

Kurzbericht zum Projekt „KI-basierte Fahrwerksregelung KIFAHR“

Aufgabenstellung und angeknüpfter wissenschaftlich-technischer Stand

Für die Vertikaldynamikregelung von semi-aktiven Dämpfern werden neuartige Regelungsansätze benötigt, welche für den Zielkonflikt zwischen Komfort und Fahrsicherheit unter Berücksichtigung von verschiedenen Einflussfaktoren, wie veränderliche Beladungen, unterschiedlichste Fahrbahnoberflächen, Reifentypen, Reifendrucke und Wetterbedingungen einen besseren Kompromiss als Regler nach dem Stand der Technik realisieren. Die herkömmliche Umsetzung einer semi-aktiven Vertikaldynamikregelung beinhaltet in der Praxis sowie in den meisten wissenschaftlichen Veröffentlichungen das Zusammenführen folgender Komponenten: Ein parametrisiertes Synthesemodell (meist ein so genanntes Viertelfahrzeugmodell), ein Regelansatz, der darauf abzielt eine Zielgröße zu minimieren sowie eine Auswahl an Sensorsignalen als Eingänge des Reglers.

Methoden des maschinellen Lernens bieten die Möglichkeit, das Regelgesetz aus gemessenen Daten und der Interaktion mit System oder Simulation automatisiert zu lernen. Für den Regler stellen Methoden des Reinforcement Learnings (RL) einen vielversprechenden Ansatz dar. In mehreren Veröffentlichungen wurde bereits die Leistungsfähigkeit von RL-basierten Methoden für die Anwendung auf regelungstechnische Probleme gezeigt. Entsprechende Ansätze wurden bisher nur vereinzelt an einer semi-aktiven Vertikaldynamikregelung erprobt.

Ziel des Projekts war es, eine stärkere Automatisierung des Reglerauslegungsprozesses zu erreichen. Gleichzeitig soll das Potential von intelligenten Lernverfahren, insbesondere Reinforcement Learning, für die Regelung von semi-aktiven Dämpfern im Fahrwerksbereich bestimmt werden. Hierfür sollen auf der Basis von realen Messdaten und daraus abgeleiteten Systemmodellen intelligente Lernverfahren zur Auslegung des Reglers zum Einsatz kommen. Ziel ist es zudem, die Sicherheit des Systems im Betrieb mit einem Absicherungskonzept für die Umsetzung der gelernten Regler zu gewährleisten und damit die Praxistauglichkeit der entwickelten Konzepte am Versuchsträger in Prüfstandsversuchen und realen Versuchsfahrten zu demonstrieren.

Ablauf des Projekts und Ergebnisse

Das Versuchsfahrzeug AFM (AI for Mobility, einem straßenzugelassenen Versuchsfahrzeug mit Drive-By-Wire Kit) wurde mit den nötigen Sensoren und Aktuatoren sowie Rapid Control Prototyping (RCP) Systemen ausgerüstet. Durch umfangreiche Vermessung von sowohl Einzelkomponenten als auch dem gesamten Fahrzeug wurde eine umfassende Datenbasis für die Modellierung und das Lernen von Neuronalen Netzen geschaffen. Auf Basis dieser Messdaten wurden Komponentenmodelle und Modelle des gesamten Fahrzeugs erstellt. Bei der Modellierung des Dämpfers kamen sowohl datenbasierte Modellierungsmethoden basierend auf Neuronalen

Netzen als auch physikalisch motivierte Methoden zum Einsatz. Darüber hinaus wurden Fahrzeugmodelle in unterschiedlicher Komplexität und Simulationsdauer je nach Einsatzzweck erstellt. Für das Training des Reglers, den Reglerexport und die Reglervalidierung wurden neue Software-Werkzeugketten entwickelt oder bestehende Werkzeugketten für den Anwendungszweck umfassend erweitert und angepasst. Zur Ausführung des gelernten Reglers wurde innerhalb des Projekts ein neues und leistungsstarkes Steuergerät für die Vertikaldynamikregelung entwickelt und eine vorkompilierte Reglerbibliothek bereitgestellt. Um die sichere Ausführung des Reglers gewährleisten zu können, wurde ein Absicherungskonzept entwickelt und im realen Fahrversuch erprobt. Die Performance des in Simulation gelernten Reglers wurden sowohl qualitativ im realen Fahrversuch als auch quantitativ durch Messungen an einem Vertikaldynamikprüfstand bestätigt. Insgesamt wurde mittels Methoden des Reinforcement Learnings ein Regelgesetz gelernt, welches qualitativ und quantitativ einen Regler auf dem Stand der Technik in den meisten Anregungsszenarien übertreffen kann.

Nutzen und Anwendungsmöglichkeiten

In dem Vorhaben wurden Methoden der künstlichen Intelligenz aus der Wissenschaft - insbesondere aus dem Bereich des Reinforcement Learnings (RL) - in die praktische Anwendung für die Regelung und Abstimmung von semi-aktiven Dämpfern straßengebundener Fahrzeuge transferiert. Die Automatisierung des Reglerauslegungsprozesses mittels RL und der Generierung von Systemmodellen aus Messdaten bietet den Projektpartner KW automotive hochmoderne Methoden, um aktuelle und künftige Anforderungen der Märkte effizient zu bedienen. Durch die Zusammenarbeit zwischen KW automotive und dem DLR-Institut für Systemdynamik und Regelungstechnik wurde darüber hinaus bei KW automotive Wissen im Bereich der KI eingeführt und in die Praxis umgesetzt. Die Firma KW wurde somit dazu befähigt, KI-Anwendungen nicht nur zu nutzen, sondern auch zu verstehen, in einem nächsten Schritt weiterzuentwickeln und in ihre Produkte zu integrieren. Durch die Erprobung des Reglers auf einem Prototypensystem wurde die Anwendbarkeit von RL-basierten Reglern in der Praxis gezeigt.

Die KW automotive GmbH wird sich im Anschluss an das Kooperationsprojekt mit der Überführung des prototypischen Aufbaus in eine seriennahe Anwendung beschäftigen, um die beschriebenen Vorteile in Ihre Produkte einfließen zu lassen. Die Erfahrung aus vorangegangenen Forschungsprojekten zeigt hier einen zeitlichen Horizont von 2-3 Jahren bis zur Einführung der neuen Technologien (Prototypen – Vorserie – Serie).

Die entwickelten methodischen Ansätze werden im Anschluss an das Projekt innerhalb des beteiligten DLR-Instituts abstrahiert, optimiert und weiterentwickelt. Ziel des Instituts ist es weitere methodische Fortschritte im Bereich der KI-gestützten Regelungsmethoden in der Robotik, der Luft- und Raumfahrt sowie dem Automobil- und Schienenfahrzeugbereich zu erzielen.

**Eingehende Darstellung des Sachberichts für
das Projekt „KI-basierte Fahrwerksregelung KIFAHR“**

Autoren (rückwärts-alphabetisch sortiert):

DLR Institut für Systemdynamik und
Regelungstechnik, Oberpfaffenhofen

KW automotive GmbH, Fichtenberg

Ultsch, Johannes
Tobolar, Jakub
Ruggaber, Julian
Pfeiffer, Andreas
Kamp, Tobias
Brembeck, Jonathan
Baumgartner, Daniel

Ziegler, Marc
Wahl, Udo
Rohn, Michael
Koch, Mario
Klenk, Steffen

Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter dem Förderkennzeichen 01IS20010 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

Inhaltsverzeichnis

1	Durchgeführte Arbeiten und Ergebnisse	2
1.1	Aufgabenstellung und angeknüpfter wissenschaftlich technischer Stand	2
1.2	Projekttablauf	4
1.2.1	Ausrüstung und Vermessung des Versuchsträgers	5
1.2.2	Modellierung	17
1.2.3	Implementierung der Software-Toolketten	24
1.2.4	Entwicklung, Training und Integration des Regelsystems	26
1.2.5	Erprobung des Regelsystems	30
1.3	Zusammenfassung der Ergebnisse des Projekts	46
2	Ergänzende Angaben	46
2.1	Wichtigste Positionen des zahlenmäßigen Nachweises	46
2.2	Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten	46
2.3	Verwertbarkeit der Ergebnisse	47
2.4	Fortschritt auf dem Gebiet des Projekts bei anderen Stellen	48
2.5	Erfolge und geplante Veröffentlichungen	48
3	Beiträge der Autoren	49
4	Literatur	49

1 Durchgeführte Arbeiten und Ergebnisse

Im folgenden Kapitel werden sowohl die Aufgabenstellung des KIFahr Projekts in Abschnitt 1.1 zusammengefasst, als auch der Projektablauf in Abschnitt 1.2 dargestellt. Die Ergebnisse des Projekts werden abschließend in Abschnitt 1.3 zusammengefasst.

1.1 Aufgabenstellung und angeknüpfter wissenschaftlich technischer Stand

Für die Vertikaldynamikregelung von semi-aktiven Feder-Dämpfer-Elementen werden neuartige Regelungsansätze benötigt, welche im Zielkonflikt zwischen Komfort und Fahrsicherheit durch verschiedene Beladungen, unterschiedlichste Fahrbahnoberflächen, Reifentypen, Reifendrucke und Wetterbedingungen einen besseren Kompromiss als Regler nach dem Stand der Technik realisieren. Der bisher übliche Entwurf von Vertikaldynamikregler erfolgt modellbasiert. Dabei sind das Ableiten eines Synthesemodells und die Parametrierung des Reglers zeitaufwendige Aufgaben, die zudem Expertenwissen in verschiedenen Ingenieursdisziplinen erfordern. Viele Schritte im Auslegungsprozess sind dabei nicht oder nur schwer automatisierbar. Die Regelgüte hängt insbesondere von der Qualität des Synthesemodells ab. Hierbei muss die Parametrierung des Synthesemodells und des Reglers in Abstimmungsfahrten für jedes Fahrzeugmodell und jede Fahrzeugvariante erneut durchgeführt werden. Neben einer objektiven Grundauslegung am Prüfstand (limitiert auf vertikale Anregungen) muss zusätzlich die komplexe Gesamtfahrzeugabstimmung in Fahrversuchen subjektiv durch einen Testfahrer erfolgen, dessen Bewertung tagesabhängigen Schwankungen unterliegt.

Die herkömmliche Umsetzung einer semi-aktiven Vertikaldynamikregelung beinhaltet in der Praxis sowie in den meisten wissenschaftlichen Veröffentlichungen das Zusammenführen folgender Komponenten: Ein parametrisiertes Synthesemodell (meist ein so genanntes Viertelfahrzeugmodell), ein Regelansatz, der darauf abzielt eine Zielgröße zu minimieren sowie eine Auswahl an Sensorsignalen als Eingänge des Reglers. Der am häufigsten verbreitete Regelansatz für die Vertikaldynamik ist der Skyhook [1]. Er liefert besonders im Bereich der Aufbauresonanzfrequenz gute Regeleigenschaften. Zudem kann er durch Kombination mit Acceleration Driven Damping (ADD) oder mit frequenzabhängig adaptierter Regelverstärkung für mittlere und hohe Frequenzen verbessert werden [2]. Der Groundhook-Ansatz [1] ist hingegen das auf möglichst gute Straßenhaftung abzielende Verfahren. Ansätze basierend auf linearen parametervarianten (LPV) Systemen ermöglichen einerseits die Berücksichtigung von Nichtlinearitäten des Systems wie z. B. Dämpfer-Charakteristiken (Kraft zu Kolbengeschwindigkeit) und zum anderen die Adaption des Reglers abhängig von z. B. der aktuellen Einfederung oder der Straßenbeschaffenheit [2]. Meist werden im Regelansatz die Stellgrößenbeschränkungen semi-aktiver Dämpfer nicht explizit berücksichtigt. Stattdessen werden zur Laufzeit die vom Regler geforderten Stellgrößen auf den vom Dämpfer aktuell umsetzbaren Bereich beschränkt (Clipped Control). Mit einer modellprädiktiven

Regelung können die Dämpferbeschränkungen explizit berücksichtigt werden. Die so erreichte Steigerung der Regelgüte gegenüber Clipped Control wird jedoch durch einen deutlich erhöhten Rechenaufwand und der damit verbundenen Anforderung an das Steuergerät erkauft.

Methoden des maschinellen Lernens bieten die Möglichkeit, das Regelgesetz aus gemessenen Daten und der Interaktion mit System oder Simulation automatisiert zu lernen. Für den Regler stellen Methoden des Reinforcement Learnings (RL) einen vielversprechenden Ansatz dar. In mehreren Veröffentlichungen wurde bereits die Leistungsfähigkeit von RL-basierten Methoden für die Anwendung auf regelungstechnische Probleme gezeigt [3], [4]. Entsprechende Ansätze wurden bisher nur vereinzelt an semi-aktiver Vertikaldynamikregelung erprobt: In [5] wird basierend auf RL und Experimenten mit einem servo-hydraulischen Straßensimulator der Regler gelernt. In [6] wird – ausgehend von Simulationen eines Viertelfahrzeugmodells – unter Verwendung von Batch-RL der Regler gelernt. In [7] wird eine voll-aktive Vertikaldynamikregelung durch ein lernendes Verfahren auf Basis eines Neuro-Fuzzy-Systems vorgestellt. Im Gegensatz zum in [5], [6] vorgestellten RL-basierten Vertikaldynamikregler sind zu Beginn des Projekts wesentlich leistungsstärkere RL-Algorithmen, wie z. B. in [8] vorgestellt, verfügbar.

Ziel des Projekts ist es, eine stärkere Automatisierung des Reglerauslegungsprozesses zu erreichen. Gleichzeitig soll das Potential von intelligenten Lernverfahren, insbesondere Reinforcement Learning, für die Regelung von semi-aktiven Feder-Dämpfer-Einheiten im Fahrwerksbereich bestimmt werden. Hierfür sollen auf der Basis von realen Messdaten und hiervon abgeleiteten Systemmodellen intelligente Lernverfahren zur Auslegung des Reglers zum Einsatz kommen. Ziel ist es zudem, die Sicherheit des Systems im Betrieb mit einem Absicherungskonzept für die Umsetzung der gelernten Regler zu gewährleisten und damit die Praxistauglichkeit der entwickelten Konzepte am Versuchsträger in Prüfstandsversuchen und realen Versuchsfahrten zu demonstrieren.

Die zentralen wissenschaftlichen und technischen Zielsetzungen des geplanten Forschungsvorhabens lauten:

- Auf Basis von KI-Verfahren: Erhöhung der Sicherheit und des Fahrkomforts (teil-)autonomer Fahrzeuge, die mit semi-aktiven Dämpfern ausgestattet sind,
- Erfassung komplexer nichtlinearer Zusammenhänge im Gesamtfahrwerk durch den Einsatz von effizienten und robusten KI-Algorithmen,
- Automatische Erzeugung von Regelalgorithmen, die auf neuronalen Netzen basieren,
- Erstellung effizienter Software-Werkzeugketten für die Integration von KI-basierten Reglern zur Ausführung auf Seriensteuergeräten,
- Entwicklung von methodischen Ansätzen für die Gewährleistung der Betriebssicherheit von KI-basierten Reglern,

- Automatisierung der Fahrzeugabstimmung mittels maschinellen Lernens.

1.2 Projektablauf

Der Projektablauf leitet sich im Wesentlichen direkt aus den notwendigen Arbeitsschritten für das Training und die anschließende Erprobung eines Vertikaldynamikreglers mittels Reinforcement Learning Algorithmen ab. In Abbildung 1 ist ein Überblick über die Arbeitsschritte dargestellt.

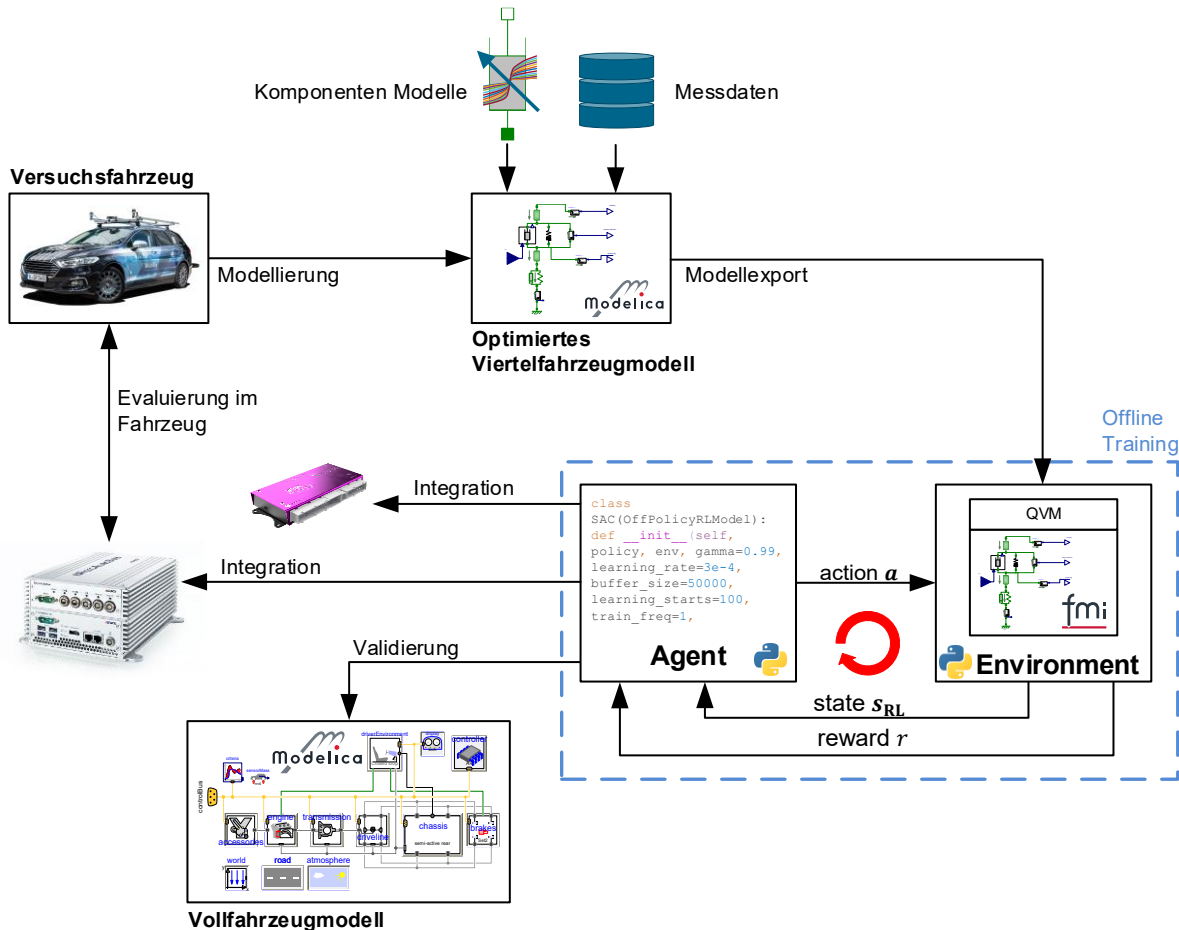


Abbildung 1: Überblick über das simulationsbasierte Training eines Vertikaldynamikreglers mit anschließender Validierung und Evaluierung im Fahrzeug

In der ersten Phase des Projekts wurde das Versuchsfahrzeug, der AFM [9], mit von KW gefertigten semiaktiven Dämpfern und zusätzlicher Mess- und Steuerungstechnik ausgerüstet. Die Ausrüstung sowie die Vermessung von sowohl Einzelkomponenten als auch des gesamten Fahrzeugs ist in Abschnitt 1.2.1 näher beschrieben.

