop with good results
- Integration of AI in closed-loop MPC simulation
- Development of Cloud integrated Pipeline using multi-worker training, enabling **Imitation Learning**
- Minimization of Distributional Shift** based on interactive training, incorporating MPC and AI
- Reduction of Execution Time to 2.2ms**, while solution keeps behavior of MPC trajectory

Abbildung 43: Übersicht der Anforderungen und Ergebnisse der Projektpartner (2)

6 Abbildungsverzeichnis

Abbildung 1: KI-basierte energieeffiziente Trajektorienplanung und -regelung	6
Abbildung 2: Kerninnovationen mit dem Technologiereifegrad am Start und Ende des Projekts	7
Abbildung 3: Projektstruktur und Arbeitspakete unterschiedlicher Ebenen	9
Abbildung 4: Arbeitspakete und Meilensteine des Projekts.....	10
Abbildung 5: Angestrebte TRL-Level der Kerninnovationen im Projekt.....	15
Abbildung 6: Szenario „Spurwechsel auf einer mehrspurigen Straße“ unterteilt in beteiligte Anwendungsfälle und Akteure	18
Abbildung 7: Aktivitätendiagramm zum Anwendungsfall "Short term trajectory plan"	18
Abbildung 8: Logische Systemstrukturen für Szenario „Spurwechsel auf einer mehrspurigen Straße“	19
Abbildung 9: Erstellung der funktionalen, logischen und physikalischen Systemarchitektur nach SySML.....	20
Abbildung 10: Physikalische Architektur (vereinfacht) für das zu entwickelnde System	21
Abbildung 11: Partitionierung der Software-Komponenten zur Trajektorien-Planung und -Regelung auf der Ziel-Hardware.....	22
Abbildung 12: Verknüpfung der Anforderungen mit der Software-Architektur in MATLAB/Simulink	22
Abbildung 13: Zyklischer Prozess zur Absicherung von KI-basierten Komponenten.....	23
Abbildung 14: Prüfung der vollständigen Abbildung von Anforderungen und Architektur in MATLAB/Simulink	23
Abbildung 15: AI-Enhanced PID-Controller.....	25
Abbildung 16: Tracking-Genauigkeit für konventionelle und AI-verstärkte PID-Verfahren auf dem Nürburgring in einer Simulationsumgebung	26
Abbildung 17: KI-gestützter Model-Predictive-Controller zur Querregelung	27
Abbildung 18: Simulierte Fahrdynamiken für die ODD des linken Spurwechsels	28
Abbildung 19: Geringster lateraler Versatzfehler für AI MPC im Vergleich zum konventionellen MPC	28
Abbildung 20: Vergleich konventioneller MPC und AI-gestützter MPC für Spurwechsel	29
Abbildung 21: Diagramm des KI-basierten MPC.....	29
Abbildung 22: Geschwindigkeitsprofil des Ego-Fahrzeugs und des führenden Fahrzeugs in einem Szenario mit Stauaufbau.....	30
Abbildung 23: Vergleich der a) lateralen und b) Gierwinkel-Abweichungen entlang der Hockenheim-Rennstrecke zur Bewertung der Verfolgungsgenauigkeit von Basis-MPC und KI-gestütztem MPC.....	31
Abbildung 24: Entwicklungsprozess für sicherheitskritische KI-Anwendungen	32
Abbildung 25: Ansatz A: Reinforcement Learning basierter Trajektorienregler	33
Abbildung 26: Ansatz B: RL-basierter Trajektorienregler als Ergänzung zum Basisregler	33
Abbildung 27: Ansatz C: RL-basierte Parametrisierung des Basisreglers	34
Abbildung 28: Bewertung der drei Ansätze für eine simulierte Testfahrt. Der jeweils beste Werte ist hervorgehoben	35

Abbildung 29: Laufzeit und Speicherverbrauch der RL-basierten Verfahren auf dem AURIX™-TC4x	36
Abbildung 30: Abschlussteil der Berechnungskette des autonomen Fahrens mit Trajektorienregler. Am Ein- und Ausgang des Reglers ist ein Runtime-Monitor zur Überwachung des Datenstroms. b) Flaschenhals-Architektur eines Autoencoder-Netzwerkes zur Anomalieerkennung.....	37
Abbildung 31: Vergleich statistischer Metriken zur Anomalieerkennung von einem KI-Ansatz mit simpler linearer Extrapolation für den Output des Trajektorienreglers	37
Abbildung 32: Grösse, Speicherbedarf und Laufzeit des favorisierten einfachen Autoencoder-Modells auf der PPU des AURIX™ TC4xx. Die Laufzeit wurde mit dem nSIM-Hardware-Simulator von Synopsis bestimmt.....	38
Abbildung 33: Screenshot des zeitlichen Verlaufes des Rekonstruktionsfehlers (oben) und der binären Klassifizierung (unten). Das grüne Rechteck markiert die Detektion einer injizierten Anomalie	39
Abbildung 34: Verteilung des Rekonstruktionsfehlers für die drei getesteten Modell-Architekturen: Hauptkomponentenanalyse als Baseline, einfacher Autoencoder und Variational-Autoencoder. Verteilungen für anomaliefreie (clean) und anomaliebehaftete (defect) Testdaten	39
Abbildung 35: Statistische Metriken zur Anomalieerkennung der getesteten Methoden - Daten des Trainingsszenarios Nürburgring (Train), Daten der Spurwechselszenarien, als Test der Generalisierung (Gen)	40
Abbildung 36: Konzeptionelle Sichtweise auf funktionale, logische und konkrete Szenarien	42
Abbildung 37: Abbildung der Trajektorien-Planung und -Steuerung in Matlab/Simulink	43
Abbildung 38: Kopplung der Simulationsumgebung mit der Applikations-Entwicklungsumgebung auf den unterschiedlichen Abstraktionsebenen	44
Abbildung 39: Tracking-Genauigkeit für KI-verbesserte MPC (blau) und KI-optimierten PID (rot) bei einem realen Doppelspurwechsel-Szenario auf der ZF-Teststrecke.....	45
Abbildung 40: Schematische Darstellung des Laboraufbaus zur EMV-Messung	46
Abbildung 41: Konkreter Laboraufbau zur EMV-Messung	46
Abbildung 42: Übersicht der Anforderungen und Ergebnisse der Projektpartner (1)	53
Abbildung 43: Übersicht der Anforderungen und Ergebnisse der Projektpartner (2)	54