Die auf den Messdaten basierende Modellierung des Fahrzeugs wird in Abschnitt 1.2.2 dargestellt. In Abschnitt 0 werden die zum Training, zum Reglerexport und zur modellbasierten Validierung verwendeten Software-Werkzeugketten erläutert. Das Training des Vertikaldynamikreglers, die Auslegung eines Referenzreglers sowie das implementierte Absicherungskonzept werden

anschließend in Abschnitt 1.2.4 zusammengefasst. Im letzten Abschnitt 1.2.5 werden die Ergebnisse aus simulativen und realen Erprobungen dargestellt und diskutiert.

1.2.1 Ausrüstung und Vermessung des Versuchsträgers

Als Versuchsträger für das KIFAHR Projekt wurde das Fahrzeug AI-For-Mobility (AFM) [9], [10], [11] ausgewählt. Für die Umsetzung neuartiger Regelungsalgorithmen wurde das Serienfahrzeug unter anderem mit einem Drive-by-Wire Kit, semi-aktiven Dämpfern der Firma KW automotive, einem Rapid Control Prototyping (RCP) System und weiterer Sensorik ausgerüstet. Die komplette Architektur des Versuchsträgers ist in 1.2.1.1 beschrieben. In 1.2.1.2 und 1.2.1.3 sind die Vermessung von Einzelkomponenten und des gesamten Fahrzeugs dargestellt. Voruntersuchungen für die Integration von neuronalen Netzen auf dem KW embedded Seriensteuergerät sowie die Entwicklung eines leistungsstärkeren Steuergeräts sind in 1.2.1.4 zusammengefasst.

1.2.1.1 Architektur des Versuchsträgers

Der AFM ist ein neues Testfahrzeug zur Erforschung und Umsetzung neuartiger Regelungsmethoden auf Basis von Künstlicher Intelligenz (KI) beim Institut SR am DLR. Als Basisfahrzeug dient ein Serien-Hybridfahrzeug. Da KI-basierte Verfahren datengetrieben sind, ist das Fahrzeug mit einer Vielzahl von Sensoren ausgestattet, um die benötigten Daten bereitzustellen. Eine vollständige By-Wire-Steuerung ermöglicht den Einsatz des Fahrzeugs für Anwendungen im Bereich des automatisierten Fahrens. Trotz aller Modifikationen ist es für den öffentlichen Straßenverkehr zugelassen und erfüllt die fahrdynamischen Eigenschaften eines normalen Straßenfahrzeugs. Dies macht den AFM zu einer attraktiven Testplattform als Versuchsträger im Rahmen des Projekts KIFAHR.



Abbildung 2: Der Versuchsträger AI For Mobility (AFM).

Um Untersuchungen zur Vertikaldynamikregelung auf dem AFM darstellen zu können, wurde das Fahrzeug im Projekt KIFAHR mit semi-aktiven Dämpfern von KW ausgerüstet und weitere

Umbauten am Fahrwerk vorgenommen. Das Ziel bei diesem Umbau war, dieselbe Fahrzeughöhe wie beim Basisfahrzeug beizubehalten, um den AFM möglichst nahe an vergleichbaren Serienfahrzeugen zu orientieren. Hierfür wurde eine entsprechende Sonderanfertigung der Dämpfer, vom Gehäuse bis zur Kolbenstange, durch KW konstruiert und angefertigt, siehe Abbildung 3.



Abbildung 3: Die von KW konstruierten Dämpfer als CAD Modell (links) sowie die angefertigten Dämpfergehäuse (rechts).

Zur exakten Messung der Dämpfergeschwindigkeit wurde an der Vorder- und Hinterachse Linearpotentiometer parallel zu den Dämpfern integriert. Die exakte Bestimmung der Dämpfergeschwindigkeit ist insbesondere für semiaktive Dämpfer eine entscheidende Aufgabe: Kräfte können nur entgegen der Bewegungsrichtung der Dämpfer gestellt werden. Aus diesem Grund ist die Kenntnis speziell über die Bewegungsrichtung der Dämpfer entscheidend für die Regelung. Die Integration der Linearpotentiometer an Vorder- und Hinterachse sind in Abbildung 4 und Abbildung 5 dargestellt.

Die Domlager besitzen eine komplexe Charakteristik (6D-Dämpfung, Frequenzabhängigkeit). Um das Vertikaldynamikregelungspotential der Dämpferregelung isoliert untersuchen zu können, sowie ein präziseres und direkteres Fahrverhalten des AFMs zu ermöglichen, wurden die Serien-Domlager an der Vorderachse gegen ein Uniball-Lager ausgetauscht.

Die Dämpfer werden über ein eingebettetes Steuergerät angesteuert. Vertikaldynamikregler können entweder stand-alone auf dem KW embedded Seriensteuergerät gerechnet werden oder auf einem RCP-System, welches die Soll-Ströme an ein embedded Steuergerät schickt. Auf diesem

ist der Stromregler implementiert und regelt den Sollstrom am Dämpferventil ein. Diese Architektur ermöglicht die direkte Kompatibilität mit dem Steuergerät von KW.



Abbildung 4: Federbeim Vorderachse mit Linearpotentiometer




Abbildung 5: Dämpfer an der Hinterachse mit Linearpotentiometer

Das modifizierte Fahrwerk wurde von einer unabhängigen technischen Prüfstelle freigegeben, sodass auch mit geregelten Dämpfern eine Zulassung für den öffentlichen Straßenverkehr für den AFM vorliegt.

Zur Erfassung der für die Vertikaldynamikregelung relevanten Größen ist der AFM ausgestattet mit:

- **Beschleunigungssensoren in Vertikalrichtung**
 - 4× Dämpfergehäuse, 3× Body, 1× Motorblock
- **Potentiometer zur Messung von Auslenkungen**
 - Linearpotentiometer: 4× Dämpferweg, 3× Motorblockbewegungen
 - Rotationspotentiometer: 4× Einfederung über die Auslenkung des Querlenkers (Vorderachse) bzw. des Längslenkers (Hinterachse) relativ zum Hilfsrahmen.
- **Messung des Dämpfersollstroms**
 - 4× über die Leistungsendstufe auf dem KW Steuergerät, worüber die Soll-Ströme eingeregelt werden.

Die Erfassung der Motorbewegung ist über drei Linearpotentiometer umgesetzt. Diese sind, zwischen einem eigens hierfür angefertigten Hilfsrahmens unterhalb des Motorraums, und der

Aggregateinheit, angebracht. Die Geometrie des Hilfs-Rahmen sowie die Positionierung der Potentiometer wurden durch KW mithilfe eines 3D-Scanners am Fahrzeug aufgezeichnet und anschließend dem DLR als Datensatz zur Verfügung gestellt, siehe Abbildung 6.




Abbildung 6: Aufbereitete 3D-Scandaten der AFM Vorderachse

1.2.1.2 Vermessung von Komponenten

Für die Modellierung der Vertikaldynamik des Fahrzeugs sind neben der Kenntnis über die physikalischen Prinzipien der Einzelkomponenten Messdaten zu verschiedenen Fahrwerkskomponenten hilfreich und teils sogar notwendig. Für die Vermessung von Einzelkomponenten steht bei KW eine Dämpfer-Prüfmaschine, wie in Abbildung 7 dargestellt, zur Verfügung. In Verbindung mit extra gefertigten Adapterkomponenten können mit diesem Prüfstand neben der standardmäßigen Vermessung von Dämpfern auch andere Komponenten vermessen werden.



Abbildung 7: Dämpfer-Prüfmaschine bei KW

Für die Modellierung der Einzelkomponenten wurden folgende Messungen vorgenommen:

- Vermessung des Dämpferkennfelds und der Ventildynamik der semiaktiven Dämpfer
- Vermessung der Domlagersteifigkeiten und dessen dynamischen Eigenschaften
- Vermessung des Gummimetallements am Dämpfer der Hinterachse
- Vermessung des Gummipuffers (Endanschlag) der Dämpfer
- Vermessung der Federsteifigkeiten an Vorder- und Hinterachse
- 3D Scan verschiedener Achsbauteile via Flächenrückführung von photogrammetrischer Vermessung

Aus der Vermessung des Dämpfers ergab sich ein charakteristisches Kennfeld, welches exemplarisch für den Dämpfer vorne links in Abbildung 8 dargestellt ist. Hierbei wurden die wirkenden Dämpferkräfte bei verschiedenen konstanten Ventilströmen und definierten Dämpfergeschwindigkeiten ermittelt.

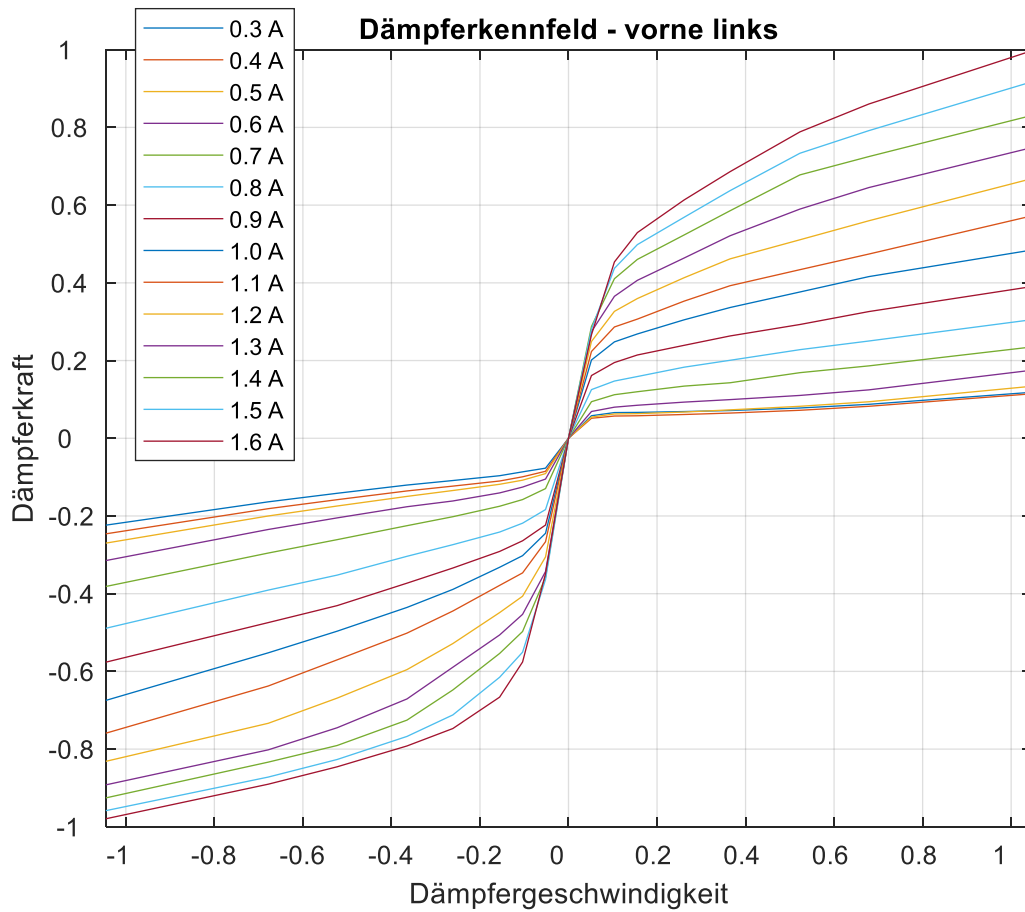


Abbildung 8: Dämpferkennfeld mit normierten Skalen, ermittelt für verschiedene konstante Ströme

Neben dem statischen Dämpferkennfeld sind die dynamischen Eigenschaften des Dämpferventils und die damit verbundene Dynamik der Dämpferkraft von Interesse. Hierbei greifen 2 dynamische Systeme ineinander: Zum einen stellt ein Stromregler mittels PWM einen vorgegebenen Sollstrom in einem elektrischen Regelkreis ein. Die Dämpferkraft ergibt sich aus der durch den Strom in einer Spule induzierten Magnetkraft und der daraus eingestellten Ventilposition. Die Messergebnisse für einen Sprung im Sollstrom bei einer konstanten Dämpfergeschwindigkeit sind in Abbildung 9 dargestellt. Deutlich zu sehen ist die deutlich schnellere Dynamik des Sollstroms im Vergleich zur mechanischen Einstellung der Dämpferkraft.




Abbildung 9: Ventildynamik bei konstanter Dämpfergeschwindigkeit

Um die Einflüsse des mit dem Hinterachsdämpfer in Reihe geschalteten Domlagers und Gummimetallelements zu untersuchen, wurden sowohl die statischen als auch dynamischen Eigenschaften mittels Adaptervorrichtungen am KW Dämpferprüfstand gemessen. Die Messaufbauten sind in Abbildung 10 und Abbildung 11 dargestellt.



Abbildung 10: Messaufbau für die Vermessung des Domlagers der Hinterachse




Abbildung 11: Messaufbau für die Vermessung des Gummimetallements der Hinterachse

1.2.1.3 Vermessung des Vollfahrzeugs

Als Grundlage für die Modellierung der Vertikaldynamik des Fahrzeugs wurden umfangreiche Messdaten erhoben. Ein spezieller Prüfstand, der mit hydraulischen Stempeln vertikale Anregungen erzeugt, gewährleistet die Reproduzierbarkeit der Anregungen und die Vergleichbarkeit der Daten. Die einzelnen Stempel können jeweils unterschiedliche, also *asynchrone* oder dieselben, d.h. *synchrone* Anregungen aufprägen. Zur Analyse des Schwingverhaltens des Fahrzeugs werden standardmäßig synchrone, harmonische Sinus-Schwingungen mit steigender Frequenz und unterschiedlichen Amplituden verwendet, sog. Sine-Sweeps. Diese Anregungsprofile erlauben eine Charakterisierung im Frequenzbereich, z.B. mithilfe von Übertragungsfunktionen. Im

Rahmen der Messkampagnen wurden Sine-Sweeps mit fünf verschiedenen Intensitäten (Amplituden) verwendet. Für die Validierung der Modellierung und zur Analyse der trainierten Regler können weiterhin realistische Straßenprofile erzeugt und zur Anregung verwendet werden. Die zugrundeliegende Norm ISO 8608 [12] unterscheidet verschiedene Straßentypen, von denen Typ A (sehr gute Bedingungen) bis Typ D (Schlechtwegstrecke) verwendet wurden. Um die Modellierung des semi-aktiven Fahrwerks abzusichern, wurde das Fahrzeug mit den beschriebenen Anregungen jeweils für fünf verschiedene, konstante Dämpferströme vermessen. Die (relevanten) erhobenen Messsignale sind in Tabelle 1 aufgelistet. Da sowohl auf dem RCP (Rapid Control Prototyping)-System im Fahrzeug, als auch am Prüfstand Messdaten aufgezeichnet wurden, mussten die Signale im Nachhinein zeitlich synchronisiert werden. Zu diesem Zweck wurde ein Rechtecksignal auf beiden Systemen aufgezeichnet, welches die automatisierte Berechnung und Korrektur des zeitlichen Versatzes ermöglichten.

Messgröße	Anzahl der Signale	Sensor	Bemerkungen
Stempelposition	4	n.b.	Prüfstandsinterne Sensorik
Stempelgeschwindigkeit	4	n.b.	
Stempelbeschleunigung	4	Acc-Sensor	
Radlasten	4	Kraft-Messdosen	
Radbeschleunigungen	4	Acc-Sensor	-
Chassisbeschleunigungen	3	Acc-Sensor	hinten nur ein Sensor
Relativweg Rad-Chassis	4	Linearpotentiometer	-
Motorauslenkung	3	Linearpotentiometer	-
Motorbeschleunigung	1	Acc-Sensor	-
Dämpferweg	4	Rotationspotentiometer	Umrechnung Dämpferweg mit entsprechender Übersetzung
Einfederung der Reifen	2	Lasersensor	einmal vorne und einmal hinten
Dämpferströme	4	Hall-Sensoren	-

Tabelle 1: Die erhobenen Messdaten zur Charakterisierung des Fahrzeugs.

1.2.1.4 Entwicklung eines leistungsstärkeren Steuergeräts

Der Projektpartner KW hat für das DDC Gewindefahrwerk bereits ein selbst entwickeltes Steuergerät auf Basis eines ARM Cortex-R4F Prozessors im Einsatz. Zu Beginn des Projekts wurden nun die Laufzeiten verschiedener Größen von neuronalen Netzen auf dem aktuellen Steuergerät

getestet. Die Abtastzeit für die Vertikaldynamikregelung beträgt bisher 1ms. Diese sollte auch für das KIFahr Projekt beibehalten werden.

Die exakte Größe und Struktur des Neuronalen Netzes, welches als Regler fungiert, ist während des Trainings ein Design-Freiheitsgrad und war deshalb zu Beginn des noch Projekts unbekannt. Für die Laufzeitanalyse wurde angenommen, dass ein einziges Neuronales Netz das Regelgesetz für alle 4 Dämpfer abbildet. Es wurde angenommen, dass alle bereits vorhandenen Signale als Eingangsgrößen des Netzes verwendet werden: 4x Radbeschleunigungen, 4x Dämpferweg, 4 Dämpfergeschwindigkeit, 3x Aufbaubeschleunigung, Längs- und Querschleunigung (= 17 Signale). Um die Laufzeit der kompletten Software zu betrachten, wurde der KW Vertikaldynamikregler durch das jeweilige zu testende Neuronale Netz ersetzt. Da die restlichen Softwarekomponenten (Stromregler, Sensordatenverarbeitung, etc.) auch beim Betrieb des gelernten Reglers später notwendig sind, kann so die Gesamtlaufzeit abgeschätzt werden. Bei der Auswahl der Netzgrößen für den Laufzeittest haben wir uns an der Netzgröße aus der originalen Veröffentlichung des Soft Actor-Critic (SAC) Algorithmus [8] orientiert (#Input - 256 - 256 - #Output, Aktivierungsfunktion: ReLU).

Die Ergebnisse der Laufzeittests sind in der folgenden Tabelle dargestellt:

Schichten (#Inputs - #Neurons Hidden Layers - ... - #Outputs)	Aktivierungs- funktion	Gesamtlaufzeit (Neuronales Netz + restliche Software- komponenten) [ms]	Speicherbedarf [% Auslastung]	
			RAM	FLASH
17 - 256 - 4	Sigmoid	≈ 2,0 - 2,1	20,8	24,5
17 - 64 - 4	Sigmoid	≈ 0,6	12	22,4
17 - 32 - 4	Sigmoid	≈ 0,4	10,5	22,1
17 - 256 - 4	ReLU	≈ 1,8 - 1,9	20,8	24,4
17 - 64 - 4	ReLU	≈ 0,6	12	22,4
17 - 32 - 4	ReLU	≈ 0,4	10,5	22
17 - 32 - 32 - 4	ReLU	≈ 0,7	12,7	22,6
17 - 32 - 32 - 32 - 4	ReLU	≈ 1,0 - 1,1	14,9	23,1

Es zeigt sich, dass die angestrebte Abtastzeit von 1ms bereits mit einer verdeckten Schicht mit 256 Neuronen unabhängig von der Aktivierungsfunktion überschritten wird. Somit könnte auf dem Steuergerät bei weitem nicht die Netzgröße aus der originalen Veröffentlichung des Soft Actor-Critic (SAC) Algorithmus echtzeitfähig ausgeführt werden. Aus diesen Gründen wurde bereits zu Beginn des Projekts die Entwicklung eines leistungsstärkeren Steuergeräts begonnen.

Da das bestehende KW DDC ECU Steuergerät nicht über genügend Rechenleistung und Speichergröße verfügt, um die KI-basierte Regelung zu integrieren, wurde auf dieser Grundlage die Entwicklung einer geeigneten Hardware vorangetrieben.

Bei der Ausarbeitung möglicher Lösungsansätze wurde zunächst nach stärkeren Mikrocontrollern der eingesetzten Controller-Familie recherchiert. Der Hersteller Texas Instruments gliedert seine ARM-basierten Microcontroller-Units (MCU) anhand der Speichergrößen und der CPU-Taktung. Diese beiden Größen sind auch im vorliegenden Fall die relevanten Parameter.

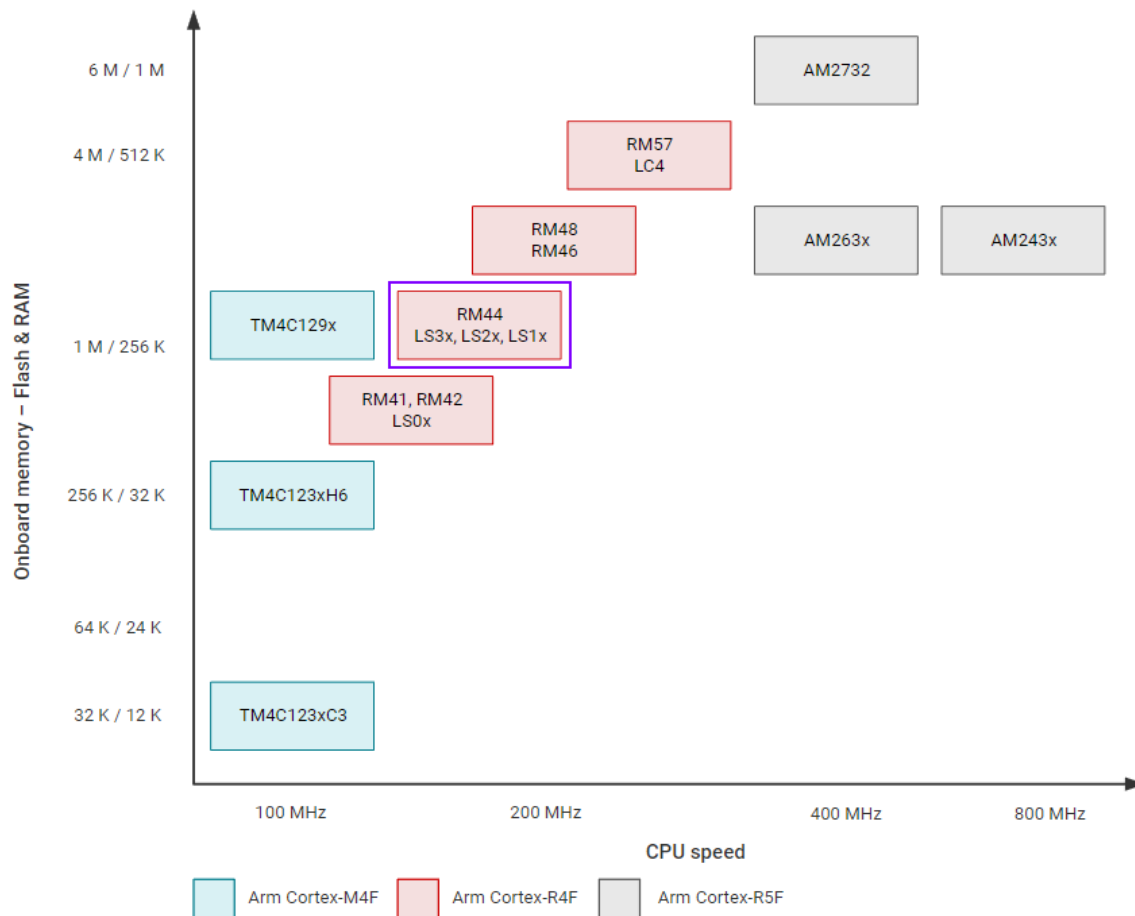


Abbildung 12: ARM-basierte Mikrocontroller-Übersicht. Quelle Texas Instruments

Verwendung findet aktuell ein Arm Cortex-R4F aus der LS1x-Gruppe mit folgenden Haupt-Spezifikationen Verwendung.

TMS570LS1114 // 144-LQFP

CPU-Taktung	160MHz
Rechenleistung	1,66DMIPS/MHz
Flash-Speicher	1024KB
RAM-Speicher	128KB
EEPROM-Speicher	64KB

Anzahl an Analogeingängen	24 (12-bit)
Anzahl an GPIOs	64

Die Auswahl eines performanteren Modells erfolgte aus der höchsten Gruppe aus derselben Prozessor Architektur, ein LC4 Typ.

TMS570LC4357 // NFBGA-337

CPU-Taktung	300MHz
Rechenleistung	1,66DMIPS/MHz
Flash-Speicher	4096KB
RAM-Speicher	512KB
EEPROM-Speicher	128KB
Anzahl an Analogeingängen	42 (12-bit)
Anzahl an GPIOs	168

Zur Bewertung der Rechenleistung befindet sich in den Datenblättern der Controller die Angabe der Dhrystone-Leistung in DMIPS/MHz. Dabei handelt es sich um einen standardisierten Benchmark, der die Ausführungszeit der Controller-Instruktionen angibt. Dies zielt darauf ab, die tatsächliche Rechenleistung zu bestimmen, und nicht nur CPU-Taktungen zu vergleichen.

Die beiden zu vergleichenden Microcontroller arbeiten allerdings beide mit 1,66DMIPS/MHz, da sie auf derselben Prozessorarchitektur basieren. Nimmt man jedoch die höhere CPU-Taktung des stärkeren Derivats in die Betrachtung mit auf, ergibt sich eine deutliche Steigerung von +87,5%. Um der höheren Anzahl an Ein- & Ausgangssignalen Rechnung zu tragen, kann der stärkere Microcontroller zudem mit deutlich mehr Anschlusskontakten aufwarten. Dadurch stehen sowohl mehr analoge als auch digitale zur Verfügung. Möglich ist dies durch eine andere Bauform (NFBGA), bei welcher die Anschlüsse über kleine Kugeln nach unten in die Platine weggeführt werden. Dadurch können auf derselben Fläche deutlich mehr Signale weggeführt werden als bei der klassischen LQFP Bauform.

Mit den größeren Flash- und RAM-Speicherbereichen steht nun auch die vierfache Größe für die Implementierung der neuen KI-basierten Regelansätze und neuronalen Netze zur Verfügung.

1.2.2 Modellierung

Für die Modellierung der dynamischen Eigenschaften des Systems stehen verschiedene Modellierungsansätze zur Verfügung: Modellierung auf Basis physikalischer Gesetze, datengetriebene Modellierung anhand von Messdaten und Mischformen aus beiden. Die Modellierung

dynamischer Systeme auf Basis physikalischer Gesetze ist beim beteiligten DLR-Institut seit Jahrzehnten etabliert und mit der Modellierungssprache Modelica und den etablierten Modelica Entwicklungsumgebungen stehen mächtige und erprobte Software-Werkzeugketten zur Verfügung. Vorteil der physikalischen Modellierung ist die Fähigkeit zur Extrapolation sowie die Robustheit des Modells. Oft notwendige Modellvereinfachungen begrenzen jedoch häufig die Modellgüte. Im Gegensatz hierzu können datenbasierte Methoden die Messdaten oft wesentlich genauer nachempfinden. Die auf einem Datensatz gelernten Modelle liefern meist nur innerhalb des Messbereichs sinnvolle Simulationsergebnisse. Darüber hinaus wird beim Training nur das Ein- und Ausgangsverhalten gelernt und physikalische Zwischengrößen werden nicht direkt berechnet. Mischformen aus beiden Ansätzen, sogenannte hybride Ansätze, sind noch Gegenstand der Forschung und werden in diesem Projekt nicht betrachtet.

In den folgenden Kapiteln werden zum einen das Komponentenmodell für den semiaktiven Dämpfer, das effiziente Fahrzeugmodell für das Training des Reglers sowie ein umfassendes Vollfahrzeugmodell für die Validierung des Reglers beschrieben.

1.2.2.1 Dämpfermodell

Das Dämpfermodell bildet die zentrale Komponente bei der Modellierung der Vertikaldynamik. Aufgrund von komplexen Strömungs-, Reibungs- und Magnetisierungsphänomenen ist es nicht möglich ein physikalisch genaues Modell abzuleiten, welches in annehmbarer Zeit simuliert werden kann. Aus diesem Grund wurden innerhalb des KIFahr Projekts zwei Ansätze verfolgt: Einerseits wurde ein datenbasiertes Modell über Supervised-Learning Methoden als sogenannte rekurrente Neuronale Netze (RNN) gelernt. Andererseits wurde ein vereinfachtes physikalisches Modell erstellt. Das vereinfachte physikalische Modell ist eine geringfügig abgeänderte Version des in [13] beschriebenen „Force map based model“.

Da datenbasierte Modelle oft nur schlechte Extrapolationseigenschaften aufweisen, war die Erstellung eines hinreichend großen Datensatzes notwendig. Hierzu wurde der Dämpfer mit verschiedenen Geschwindigkeitsprofilen in der Dämpferprüfmaschine (vgl. Kapitel 1.2.1.2) angeregt. Gleichzeitig wurden zeitlich und betragsmäßig randomisierte Sollströme vorgegeben. So wurde ein möglichst großer Bereich innerhalb des Arbeitsbereichs abgetastet. Als Neuronale Netze wurden für das Training sowohl die *Gated Recurrent Unit* (GRU) als auch ein Ansatz basierend auf *Nonlinear Autoregressive Exogenous Models* (NARX) verwendet und miteinander verglichen. Exemplarische Ergebnisse des Vergleichs sind in Abbildung 13 dargestellt.

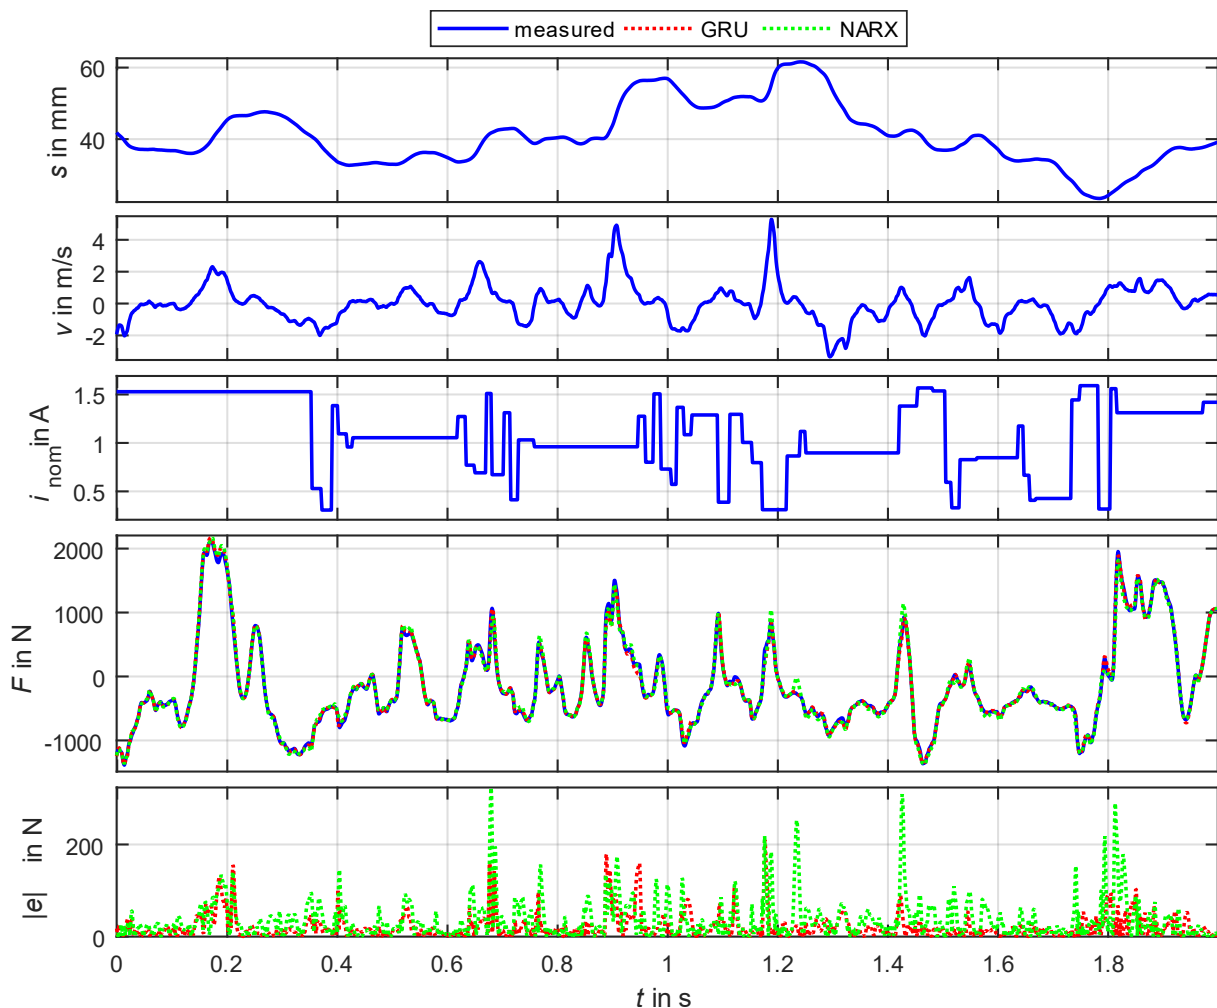


Abbildung 13: Vergleich datenbasierter Dämpfermodelle basierend auf GRU und NARX

Trotz der guten Ergebnisse der datenbasierten Modelle wurden für das Trainingsmodell und das Vollfahrzeugmodell letztendlich das vereinfachte physikalische Modell verwendet. Die Entscheidung für die Verwendung des vereinfachten physikalischen Modells ist damit begründet, dass einerseits bei den datenbasierten Modellen grundlegende physikalische Eigenschaften nicht sichergestellt werden konnten. Es konnte beispielsweise nicht sichergestellt werden, dass bei dem passivem Dämpferelement nur der Bewegung entgegengerichtete Kräfte berechnet werden. Andererseits war die Unsicherheit, dass während des Reglertrainingsprozesses doch Zustände außerhalb des abgetasteten Zustandsraumes erreicht werden, zu groß.

Das physikalische Dämpfermodell wurde anhand der verschiedenen Messdaten parametrisiert und optimiert.