Berichtsblatt

1. ISBN oder ISSN -	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel Gemeinsamer Schlussbericht EEmotion Projekt	
4. Autor(en) [Name(n), Vorname(n)] Baumgärtner, Stephan Chmurski, Mateusz Haberjahn, Mathias Koch, Jürgen Marik, Lukas Prosser, Minira Schäfer, Jürgen	5. Abschlussdatum des Vorhabens 31.08.2024
	6. Veröffentlichungsdatum Februar 2025
	7. Form der Publikation Broschüre
8. Durchführende Institution(en) (Name, Adresse) Infineon Technologies AG, Am Campeon 1-15, 85579 Neubiberg	9. Ber. Nr. Durchführende Institution -
	10. Förderkennzeichen 19A21038A
	11. Seitezahl 58
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. Literaturangaben -
	14. Tabellen -
	15. Abbildungen 43
16. Zusätzliche Angaben Vollständiger Titel des Verbundvorhabens EEmotion: Verbundprojekt: „Embedded Excellence - Fahrdynamik mit KI“	
17. Vorgelegt bei (Titel, Ort, Datum) Technische Informationsbibliothek, Deutsche Forschungsberichte, Hannover, Februar 2025	
18. Kurzfassung Schlüsselinnovation: Die Erweiterung der Fahrdynamikregelungen mit KI-Methoden ermöglicht die Prädiktion des kinematischen Fahrzeugzustandes, was dazu führt, dass die entsprechenden Aktuator-Systeme wie Antriebsstrang, Bremse, Lenkung an die aktuellen Bedingungen der Umgebung angepasst werden können. Damit wird erreicht, dass die von der zentralen Perzeptionseinheit vorgegebenen Fahrmanöver sehr präzise umgesetzt werden können, was einerseits zu einer Verbesserung des Fahrkomforts und andererseits zu einer Verbesserung der Energieeffizienz beiträgt. Bei konventionellen Antriebskonzepten führt das zu einer Reduktion der Emissionen. Bei batterieelektrischen Fahrzeugen wird die Reichweite erhöht. Zusätzlich zu den technischen Errungenschaften ergab sich im EEmotion-Projekt auch ein wirtschaftlicher Vorteil: durch die KI wurde eine bessere Anpassbarkeit der Entwicklungssysteme an andere Fahrzeugtypen ermöglicht, was zu kürzeren Entwicklungszeiten beitrug.	
19. Schlagwörter KI, Künstliche Intelligenz, Trajektorienregelung, Trajektorienplanung, Fahrdynamik, Edge-AI, Simulation, Safety	
20. Verlag -	21. Preis -

Document Control Sheet

1. ISBN or ISSN -	2. type of document (e.g. report, publication) Final report
3. title Gemeinsamer Schlussbericht EEmotion Projekt	
4. author(s) (family name, first name(s)) Baumgärtner, Stephan Chmurski, Mateusz Haberjahn, Mathias Koch, Jürgen Marik, Lukas Prosser, Minira Schäfer, Jürgen	5. end of project 31.08.2024
	6. publication date Februar 2025
	7. form of publication brochure
8. performing organization(s) (name, address) Infineon Technologies AG, Am Campeon 1-15, 85579 Neubiberg	9. originator's report no. -
	10. reference no. 19A21038A
	11. no. of pages 58
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. no. of references -
	14. no. of tables -
	15. no. of figures 43
16. supplementary notes Translation of the title: Joint final report EEmotion project „Embedded Excellence – vehicle motion with AI“	
17. presented at (title, place, date) Technische Informationsbibliothek, Deutsche Forschungsberichte, Hannover, February 2025	
18. abstract Key Innovation: The extension of vehicle dynamics control systems with AI methods enables the prediction of the kinematic state of the vehicle, allowing corresponding actuator systems such as the drivetrain, brakes, and steering to be adapted to current environmental conditions. This ensures that the driving maneuvers specified by the central perception unit can be implemented very precisely, which on the one hand improves driving comfort and on the other hand enhances energy efficiency. For conventional drive concepts, this leads to a reduction in emissions. For battery electric vehicles, the range is increased. In addition to technical achievements, the EEmotion project also resulted in an economic advantage: through AI, a better adaptability of development systems to other vehicle types was enabled, which contributed to shorter development times.	
19. keywords AI, Artificial Intelligence, trajectory control, trajectory planning, vehicle motion, Edge-AI, simulation, safety	
20. publisher -	21. price -