1.2.2.2 Trainingsmodell: Struktur und Parameteridentifikation

Als zweckmäßige Systemmodelle für das Training der KI-basierten Regleragenten boten sich Modelle an, die die Vertikaldynamik des Fahrzeugs an einem der vier Räder näherungsweise

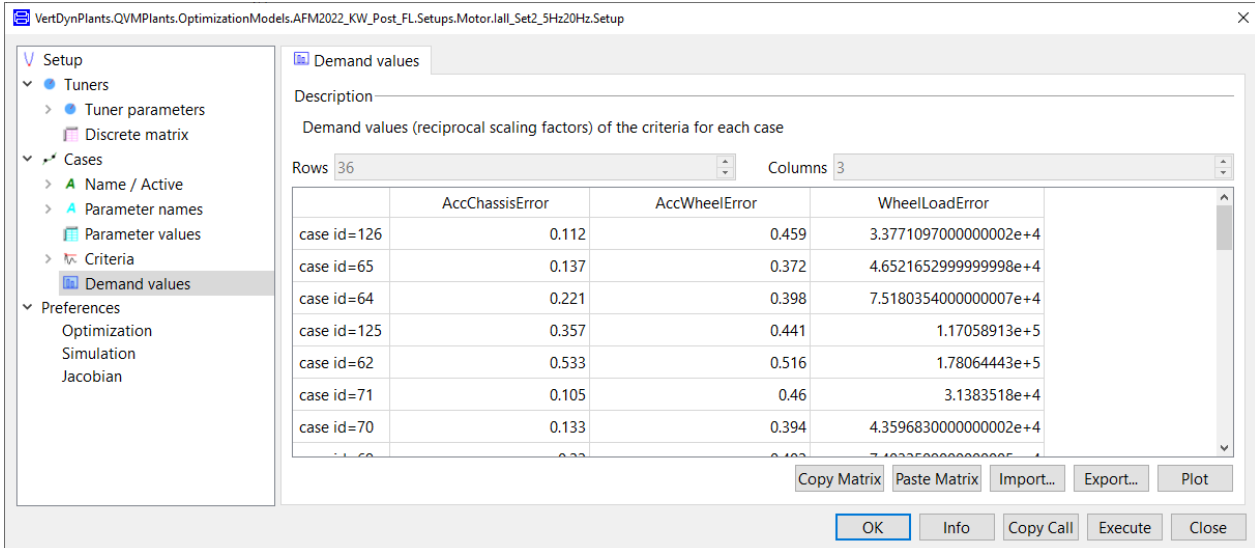
beschreiben. Diese Modelle – im Folgenden „Viertelfahrzeugmodelle“ genannt – zeichnen sich durch eine relativ einfache und reduzierte Modellstruktur ohne Kopplungseffekte mit dem gesamten Fahrzeug und insbesondere den anderen Rädern aus. Vorteile sind die wesentlich schnellere Simulationszeit eines Viertelfahrzeugmodells im Vergleich zu einem Modell, das das gesamte Fahrzeug beschreibt, sowie eine einfachere Parameteridentifikation für ein Viertelfahrzeugmodell. Die vereinfachten Modellannahmen wurden als ausreichend für die Auslegung und das Training von Vertikaldynamikreglern erachtet.

Die Viertelfahrzeugmodelle wurden für verschiedene Modellstrukturen in einer Modelica-Bibliothek aufgebaut, da von vornherein nicht klar war, mit welcher Zusammenschaltung von Komponentenmodellen die besten Ergebnisse im Vergleich zu dem realen Verhalten des Versuchsträgers erzielt werden konnten. Basis für alle Viertelfahrzeugmodelle bildete ein Zweimassensystem, je eine Masse für Rad und Aufbau, mit dem Dämpfermodell beschrieben in 1.2.2.1, einer linearen Feder, einer nichtlinearen Übersetzungskinetik für Feder und Dämpfer und einem linearen Feder-Dämpfermodell für die Reifeneigenschaften. Aufbauend auf diesem Basismodell wurden folgende Varianten untersucht:

1. Basismodell ohne Erweiterungen
2. Basismodell mit linearem Domlagermodell am Dämpfer
3. Basismodell mit Motormasse und linearem Motorlagermodell
4. Basismodell mit linearem Domlagermodell am Dämpfer und mit Motormasse und linearem Motorlagermodell

Für jede der Modellstrukturen eines Viertelfahrzeugmodells wurden Optimierungssetups erstellt, um die Modellparameter der Modellstrukturen so zu bestimmen, dass das Verhalten der Modelle möglichst gut mit den Messergebnissen des Versuchsträgers (siehe Abschnitt 1.2.1.3) übereinstimmt. Aus der Vermessung des Versuchsträgers (Vollfahrzeug) war das vertikale Verhalten des Fahrzeugs an jedem Rad für zahlreiche Anregungszeitverläufe bekannt. Die Anregung war hierbei die vertikale Position des Bodens, auf dem das Rad steht. In die Optimierungssetups, die für die Optimization Library [14] in Dymola geschrieben wurden, wurden schrittweise immer mehr Anregungsfälle mit aufgenommen, um eine möglichst breite Abdeckung der Modellgüte über die verschiedenen Anregungen hinweg zu erreichen. Da in diesem Anwendungsfall ca. 35 Anregungsfälle für vier verschiedene Modellstrukturen und vier Räder zu zahlreichen Optimierungssetups führten, wurde das Erstellen der Setups als übergeordnete Aufgabe automatisiert. Die Dimension an Messdaten kombiniert mit den verschiedenen Modellstrukturen ging über eine klassische Parameteridentifikationsaufgabe deutlich hinaus.

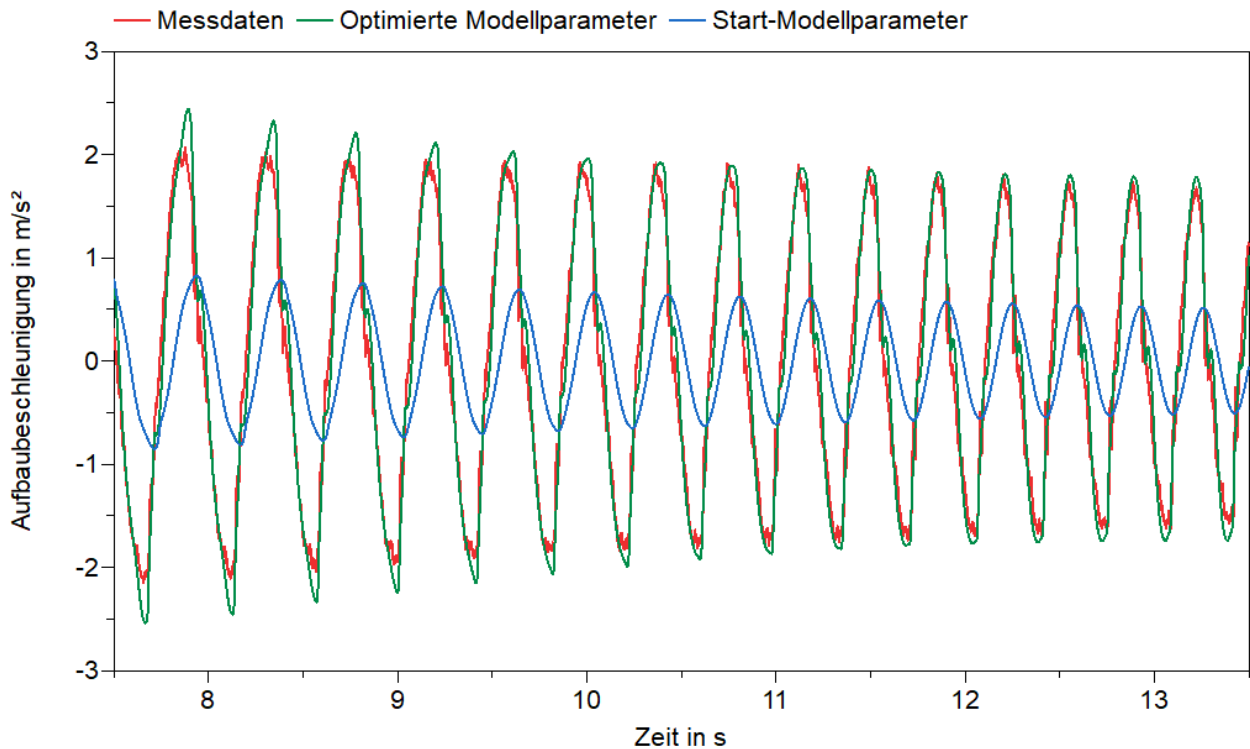
Nachfolgend ist ein graphisch aufbereiteter Teil eines Optimierungssetups dargestellt, bei dem einige der Anregungsfälle (mit unterschiedlicher id) mit ihren Gewichtungsfaktoren für die Kriterien zu erkennen sind.



	AccChassisError	AccWheelError	WheelLoadError
case id=126	0.112	0.459	3.3771097000000002e+4
case id=65	0.137	0.372	4.6521652999999998e+4
case id=64	0.221	0.398	7.5180354000000007e+4
case id=125	0.357	0.441	1.17058913e+5
case id=62	0.533	0.516	1.78064443e+5
case id=71	0.105	0.46	3.1383518e+4
case id=70	0.133	0.394	4.3596830000000002e+4
case id=66	0.22	0.403	7.1033500000000005e+4

Als Kriterien zur Bewertung, wie gut Simulationsergebnisse eines Modells mit Messdaten übereinstimmen, wurden die Integrale der quadratischen Abweichungen in der dynamischen Radlast, der Aufbaubeschleunigung und der Radbeschleunigung ausgewählt. Die für die numerische Optimierung notwendige skalare Zielfunktion wurde als gewichtete Summe der Kriterien über alle Anregungsfälle definiert. Die Gewichtungsfaktoren wurden automatisch aus den Verläufen der Messdaten errechnet. Als Optimierungsverfahren zur Minimierung der Zielfunktion zeigte sich ein Pattern-Search-Ansatz, der in der Optimization Library angeboten wird, als zweckmäßig.

In einem aufwändigen Prozess wurden zahlreiche Optimierungsläufe – teilweise auf einem Rechencluster – durchgeführt und iterativ verbessert, um schlussendlich eine Modellstruktur auszuwählen, die die besten Ergebnisse für eine repräsentative Auswahl an Anregungsverläufen erzielte. Bei der Berechnung der Simulationläufe der Modelle für verschiedene Anregungen konnten stark die Parallelisierungsfunktionalitäten der Optimization Library ausgenutzt werden. Je nach Modellstruktur wurden zwischen vier und 14 Modellparameter für jedes Rad identifiziert. Beispielhaft ist nachfolgend der Vergleich für ein optimiertes, ausgewähltes Viertelfahrzeugmodell für vorne links am Fahrzeug zu einer einzelnen Anregung (id = 44) dargestellt:



Im Vergleich zu den Messdaten der Aufbaubeschleunigung (rote Linie) konnte durch die Optimierung der Modellparameter eine gute Deckungsgenauigkeit des Modells (grüne Linie) erreicht werden. Zu Vergleichszwecken ist auch die Aufbaubeschleunigung des Modells mit den Startparametern (blaue Linie) eingezeichnet. Es ist klar ersichtlich, dass die Startparameter zu keiner hinreichenden Modellgüte führten – im Gegensatz zu den optimierten Parametern.

1.2.2.3 Vollfahrzeug Validierungsmodell

Die finale Validierung der Regler erfolgte mithilfe eines komplexen räumlichen Mehrkörper-Fahrzeugmodells. Das Fahrzeugmodell beinhaltet ein nichtlineares Reifenmodell, Mehrkörper-Radaufhängungen mit Modellen der semiaktiven Dämpfer, Stabilisatoren und die Lenkung, siehe Abbildung 14.




Abbildung 14: Das CAD-Modell der Vorder- und Hinterachse des AFMs (links) sowie die Visualisierung des Gesamtfahrzeugmodells in Modelica (rechts).

Auch die Ein- und Ausfederungsanschlüsse der Dämpfer wurden modelliert. Diese kommen insbesondere beim Überfahren größerer Einzelhindernisse (wie z.B. einer „Sinuswelle“) zur Geltung, da die Dämpferbewegungen hierbei voll ausgeschöpft werden.

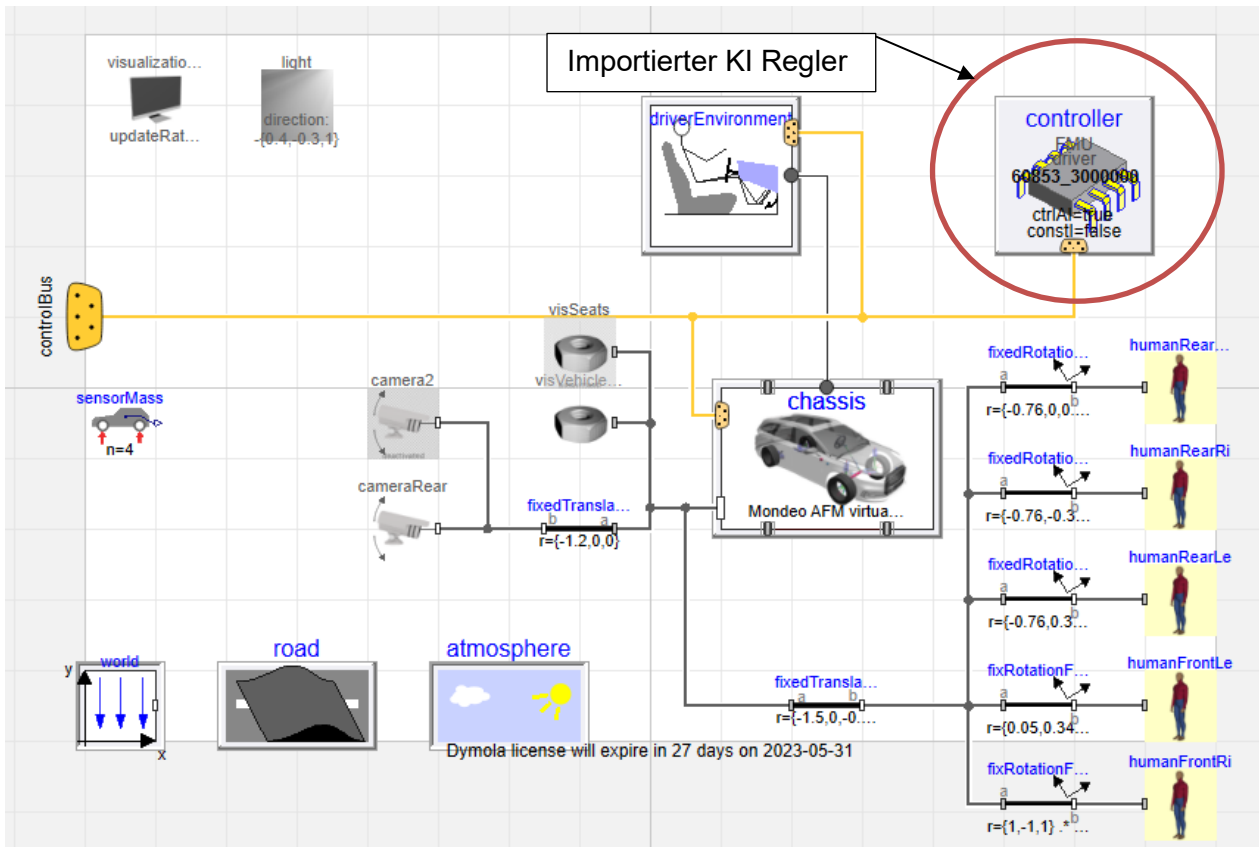


Abbildung 15: Vollfahrzeug Simulationsmodell mit importierten KI-Regler mittels FMI-Schnittstelle

Das komplette Modell wurde in Modelica erstellt (siehe Abbildung 15), wobei die Mehrheit der Submodelle, wie z.B. das Reifenmodell, bereits aus früheren Arbeiten und Projekten im Modellbaukasten des DLR-Projektpartners vorhanden war. Einige Submodelle, v.a. die Modelle der semiaktiven Dämpfer, wurden dagegen neu implementiert. Ein signifikanter Anteil der Modellierung bestand daher in der Parametrierung, Zusammenstellung und Abstimmung des Fahrzeugmodells. Für das Fahrzeugmodell werden mehrere hundert Parameter zur Kalibrierung benötigt. Diese wurden vorrangig durch Vermessung von Einzelteilen oder an Versuchsprüfständen (wie z.B. die Dämpfercharakteristiken) ermittelt. In Fällen, in welchen die Ermittlung der Parameter z.B. aus Kostengründen nicht sinnvoll war, wurde auf Parameterwerte aus der einschlägigen Literatur oder Erfahrungswerte zurückgegriffen, wobei die Fahrzeugklasse und -Abmaße berücksichtigt wurden. Ein Nachteil der Komplexität des räumlichen Mehrkörper-Fahrzeugmodells ist, dass die numerische Simulation im Zeitbereich sehr aufwendig, und daher langsam ist. Daher wurde das volle Fahrzeugmodells nur zur Überprüfung der Ergebnisse eingesetzt. Für alle anderen Simulationen

wurde ein vereinfachtes, ebenfalls räumliches Modell, mittels sogenannter Kennfeldgelenkachsen abgeleitet, dessen Berechnung um ein Vielfaches schneller simuliert.

1.2.3 Implementierung der Software-Toolketten

Für das Training des Reglers, der Validierung des trainierten Reglers und dessen Integration wurden innerhalb des KIFahr Projekts verschiedene Software-Toolketten entwickelt oder erweitert. In den folgenden Abschnitten wird kurz auf das Trainingsframework für das Lernen des Reglers mittels RL Methoden, sowie die embedded Codegenerierung und dessen Validierung eingegangen.

1.2.3.1 Reinforcement Learning Trainingsframework

Viele Standardbibliotheken für maschinelles lernen bieten eine Python Schnittstelle und werden meistens in Python verwendet. Andererseits haben sich für die Simulation dynamischer Systeme eine Vielzahl unterschiedlicher Tools und Frameworks etabliert, beispielsweise Dymola/Modelica, Simpack, Simscape, usw. Der bereits vielfach unterstützte Functional Mock-up Interface (FMI) Standard [15] bietet eine Möglichkeit Simulationsmodelle standardisiert zu exportieren und in anderen Simulationsumgebungen einzubinden. Um die teils mächtigen Modellierungs- und Simulationsumgebungen auch für das Lernen von Reglern nutzbar zu machen, wurde bereits 2019 am DLR ein Trainingsframework implementiert, welches die Simulation von Functional Mock-up Units mit Standard RL Bibliotheken in Python koppeln [3].

Für das Training des Reglers innerhalb von KIFahr wurde das DLR interne Trainingsframework angepasst und erweitert. Wie in Abschnitt 1.2.2.2 erläutert ist, wurde der Vertikaldynamikregler anhand von Viertelfahrzeugmodellen trainiert. Um nun einen robusten Regler für alle vier Räder zu erhalten, wurde ein Mechanismus implementiert, welcher während des Trainings die Simulationsmodelle austauscht. Dies ermöglicht dem Agenten eine Regelstrategie zu lernen, welche für alle vier Räder adäquate Ergebnisse erzielt.

Darüber hinaus wurde das Framework weiter für die Anwendung am DLR Rechencluster optimiert. Beispielsweise wurde eine parallelisierte und automatisierte Auswertung von gelernten Reglern auf verschiedenen Straßenanregungen und den jeweiligen Viertelfahrzeugmodellen implementiert. Alle Trainings und Auswertungen werden nun in einer Datenbank gespeichert und können im Anschluss analysiert und verglichen werden.

Das Framework basiert auf FMI 2.0 [15], der Python RL Bibliothek Stable-Baselines 3 [16] und dem Trainingsframework RL-Baselines-Zoo 3 [17].

1.2.3.2 Reglerexport und embedded Codegenerierung

Nach dem Training liegen die trainierten Agenten in der von Stable-Baselines definierten Klasse vor und können als zip-Archiv gespeichert werden. Um die Agenten für die Validierung und

Anwendung verfügbar zu machen, wurden die optimierten Parameter sowie die Struktur der neuronalen Netze mithilfe einer Adapterklasse ausgelesen und in ein im Rahmen des Projektes definiertes, generisches Format gebracht. Für dieses Format wurde weiterhin ein Codegenerierungswerkzeug implementiert, welches nativen C Code erzeugt und abspeichert. Dieser C-Code ist die Grundlage für die Verwendung der trainierten Agenten auf eingebetteten Systemen. Weiterhin ermöglicht das Matlab *Legacy Code Tool* die automatisierte Generierung einer S-Function aus dem generierten C-Code, die dann direkt in Simulink verwendet werden kann. Eine schematische Darstellung der Werkzeugkette für den Export der trainierten Agenten zeigt Abbildung 16. In diesem Projekt wurde die generierte S-Function im übergeordneten Vertikaldynamik-Regelungsmodell eingebunden und somit sowohl für die Validierung als auch den Einsatz auf der für die Regelung eingesetzten Steuereinheit verfügbar gemacht.




Abbildung 16: Export-Werkzeugkette für die trainierten Agenten

Darüber hinaus wurde mittels des Codegenerierungstools dSPACE TargetLink ein Interface geschaffen, um optimierten embedded C-Code für den Einsatz des Reglers im Steuergerät von KW zu ermöglichen. Für den final ausgewählten Regler wurde am DLR eine statische vorkompilierte Bibliothek für das Steuergerät generiert und KW zur Verfügung gestellt.

1.2.3.3 Validierungstoolkette

Die Funktionalität des verwendeten Vertikaldynamik-Regelungsmodell in Simulink mit den als S-Function exportierten Agenten wurde in einem mehrstufigen Prozess validiert und abgesichert. Um sicherzustellen, dass der Export aus Python fehlerfrei gelungen ist, wurden noch in Python Validierungsdaten für jeden trainierten Agenten mit definierten Eingängen und den sich daraus ergebenden Ausgängen der neuronalen Netze erzeugt und gespeichert. Die exportierte S-Function wurde dann in Simulink mit den entsprechenden Eingängen simuliert und die Ausgänge mit den zu erwartenden Werten verglichen. Zur Absicherung des Gesamtmodells für die Regelung der Dämpfer wurde das Modell mit den eingebundenen Agenten als FMU (Functional Mock-up Unit) direkt aus Simulink exportiert und im Vollfahrzeug Simulationsmodell in Modelica eingebunden. Hier wurde das Verhalten für definierte Manöver plausibilisiert und mit Daten aus realen Messfahrten verglichen.

1.2.4 Entwicklung, Training und Integration des Regelsystems

In diesem Abschnitt wird detaillierter auf die Entwicklung und das Training sowohl des Vertikaldynamikreglers als auch des Absicherungskonzepts eingegangen. Abschließend wird die Auslegung eines Referenzreglers für den Vergleich mit dem trainierten Regler beschrieben.

1.2.4.1 Training des RL Vertikaldynamikreglers

Das Training eines Reglers über Reinforcement Learning Methoden bietet den Vorteil, dass direkt an einem Simulationsmodell oder am echten System trainiert werden kann. RL Methoden sind universell einsetzbar und sind nicht beschränkt auf spezielle Systemstrukturen oder Systemdarstellungen. Es ist möglich direkt an einem komplexen Simulationsmodell zu trainieren. Eine analytische Systemdarstellung z.B. als Zustandsraummodell ist nicht nötig.

Das Training an einem Simulationsmodell ist im Gegensatz zum Training am echten System schnell, skalierbar und sicher. Deswegen wurden innerhalb dieses Projekts das Training anhand des Trainingsmodells gewählt.

Die zentralen Freiheitsgrade beim Training eines Reglers mittels Reinforcement Learning sind die Wahl des RL Algorithmus und dessen Parameter (Hyperparameter), die Wahl der Feedbacksignale (Observations), Design und Parametrierung der Gütefunktion (Rewardfunktion) sowie eine optionale Randomisierung von Systemparametern.

Ziel des Trainings ist es, einen Vertikaldynamikregler zu trainieren, welcher sowohl Straßenhaftung als auch Fahrkomfort pro Rad verbessert. Die Modellierung eines Vollfahrzeugmodells, welches sowohl Vertikaldynamik als auch Längs- und Querdynamik akkurat abbildet, ist äußerst komplex. Darüber hinaus weist das resultierende Vollfahrzeugmodell aufgrund der Komplexität und Größe eine vergleichsweise lange Simulationsdauer auf. Daraus begründet sich der Ansatz den Vertikaldynamikregler radbezogen zu trainieren und die Längs- und Querdynamik über eine modellbasierte Vorsteuerung zu kompensieren.

Für das Training des Vertikaldynamikreglers wurden die in Abschnitt 1.2.2.2 beschriebene Trainingsmodelle in die in Abschnitt 1.2.3.1 dargestellte Trainingstoolkette als FMUs eingebunden. Während des Trainings werden nun die Viertelfahrzeugmodelle der verschiedenen Räder durchiteriert, sodass der resultierende Regler im Anschluss auf allen vier Rädern einzeln angewandt werden kann. Das Training eines separaten Reglers für jedes einzelne Rad hat nicht die gewünschten Ergebnisse geliefert: Unvermeidbare Unterschiede in den gelernten Regelgesetzen pro Rad führten zu einer aufschwingenden Nick- und Rolldynamik des Fahrzeugs. Aus diesem Grund wurde ein Regelgesetz basierend auf allen Viertelfahrzeugmodellen gelernt, welches im Fahrzeug für jedes Rad extra ausgewertet wurde.

Neben der Randomisierung der Viertelfahrzeugmodelle wurde auch auf unterschiedlichen Anregungen bestehend aus unterschiedlichen virtuellen Straßenprofile trainiert. Beispielsweise wurde

das Training auf unterschiedlich parametrisierten Bodenwellen, Schlagleisten, Schlaglöchern und Sinus Sweeps durchgeführt. Jede Kombination aus Viertelfahrzeugmodell und Straßenprofil wird im Folgenden als Szenario bezeichnet. Insgesamt standen 42 Szenarien für das Training und die Auswertung innerhalb des Projekts zur Verfügung.

Nach dem Training eines Agenten wurde dieser auf ausgewählten Szenarien ausgewertet und es wurden unterschiedliche Metriken berechnet, um die trainierten Agenten zu vergleichen. Grundsätzlich liefert die Gütefunktion einen numerischen Wert, welcher die Performanz des Reglers abbilden soll. Allerdings wurde die Gütefunktion so gestaltet, dass verschiedene Regelungsziele zu einem numerischen Wert zusammengefasst wurden. Um die Performanz eines Agenten auf jeder einzelnen Zielsetzung beurteilen zu können, wurden für jeden trainierten Agenten auf ausgewählten Szenarien die folgenden Metriken berechnet. Zum einen wurde der Fahrkomfort

$$J_{c,RL} = \sqrt{\frac{1}{T} \int_0^T a_b^2 dt} \quad (1)$$

mit der Simulationsdauer T und der vertikalen Aufbaubeschleunigung a_b und die Straßenhaftung

$$J_{rh,RL} = \sqrt{\frac{1}{T} \int_0^T F_{wl}^2 dt} \quad (2)$$

mit der dynamischen Radaufstandskraft F_{wl} berechnet [2]. Um die Metriken besser beurteilen zu können, wurden diese jeweils auf den besseren Wert aus einer Simulation mit einem optimierten Skyhook- (SH) und Groundhook- (GH) Regler normiert:

$$\tilde{J}_{c,RL} = \frac{J_{c,RL}}{\min(J_{c,SH}, J_{c,GH})} \quad (3)$$

$$\tilde{J}_{rh,RL} = \frac{J_{rh,RL}}{\min(J_{rh,SH}, J_{rh,GH})} \quad (4)$$

Darüber hinaus wurden jeweils noch eine Metrik für die Rauschigkeit des Stellsignals

$$J_{ji,RL} = \frac{1}{N} \sum_{k=2}^N |u_k - u_{k-1}| \quad (5)$$

mit der Stellgröße u berechnet und anschließend auf die entsprechenden Werte des SH- und GH-Reglers normiert:

$$\tilde{J}_{ji,RL} = \frac{J_{ji,RL}}{\min(J_{ji,SH}, J_{ji,GH})} \quad (6)$$

Auf weitere Metriken mit untergeordneter Rolle wird hier nicht weiter eingegangen. Um die Metriken nun beurteilen zu können, wurden diese anschließend über alle Szenarien gemittelt.

Das Training bestand nun aus einem iterativen Prozess der folgenden Schritte:

1. Auswahl von RL Hyperparametern; Design und Parametrierung einer Rewardfunktion
2. Training

3. Durchführen der Ergebnissimulationen auf allen Szenarien und Berechnen der Metriken
4. Analyse und Start bei Punkt 1

Durch die effiziente Toolkette und die Parallelisierung verschiedener Trainings und Auswertungen auf dem DLR Compute Servern konnten 5.288 Agenten trainiert werden und 63.456 Ergebnissimulationen durchgeführt werden.

Aus früheren Tests ist bereits bekannt, dass gelernte RL Regler oft zu einem sehr rauschigen Stellsignal neigen. Dies beeinflusst die Reglerperformanz im Fahrzeug negativ, auch wenn die Auswertungen in der Simulation gute Ergebnisse zeigen.

Für den Test im Fahrzeug wurden deswegen diejenigen Regler ausgewählt, welche gute Straßenhaftung und guten Fahrkomfort bei ausreichend glattem Stellsignal bieten.

1.2.4.2 Absicherungskonzept

In diesem Abschnitt wird die Entwicklung eines Absicherungsmoduls vorgestellt, welches in kritischen Fahrzuständen aktiviert wird und die sichere Erprobung der gelernten Vertikaldynamikregler ermöglicht.

Die Horizontaldynamik des Fahrzeugs ist über die Radaufstandskräfte (die sogenannten Radlasten) mit der Vertikaldynamik gekoppelt. Kritische Fahrsituationen können auftreten, wenn durch die dynamische Radlast eine Schwächung des Kraftschlusspotentials einsetzt, welche eine unzureichende oder sogar komplett ausbleibende Übertragung der Reifenhorizontalkräfte zur Folge hat. Dies betrifft insbesondere das Lenken und Bremsen, was mit einem fahrdynamischen Kontrollverlust einhergeht. Aus Perspektive der Fahrsicherheit ist daher eine Minimierung der dynamischen Radlast optimal (Rad folgt exakt dem Verlauf des Untergrunds \triangleq ground hook).

Die genaue Quantifizierung eines kritischen Wertes der dynamischen Radlast ist nicht ohne weiteres möglich. Ohnehin stehen im realen Fahrbetrieb keine Sensoren zur Ermittlung dieses Wertes zur Verfügung. Dessen Schätzung stellt weiterhin eine komplexe Aufgabe dar. Für die Identifikation eines kritischen Fahrzustandes im Rahmen des Projekts KIFahr wird daher eine heuristische Quantifizierung verwendet.

Eine kritische Fahrsituation kann nur auftreten, wenn der Fahrer eine Horizontalkraft-Anforderung stellt (Lenken, Beschleunigen, Bremsen). Für die Identifikation von kritischen Fahrzuständen werden daher nur die fahrerinduzierten Anregungen berücksichtigt, und nicht etwa jene, welche durch reine Straßenanregungen entstehen.

Die Radlasten $F_{z,i}$ können in Abhängigkeit von der Fahrzeuglängsbeschleunigung a_x , der Querschleunigung a_y , und der Fahrzeuggeometrie berechnet werden. Für die Radlast am Reifen vorne links (fl) ergibt sich:

$$F_{z,fl} = m \left(\frac{l_r}{l} g - \frac{h_{CoG}}{l} a_x \right) \cdot \left(\frac{1}{2} - \frac{h_{CoG}}{b_f g} a_y \right) \quad (7)$$

Die Radlasten der anderen Räder ergeben sich analog aus einem Momentengleichgewicht der Halffahrzeuge, siehe Abbildung 17. Im Sinne der Übersichtlichkeit wird im Folgenden nur das Rad vorne links betrachtet.




Abbildung 17: Die Halffahrzeugansichten - Nicken bei Seitenansicht (links) sowie Rollen bei Frontansicht (rechts).

Detektion eines kritischen Fahrzustandes

Wegen der Forderung nach einer minimalen dynamischen Radlast, also der Radlaständerung, wird die zeitliche Ableitung von $F_{z,fl}$ betrachtet:

$$\dot{F}_{z,fl} = m \cdot \left[\dot{a}_y \frac{h_{CoG}}{b_f l} \left(\frac{h_{CoG}}{g} a_x - l_r \right) + \dot{a}_x \frac{h_{CoG}}{l} \left(\frac{h_{CoG}}{b_f g} a_y - \frac{1}{2} \right) \right] \quad (8)$$

Über den Längs- und Querruck \dot{a}_x bzw. \dot{a}_y können nun Grenzwerte festgelegt werden, welche den Übergang zu einem kritischen Fahrzustand quantifizieren. Die beiden Rucke können nur in unzureichender Qualität ermittelt werden, da sie aus der Differentiation der Fahrzeugbeschleunigungen resultieren, was zu einem starken Rauschen führt. Stattdessen können die Nick- und Rollwinkelgeschwindigkeit $\dot{\phi}$ bzw. $\dot{\theta}$ verwendet werden, da sie mit guter Näherung mit \dot{a}_x und \dot{a}_y linear abhängig sind [18]:

$$\begin{aligned} \dot{\phi} &= K_{Roll} \cdot \dot{a}_y \\ \dot{\theta} &= K_{Nick} \cdot \dot{a}_x \end{aligned} \quad (9)$$

Absicherungsstrategie

Bei Identifikation eines kritischen Fahrzustands wird ein konstante Dämpferkennlinie gestellt. Zur Ermittlung eines hierfür geeigneten Dämpferstroms wurden anhand von Messdaten, welche auf dem Stempelprüfstand aufgenommen wurden, umfangreiche Analysen vorgenommen. Bei einem Dämpferstrom von 0,8 A konnte, unter Berücksichtigung des gesamten Anregungs-Frequenzbereiches, eine größtmögliche Dämpfung der dynamischen Radlast (schnellstmögliche Rückkehr in einen unkritischeren Fahrzustands) erreicht werden. Bei Triggerung des Absicherungsmoduls

wird der o.g. konstante Dämpferstrom für eine Dauer von 0,5 s gehalten, um Nachschwingeffekte zu berücksichtigen.

In Fahrversuchen, siehe Abschnitt 1.2.5.2, wurden Schwellwerte für die Roll- und Nickgeschwindigkeit ermittelt, sodass objektiv beim Übergang in einen kritischen Fahrzustand in die sichere Dämpferkennlinie geschaltet wird.

1.2.4.3 Auslegung eines Referenzreglers

Neben den KI-basierten Regelungsansätzen wurde als Referenz ein kombinierter Skyhook-Groundhook-Regler modellbasiert ausgelegt. Hierzu wurden die beiden Verstärkungsfaktoren für den Skyhook- und den Groundhook-Anteil als freie Parameter des Reglermodells in Modelica optimierungsbasiert so bestimmt, dass der Regler möglichst gute Eigenschaften hinsichtlich Komfort und Straßenlage in Modellsimulationen realisiert. Für jedes der ausgewählten Viertelfahrzeugmodelle aus Abschnitt 1.2.2.2 wurde demnach ein numerischer Optimierungslauf für die beiden Reglerparameter für mehrere ausgewählte Anregungsszenarien durchgeführt. Als Kriterien c_1 , c_2 zur Bewertung der Reglergüte wurden analog zu [2] die dynamische Radlast F_{wl} für die Straßenlage und die Aufbaubeschleunigung \ddot{x}_b für den Komfort verwendet:

$$c_1 = \sqrt{\frac{1}{T} \int_0^T F_{wl}^2 dt} \quad (10)$$
$$c_2 = \sqrt{\frac{1}{T} \int_0^T \ddot{x}_b^2 dt}$$

Die Zeit T gibt die Zeitdauer für das einzelne Szenario an. Eine gewichtete Summe dieser Kriterien für alle Anregungsszenarien ergibt die skalare Zielfunktion, die minimiert wurde. Als Werkzeug wurde wie in Abschnitt 1.2.2.2 die Optimization Library in Dymola verwendet. Die für jedes der vier Räder einzeln ermittelten optimalen Reglerparameter unterschieden sich um weniger als 50%. Die Optimierung des Vergleichsreglers anhand derselben Modelle, an welchen auch das RL-basierte Regelgesetz trainiert wurde, bietet eine faire Vergleichsgrundlage.

1.2.5 Erprobung des Regelsystems

Abschließend wurde das entwickelte Regelsystem verschiedenen simulativen und realen Fahrversuchen unterzogen. Die simulative Validierung des Regelsystems wird in Abschnitt 1.2.5.1 beschrieben. In Abschnitt 1.2.5.3 wird die Erprobung des Regelsystems und in Abschnitt 1.2.5.2 die Erprobung des Absicherungsmoduls im Fahrversuch zusammengefasst. Abschließend wird in 1.2.5.4 die quantitative Vermessung der gelernten Regler am Stempelprüfstand von KW analysiert.

1.2.5.1 Validierung des Regelsystems in der Simulation

In der Abstimmungsphase wurde das vereinfachte Fahrzeugmodell eingesetzt, vgl. Abschnitt 1.2.2.3.

Mit Hilfe des Multibody Simulationsmodells, beschrieben in Abschnitt 1.2.2.3, konnte eine detaillierte Analyse der verschiedenen KI-basierten Regler und des Referenzreglers durchgeführt werden. Dafür wurde eine Teilstrecke „Fornsbachwelle“ der KW Erprobungsstrecken genutzt, da diese eine äußerst relevante Anregung schafft. Hierbei handelt es sich um eine Schlechtwegstrecke mit einer anschließenden langen Bodenwelle über eine alte Brücke, siehe Foto und Profilabschätzung der Bodenwelle in Abbildung 18.



Abbildung 18: Fahrtechnik Event „Fornsbachwelle“ – alte Brücke auf Schlechtwegstrecke

Die Regeleingriffe speziell an der Bodenwelle wurden detaillierter analysiert und werden im Folgenden diskutiert. Dazu wurde das Simulationsmodell, das in Abbildung 15 dargestellt ist, verwendet. Hierin können die verschiedenen (KI)-Regler mittels dem Industriestandard Functional Mockup Interface (FMI) [15] aus dem Reglercode für das eingebettete System nahtlos in das Simulationsmodell importiert (rot markiert) werden. Somit wird der ident gleiche Regler verwendet, der dann auch im realen Test auf dem eingebetteten System im Fahrversuch untersucht wird (vgl. Kapitel 1.2.5.3). So ist es möglich eine Absicherung der korrekten Ausführung des entworfenen Reglers zu überprüfen, was häufig im Fahrversuch nur schwer möglich ist.



Abbildung 19: Reale Bodenwelle und virtuelles Simulationsmodell

So kann überprüft werden, ob alle Eingänge und Ausgänge korrekt verknüpft sind und sich das vorhergesehene Reglerverhalten auch einstellt. Darüber hinaus können vollständig reproduzierbare Manöver virtuell durchfahren werden und direkt untereinander verglichen werden. Auf den folgenden Seiten ist das dedizierte Event der symmetrischen Bodenwelle, ohne die Anfahrt auf der Schlechtwegstrecke, mit den verschiedenen Reglerkonfigurationen dargestellt. Auf der Abszisse ist die Zeit von 3s bis 5s dargestellt. Die Ordinate stellt die jeweilige physikalische Einheit der jeweiligen Messgröße dar. Der erste Plot stellt die vertikale Aufbaubewegung und dessen Ausschwingen da. Im zweiten Plot ist das Event und dessen Auftreffen jeweils an der Vorder- und Hinter-Achse gezeigt. Im dritten Plot ist die Aufbaugeschwindigkeit [m/s], ermittelt aus der Integration der vertikalen Beschleunigung, zu sehen. Im vierten Plot sind die vertikalen Aufbau-Beschleunigungen [m/s²] gezeigt. Der fünfte Plot stellt die gestellten Ströme an den semi-aktiven Dämpfern dar. Der letzte Plot zeigt den genutzten Federweg an dem jeweiligen Dämpfer. Die Ergebnisse der Analyse können wie folgt zusammengefasst werden:

- Abbildung 20 zeigt das Überfahren des Events mit konstanter Dämpfung von 0.3A, d.h. das Fahrzeug ist unregelt und komfortabel abgestimmt. Man kann gut erkennen, dass es sehr lange nachschwingt und das Fahrzeug eher unterdämpft ist. Die Aufbaubeschleunigungen sind gering, aber das Fahrzeug ist eher als instabil anzusehen.
- Abbildung 21 zeigt das Überfahren des Events mit konstanter Dämpfung von 1.3A, d.h. das Fahrzeug ist unregelt und sportlich abgestimmt. Hier ist das Fahrzeug sportlich straff eingestellt, was eine Verbesserung des Nachschwingens des Aufbaus bedeutet, jedoch der Komfort für die Insassen durch die höheren Aufbaubeschleunigungen deutlich schlechter wird.
- In Abbildung 22 ist die Referenzregelung basierend auf einem Skyhook / Groundhook Regler dargestellt, dessen Parameter mittels Optimierung in Abschnitt 1.2.4.3 eingestellt

wurden. Der Regeleingriff an Vorder- und Hinterachse ist hier gut zu erkennen, man erkennt, dass dieses lineare Regelgesetz mit vier festeingestellten Parametern erst eine gewisse Zeit benötigt, bis die maximalen Ströme gestellt werden. Im Gegensatz zu vorhergehender Variante kann das Anheben des Aufbaus und der notwendige Federweg reduziert werden. Auch das Aufschwingen des Aufbaus kann nochmal schneller gedämpft werden.

- In Abbildung 23 ist der erste KI-basierte Regler mit dem Agenten 60913 gezeigt. Der stark nichtlineare Zusammenhang zwischen Ein- und Ausgängen des trainierten RL-Reglers ermöglicht einen deutlich schnelleren Eingriff am Event und gleichzeitig eine Reduktion der Aufbaubeschleunigung an der Hinterachse durch eine gezielte Reduktion der Stellströme in der Ausfederphase bei gleichzeitiger schneller Stabilisierung des Aufbaus. Um dies zu realisieren, sind jedoch geringfügig höhere Federwege im Vergleich zum Referenzregler notwendig.
- In Abbildung 24 ist der zweite KI-basierte Regler mit dem Agenten 60895 dargestellt. Sein trainiertes Stellverhalten (Plot 5) ist deutlich weicher, was in der Praxis einen Vorteil in der Akustik darstellen kann (verursacht durch hohe Kraftsprünge im Dämpfer). Gleichzeitig ist der benötigte Federweg wieder geringer und es gibt dennoch eine gute Aufbaukontrolle mit leichtem Nachschwingen.
- In Abbildung 25 ist der dritte KI-basierte Regler mit dem Agenten 60853 zu sehen. Ihn charakterisiert eine nochmals deutliche Reduktion der Aufbaubeschleunigungen in allen Phasen des Events. Er benötigt dafür wiederum mehr Federweg, kann den Aufbau jedoch ohne Überschwingen wieder stabilisieren.

Zusammenfassend lässt sich die simulative Analyse wie folgt bewerten:

- In beiden passiven Fällen muss ein starker Kompromiss eingegangen werden, der entweder die Fahrstabilität oder den Komfort stark verringert.
- Der mittels numerischer Optimierung ausgelegte Referenzregler kann dies bereits deutlich verbessern, ist jedoch durch sein lineares Regelungsverhalten, mit einer geringen Anzahl von Tuner Parametern, in seiner Dynamik eingeschränkt.
- Die drei verschiedenen KI-Regler-Varianten zeigen das volle Potential des gewählten Reinforcement Learning Ansatzes. Durch das intelligente Design der Rewardfunktionen in denen z.B. zu hohe Stellraten bestraft werden, kann das gewünschte Zielverhalten im Training erreicht werden. Durch das neuronale Netzwerk des Reglers / Agenten lässt sich so eine erhöhte Stelldynamik erreichen, die das vorgegebene Zielverhalten stets berücksichtigt.

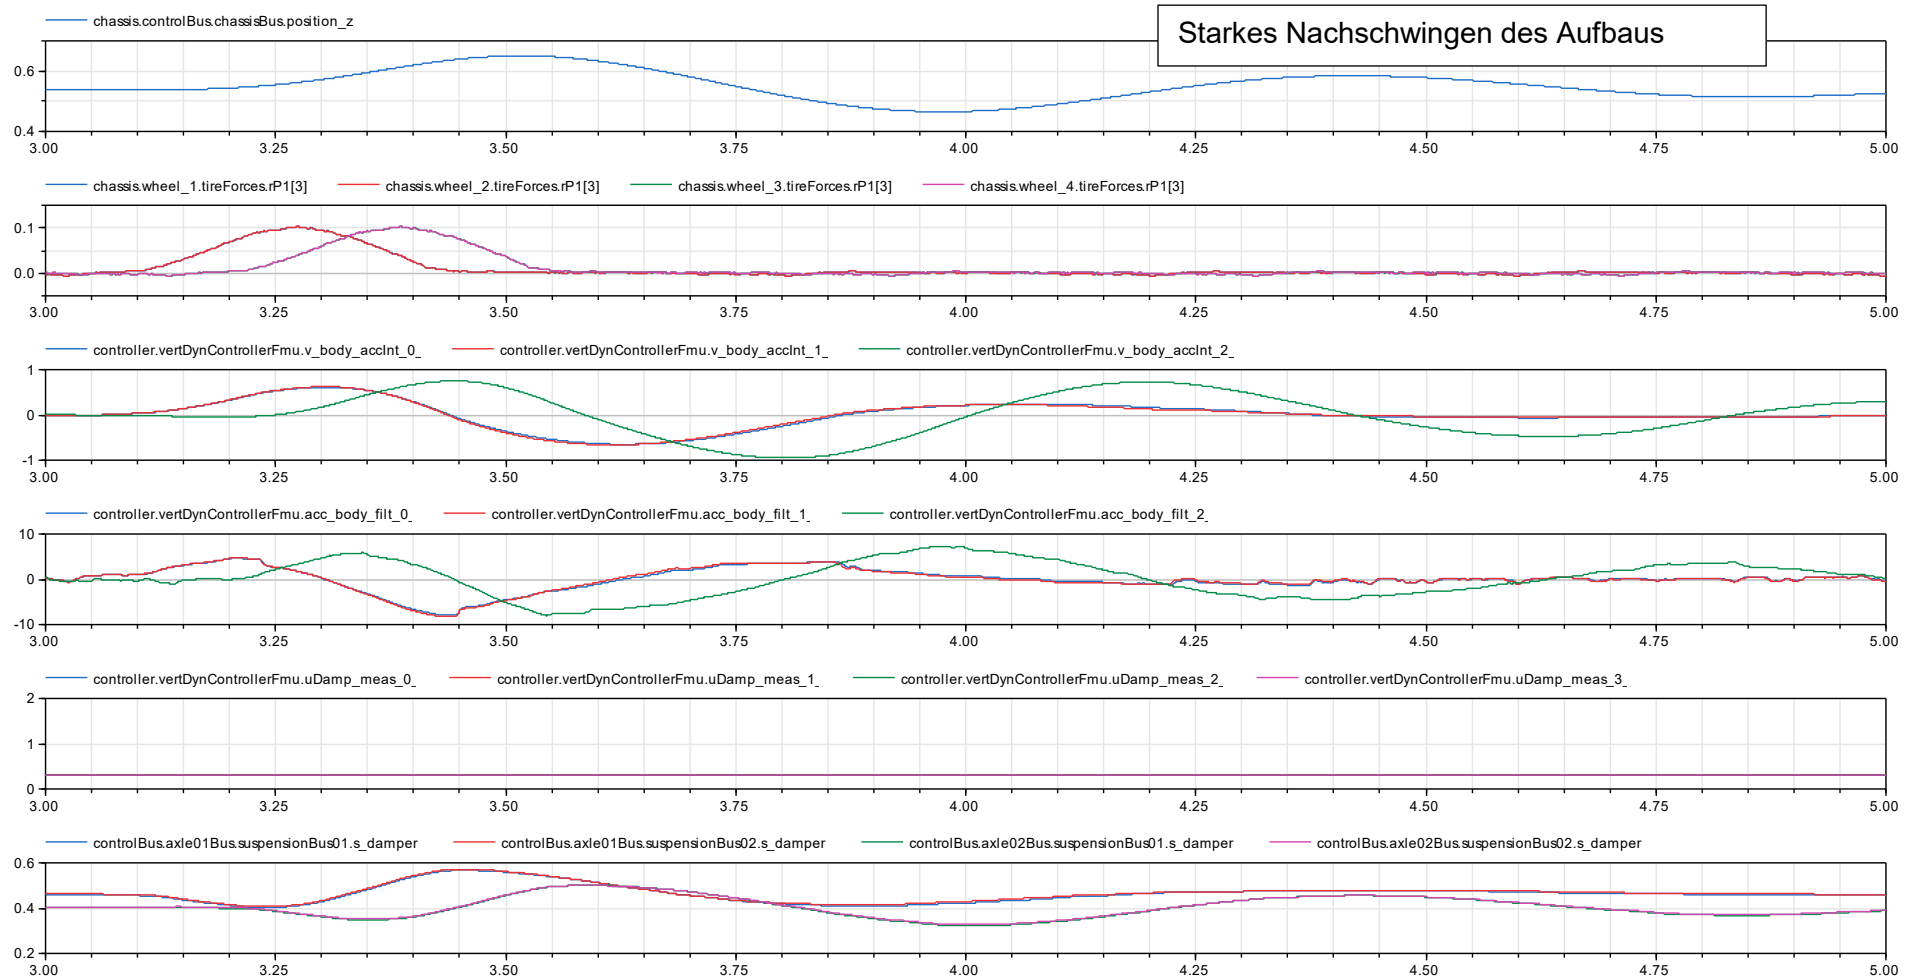


Abbildung 20: Konstante Dämpfung 0.3A

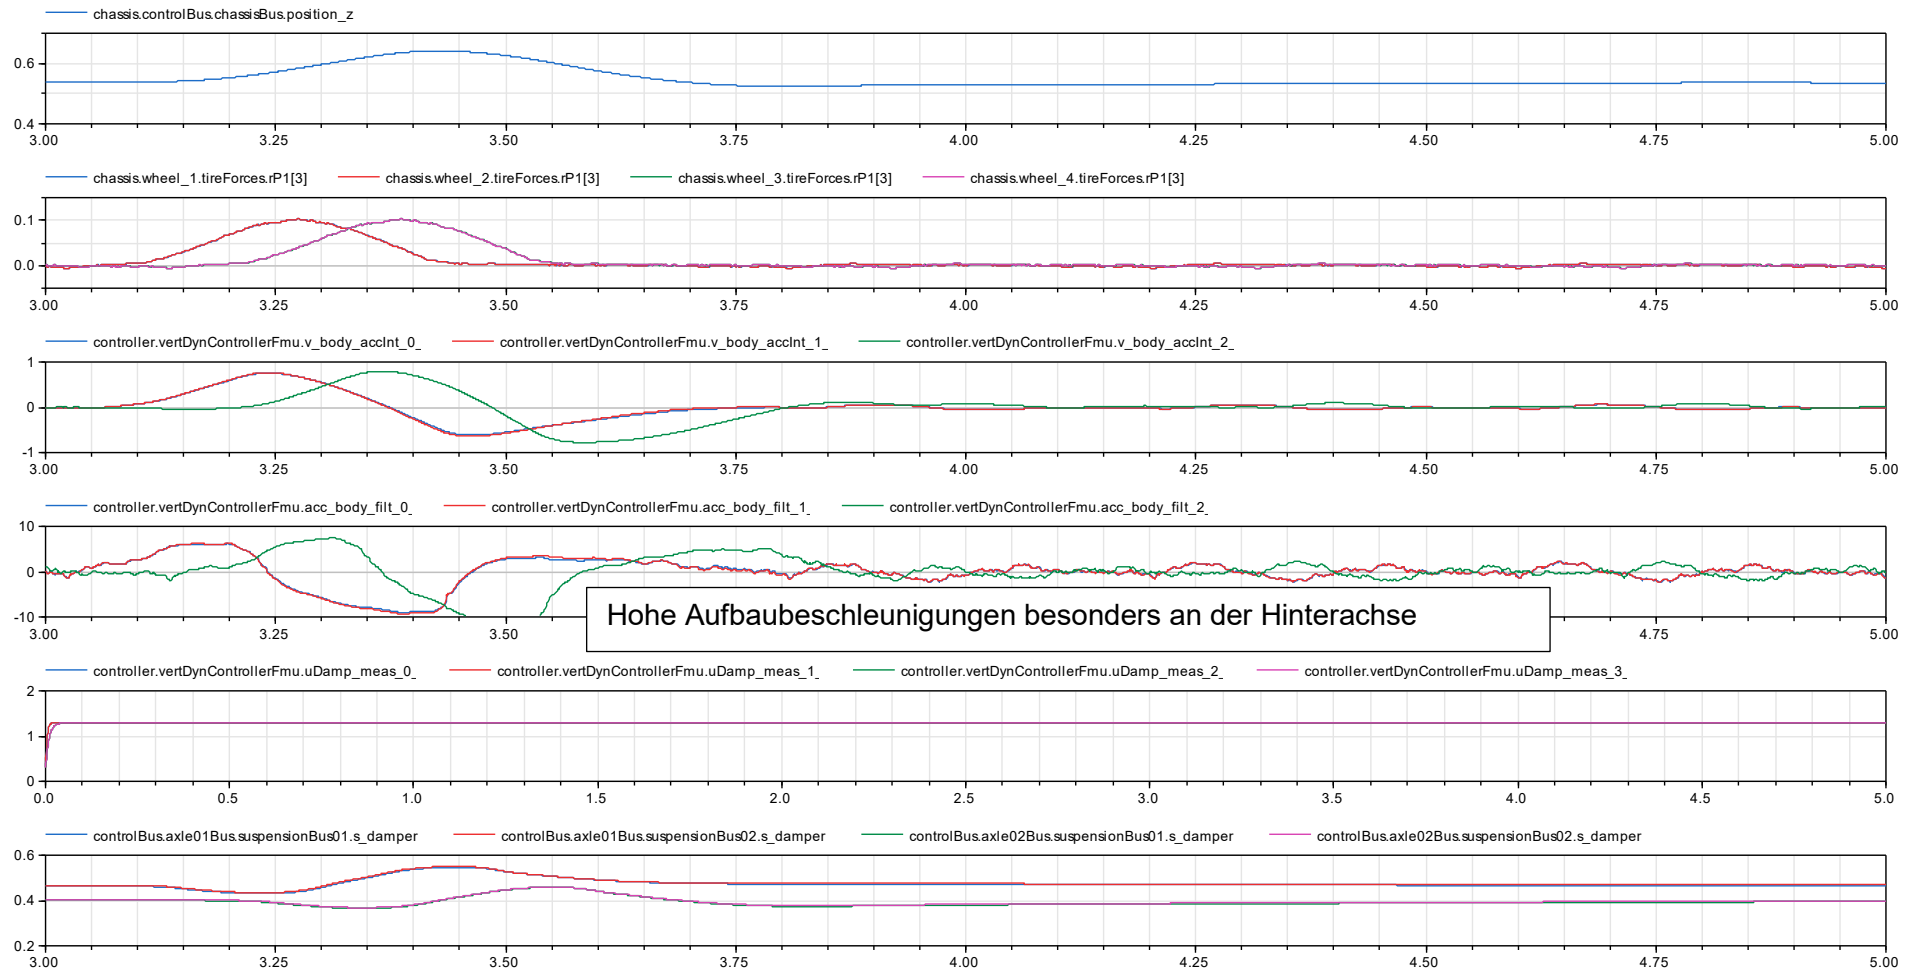


Abbildung 21: Konstante Dämpfung 1.3 A

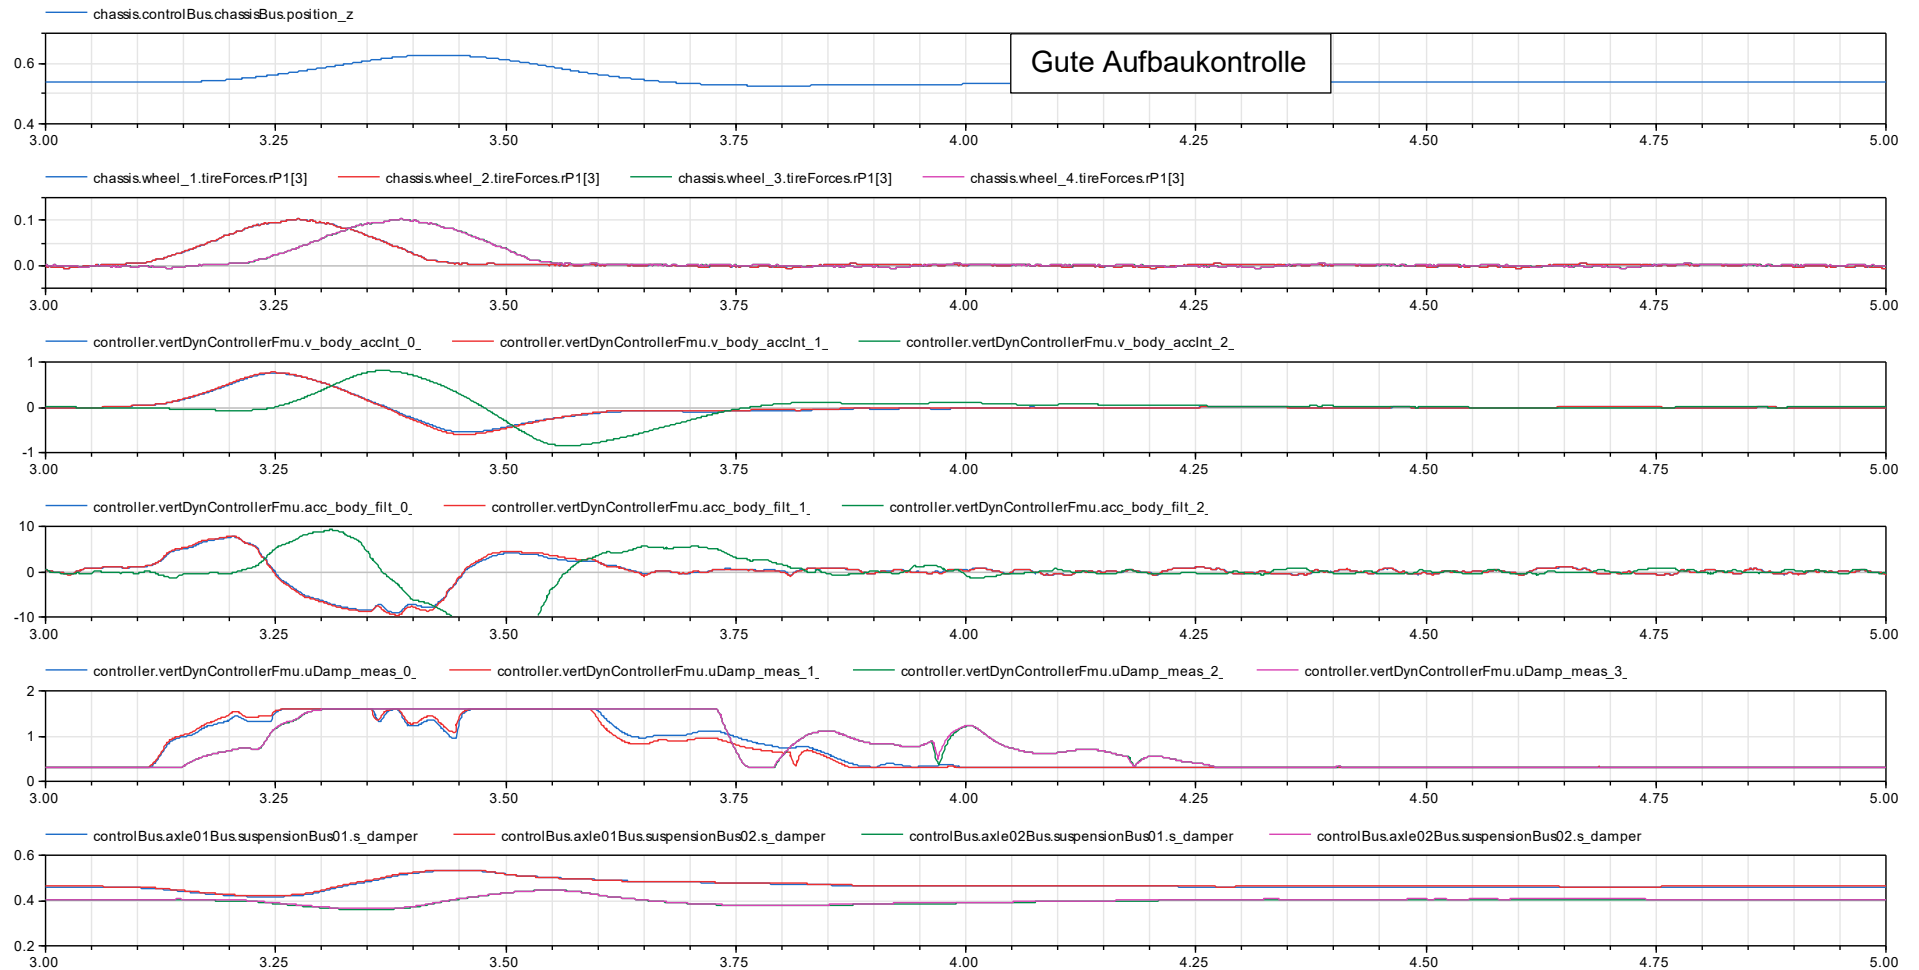


Abbildung 22: Referenz Regler Skyhook/Groundhook Regler




Abbildung 23: KI-Regler – Agent: 60913

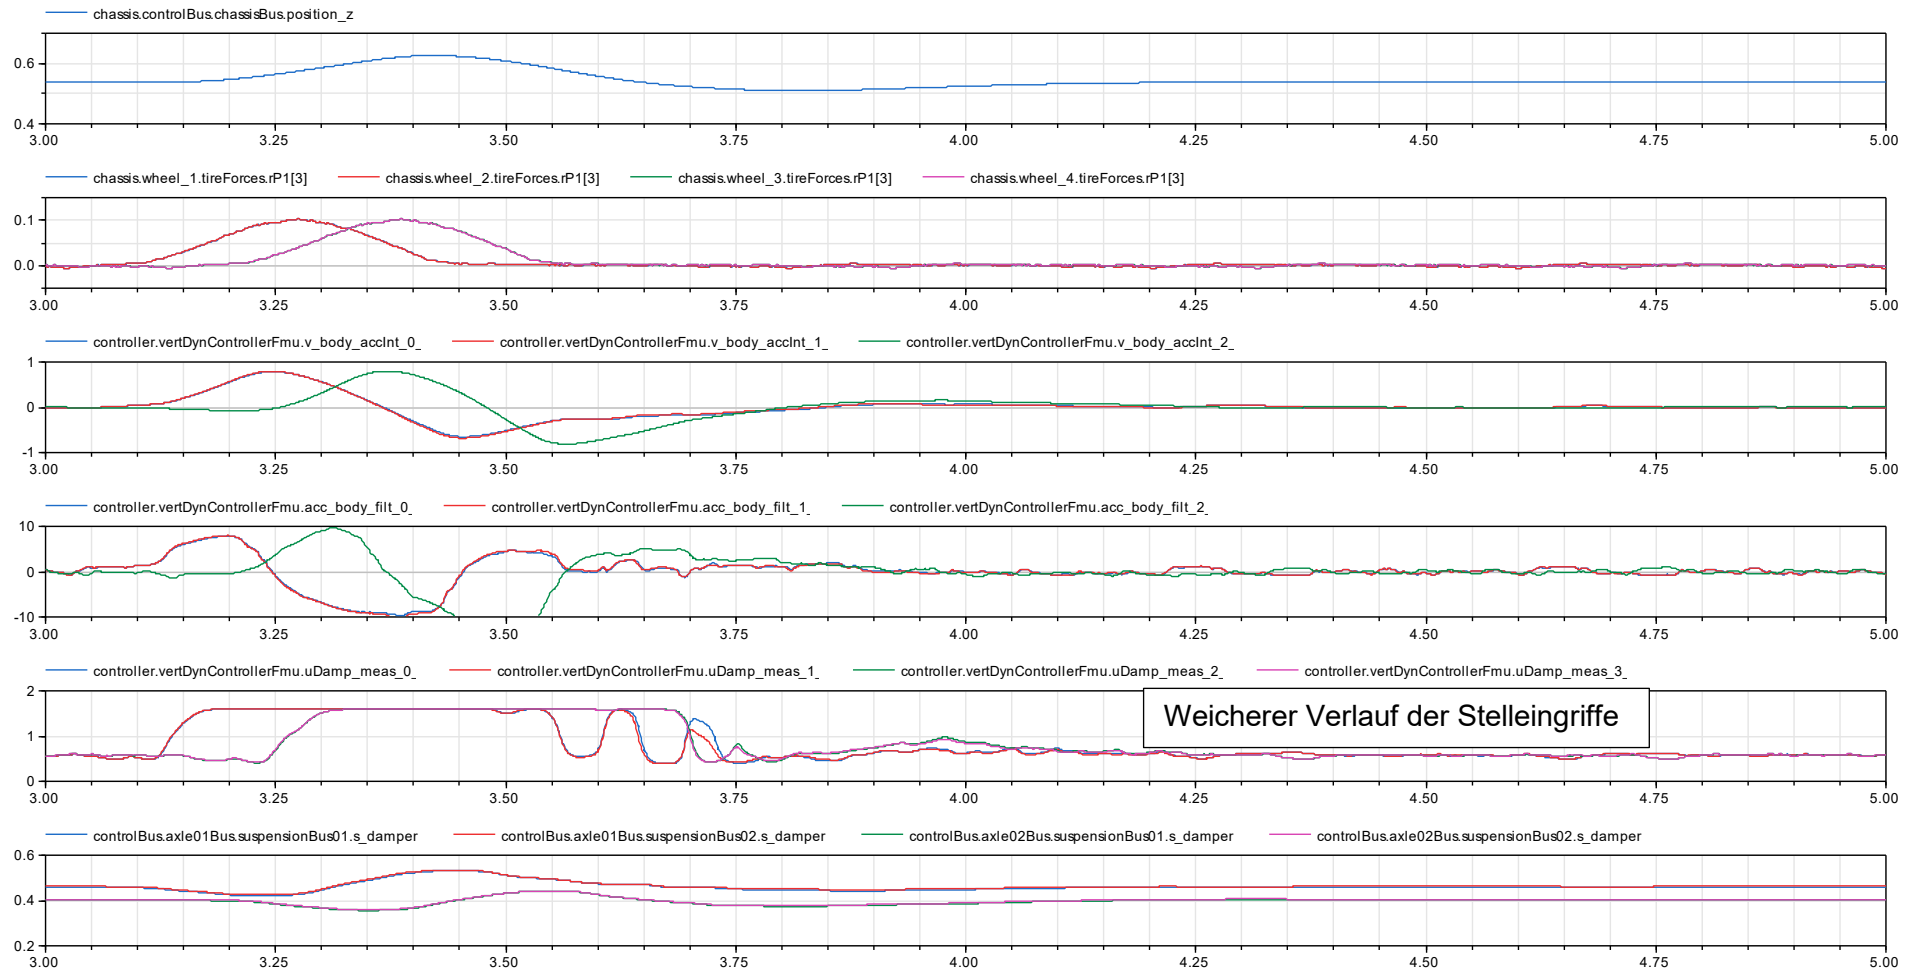


Abbildung 24: KI-Regler – Agent: 60895

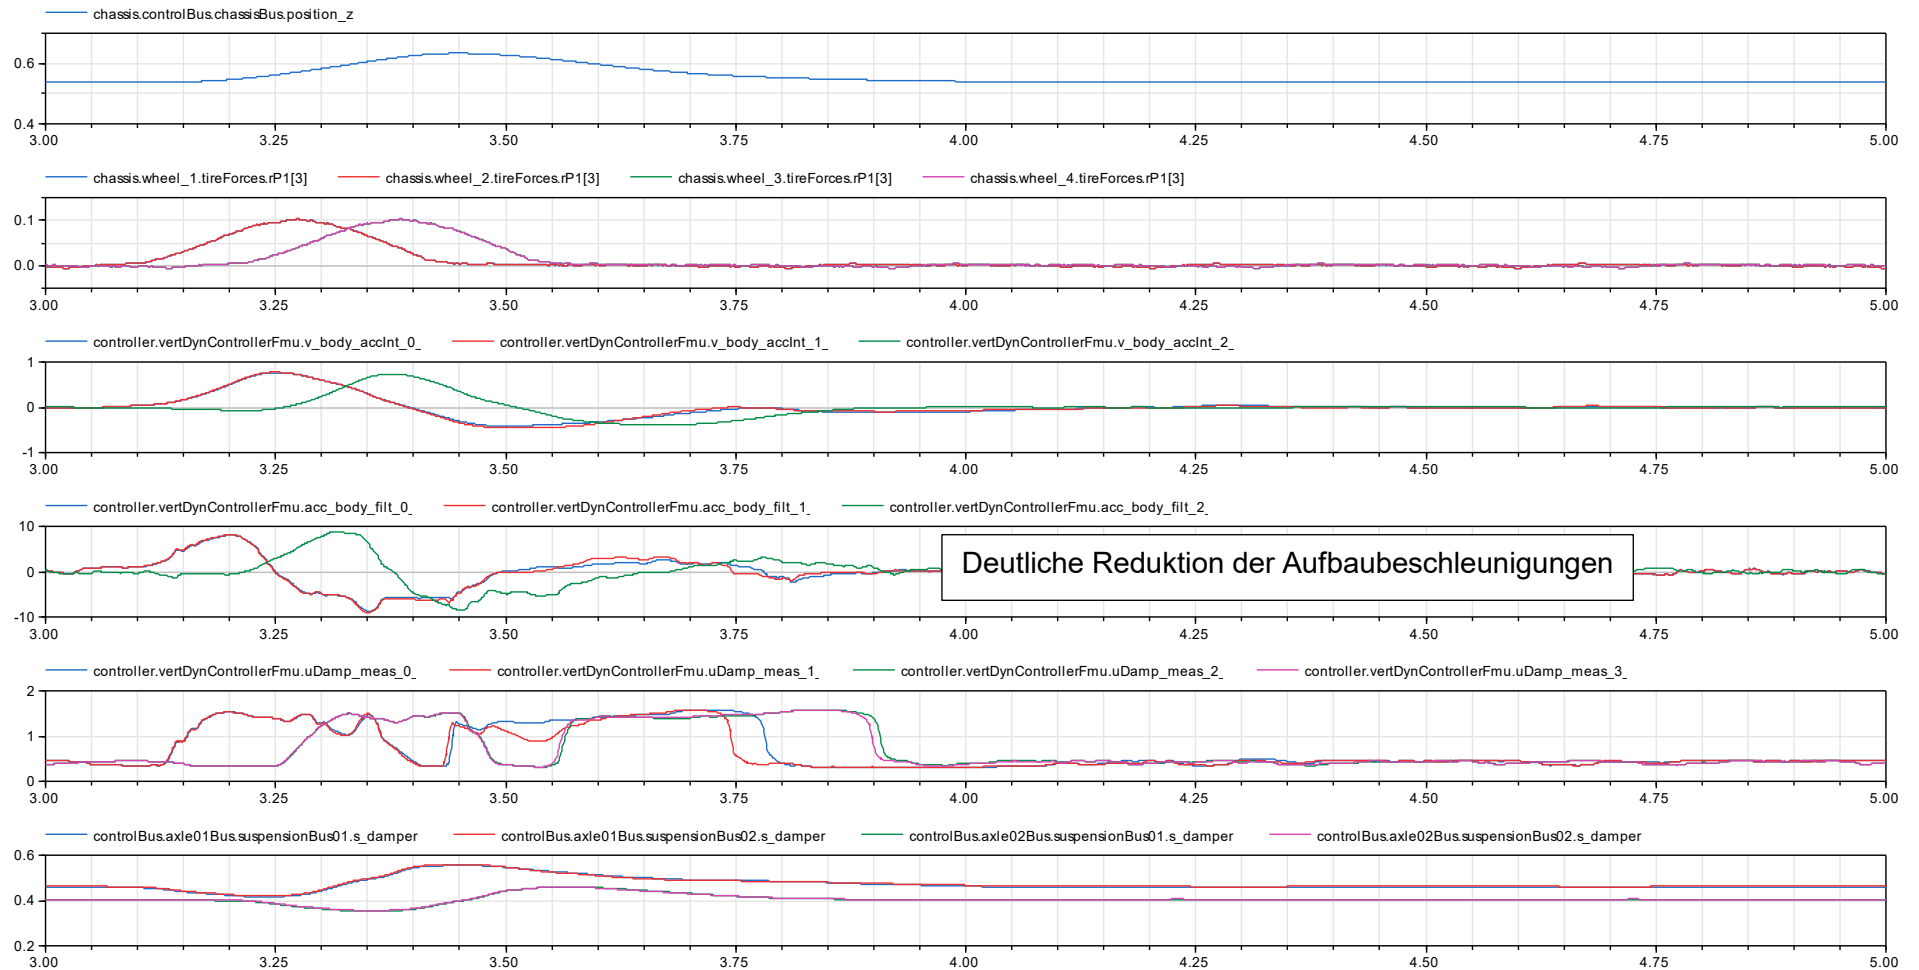


Abbildung 25: KI-Regler – Agent: 60853

1.2.5.2 Erprobung des Absicherungskonzepts im Fahrversuch

Die in Abschnitt 1.2.4.2 vorgestellte Methodik zur Absicherung der gelernten Vertikaldynamikregler wurde bei Fahrversuchen auf einem Testgelände beim DLR in Oberpfaffenhofen erprobt. Hierzu mussten zu Beginn die Schwellwerte für die Fahrzeug Nick- und Rollraten ermittelt werden. Diese sind nach Gleichung (8) und (9) abhängig von der Änderung der Radlast und sind damit ein geeignetes Detektionskriterium für kritische Fahrmanöver.

Während der Erprobung wurden unterschiedlichste Manöver durchgeführt. Hierbei sind insbesondere zu erwähnen:

- Beschleunigen und Abbremsen (Nicken)
- Spurwechsel und Sinusfahrten (Rollen), wie Abbildung 26 zu entnehmen ist.



Abbildung 26: Spurwechselmanöver mit dem AFM zur Erprobung des Absicherungsmoduls.

Zur Identifikation geeigneter Schwellwerte für die Roll- und Nickrate wurden die Fahrten in einer „Worst-Case“ Betrachtung mit einem niedrigen Dämpferstrom von 0,3 A durchgeführt (sehr weich). Unter diesen Bedingungen resultieren maximal große Roll- und Nickraten, wodurch geeignete Grenzwerte festgelegt werden können. Die Ermittlung dieser Werte fand iterativ durch einen Testfahrer sowie der Versuchsbegleitung, welche Remote mit den Rechnersystemen des Fahrzeugs verbunden war, statt. Abbildung 27 zeigt das Manöver zu einem einfachen Spurwechsel.

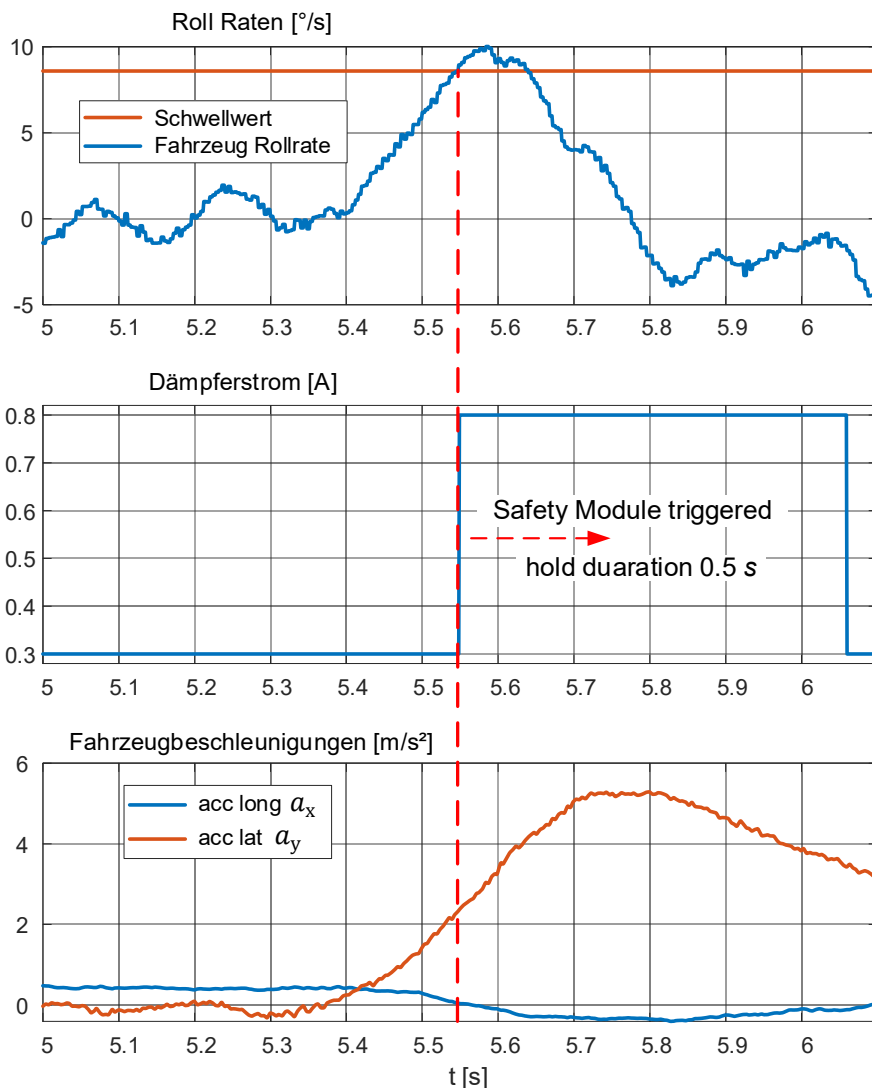


Abbildung 27: Eingriff des Absicherungsmoduls bei einem Spurwechselmanöver des AFMs.

Der festgelegte Schwellwert der Rollrate von $0,15 \frac{rad}{s} \cong 8,6 \text{ } ^\circ/s$ wird etwa $0,2 \text{ s}$ nach Lenkeinschlag erreicht, wodurch das Absicherungsmodul getriggert und ein konstanter Dämpferstrom von $0,8 \text{ A}$ für die festgelegte Haltedauer von $0,5 \text{ s}$ gestellt wird. Die Wirksamkeit des Absicherungsmoduls ist durch den Vergleich des Rollratenverlaufs mit der Quereschleunigung a_y erkennbar. Die Rollrate wird durch Aktivierung des Absicherungsmoduls sichtlich gedämpft und klingt rasch ab, sodass bei $t = 5,65 \text{ s}$ wieder der Schwellwert unterschritten wird. Währenddessen steigt die Quereschleunigung weiter an und zeigt den andauernden Energieeintrag des Manövers in den Fahrzeugaufbau. Das heißt, dass während des Quermanövers die Radlaständerung durch Aktivierung des Absicherungsmoduls gedämpft werden (vgl. Gleichung (8) und (9)) und das Modul eine kritische Fahrsituation erfolgreich abmildern kann.

1.2.5.3 Erprobung des RL Reglers im Fahrversuch

Wie in Abschnitt 1.2.5.1 erwähnt wurde die Bewertung der Regler vorrangig an dem Strecksegment „Fornsbachwelle“ durchgeführt. Die Anfahrt darauf beinhaltet eine ca. 1.5km lange Schlechtwegstrecke mit einer Superposition von kurzen Wellen und Schäden in der Fahrbahnoberfläche. Dieses erste Segment diente vorrangig zur Bewertung der Aufbaustabilisierung der verschiedenen Regelansätze. Zusätzlich konnten im realen Fahrversuch akustische Eigenschaften, wie z.B. Dämpfergeräusche aus hohen Stellraten oder mechanische Anschläge beim Erlangen der Federwegsgrenze, beurteilt werden und in den iterativen Reglertrainingsprozess wieder einfließen. Insbesondere die KI-basierten RL Regler konnten eine sehr gute subjektive Aufbaukontrolle realisieren, die den Testfahren das Gefühl eines fliegenden Teppichs vermittelten und Bodenwelle über die Brücke komplett „wegfederte“ und dabei eine hohe Fahrstabilität vermittelte. Somit konnten die Erkenntnisse der simulativen Bewertung auch in der realen Testfahrt verifiziert werden.



Abbildung 28: Drohnenaufnahme AFM Testfahrt

1.2.5.4 Vermessung des RL Reglers am Prüfstand

Abschließend wurden die gelernten Vertikaldynamikregler und der kombinierter SH-GH Regler als Referenzregler am hydraulischen Stempelprüfstand bei KW quantitativ vermessen.



Abbildung 29: Versuchsfahrzeug AFM am Stempelprüfstand bei KW

Im Gegensatz zu Fahrversuchen auf der Straße können am Stempelprüfstand verschiedene Regler mit der exakt gleichen Anregung erprobt werden. Darüber hinaus kann die dynamische Rad-
aufstandskraft über Kraftmesssensoren in den Stempeln direkt gemessen werden. Dies ermöglicht es sowohl den Fahrkomfort als auch die Straßenhaftung exakt und direkt aus den Messdaten zu bestimmen.

Um die Regler umfassend beurteilen zu können, wurden folgende Anregungen gewählt: Sinus-Sweeps mit verschiedenen konstanten Nulldurchgangsgeschwindigkeiten der Stempel, synchrone und asynchrone synthetische Straßenprofile Typ A-D [12], gemessene und rekonstruierte Straßenanregungen im Folgenden mit „Welle ROMO“ und „Teststrecke Sport“ benannt.

Nach der Vermessung wurde die Komfortmetrik (1) und die Metrik zur Straßenhaftung (2) pro Rad berechnet. Um je einen einzelnen Wert für Fahrkomfort zu bekommen, wurde über die Räder gemittelt und anschließend auf die Werte des Vergleichsreglers normiert. Das bedeutet, dass Werte kleiner als 1 eine bessere Performanz als der Vergleichsregler hinweisen und Werte größer als 1 eine entsprechend schlechtere Performanz kennzeichnen. Die gelernten Regler werden in den folgenden Abbildungen mit KI und einer anschließenden eindeutig zuordenbaren Trainingsid bezeichnet. Der modellbasierte und in Simulation optimierte, kombinierte SH-GH Regler wird als

Model SHGH bezeichnet. In Abbildung 30 und Abbildung 31 sind die Ergebnisse aus den Versuchen aufgeschlüsselt nach Anregung, Regler und Metrik gezeigt.




Abbildung 30: Heatmap Darstellung des Fahrkomforts aus der experimentellen Erprobung der gelernten Vertikaldynamikreglern

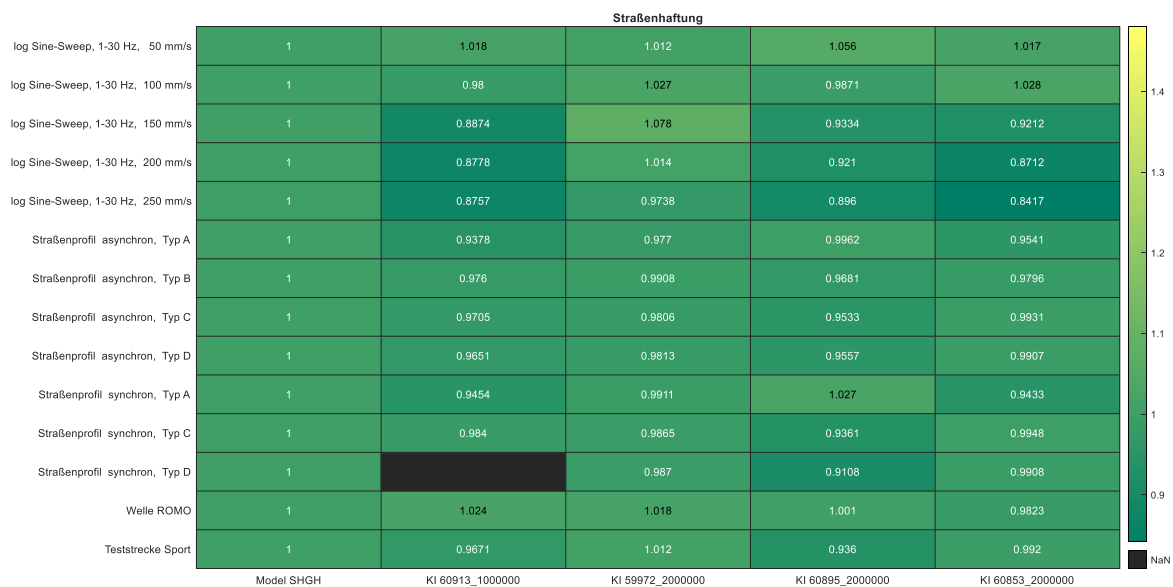


Abbildung 31: Heatmap Darstellung der Straßenhaftung aus der experimentellen Erprobung der gelernten Vertikaldynamikreglern

In Abbildung 32 sind die Ergebnisse aggregiert als Pareto Plot dargestellt. Hierbei geht zwar die Information über die Zuordnung zu den entsprechenden Anregungen verloren, aber es entsteht ein besserer Überblick über die Agenten. Abbildung 32 ist so zu lesen, dass jeder Punkt die Auswertung eines Reglers auf einer Anregung darstellt, aufgeschlüsselt nach den verschiedenen Reglern. Ein Punkt links der 1 bedeutet eine bessere Straßenhaftung als der Referenzregler, ein Punkt unterhalb der 1 einen besseren Fahrkomfort und ein Punkt links unterhalb der 1 verbessert beide Metriken gleichzeitig.




Abbildung 32: Pareto Darstellung der Ergebnisse aus der experimentellen Erprobung der gelernten Vertikaldynamikreglern

Aus Abbildung 32 ist zu erkennen, dass viele gelernte Reglervarianten meistens mindestens eine Metrik verbessern. Speziell der Regler KI 60853_2000000 verbessert, bis auf eine einzige Ausnahme, immer mindestens eine der beiden Metrik.

Diese Ergebnisse zeigen, dass mit Methoden des Reinforcement Learning ein Regler anhand eines Simulationsmodells trainiert werden kann, welcher einen modellbasierten Regler auf dem Stand der Technik übertreffen kann. Die quantitativen Messungen am Stempelprüfstand bestätigen die Potentiale von lernbasierten Reglern für die Anwendung in der Vertikaldynamikregelung. Die Ergebnisse sind insbesondere beachtenswert, da der Nutzen nicht nur in Simulation, sondern auch in quantitativen Messungen am echten Fahrzeug gezeigt werden konnte.

1.3 Zusammenfassung der Ergebnisse des Projekts

Im KIFahr Projekt wurde mittels Methoden des Reinforcement Learnings ein Regelgesetz gelernt, welches qualitativ und quantitativ einen Regler auf dem Stand der Technik in den meisten Anregungsszenarien übertreffen kann.

Um dies zu erreichen, wurde das Versuchsfahrzeug AFM mit den nötigen Sensoren und Aktuatoren sowie Rapid Control Prototyping (RCP) Systemen ausgerüstet. Durch umfangreiche Vermessung von sowohl Einzelkomponenten als auch dem gesamten Fahrzeug wurde eine umfassende Datenbasis geschaffen. Auf Basis dieser Messdaten wurden Komponentenmodelle und Modelle des gesamten Fahrzeugs erstellt. Bei der Modellierung des Dämpfers kamen hierbei sowohl datenbasierte Modellierungsmethoden basierend auf Neuronalen Netzen als auch physikalisch motivierte Methoden zum Einsatz. Darüber hinaus wurden Fahrzeugmodelle in unterschiedlicher Komplexität und Simulationsdauer je nach Einsatzzweck erstellt. Für das Training des Reglers, den Reglerexport und die Reglervalidierung wurden neue Software-Werkzeugketten entwickelt oder bestehende Werkzeugketten für den Anwendungszweck umfassend erweitert und angepasst. Zur Ausführung des gelernten Reglers wurde innerhalb des Projekts ein neues und leistungsstarkes Steuergerät für die Vertikaldynamikregelung entwickelt und eine vorkompilierte Reglerbibliothek bereitgestellt. Um die sichere Ausführung des Reglers gewährleisten zu können, wurde ein Absicherungskonzept entwickelt und im realen Fahrversuch erprobt. Die Performanz des in Simulation gelernten Reglers wurden sowohl qualitativ im realen Fahrversuch als auch quantitativ durch Messungen an einem Vertikaldynamikprüfstand bestätigt.

2 Ergänzende Angaben

2.1 Wichtigste Positionen des zahlenmäßigen Nachweises

Für das DLR wurden im Wesentlichen Personalkosten inkl. der Institutsgemeinkosten nachgewiesen. Wegen der pandemischen Lage während der Projektlaufzeit wurden nur sehr wenig Projektreisen durchgeführt.

Für die KW automotive GmbH wurden ausschließlich Personalkosten nachgewiesen. Während der Projektlaufzeit wurden pandemiebedingt keine Projektreisen durchgeführt.

2.2 Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Die geleisteten Projektarbeiten waren entweder von vornherein nach dem Plan des Projektantrags vorgesehen oder ergaben sich aus der Notwendigkeit die Projektziele zu erreichen, insbesondere für die prototypische Darstellung von KI-basierten Vertikaldynamikreglern in Fahrversuchen und auf dem Stempelprüfstand. Alle durchgeführten Arbeiten waren für die Erreichung der Projektziele angemessen.

2.3 Verwertbarkeit der Ergebnisse

In dem Vorhaben wurden Methoden der künstlichen Intelligenz aus der Wissenschaft - insbesondere aus dem Bereich des Reinforcement Learnings (RL) - in die praktische Anwendung für die Regelung und Abstimmung von semi-aktiven Dämpfern straßengebundener Fahrzeuge transferiert. Entscheidend dabei war die Entwicklung und Implementierung von effizienten und robusten Software-Werkzeugketten, die die beschriebenen Problemstellungen bestmöglich lösen und vorrangig im Mobilitätssektor angewendet werden sollen.

Die Automatisierung des Reglerauslegungsprozesses mittels RL und der Generierung von Systemmodellen aus Messdaten bietet KW automotive hochmoderne Methoden, um aktuelle und künftige Anforderungen der Märkte effizient zu bedienen. Durch die Zusammenarbeit zwischen KW automotive und dem DLR-Institut für Systemdynamik und Regelungstechnik wurde darüber hinaus bei KW automotive Wissen im Bereich KI eingeführt und in die Praxis umgesetzt. Die Firma KW wurde somit dazu befähigt, KI-Anwendungen nicht nur zu nutzen, sondern auch zu verstehen, in einem nächsten Schritt weiterzuentwickeln und in ihre Produkte einzuarbeiten. Durch die Erprobung des Reglers auf einem Prototypensystem wurde die Anwendbarkeit von RL-basierten Reglern in der Praxis gezeigt.

Die KW automotive GmbH wird sich im Anschluss an das Kooperationsprojekt mit der Überführung des prototypischen Aufbaus in eine seriennahe Anwendung beschäftigen, um die beschriebenen Vorteile in Ihre Produkte einfließen zu lassen. Die Erfahrung aus vorangegangenen Forschungsprojekten zeigt hier einen zeitlichen Horizont von 2-3 Jahren bis zur Einführung der neuen Technologien (Prototypen – Vorserie – Serie).

Zeitnahe Verwertung lässt sich aus verschiedenen Nebenergebnissen ableiten:

- Komplexe (KI-basierte) Dämpfermodelle: Solche Modelle sind für die Auftragsvergabe und die Nominierung bei verschiedenen Herstellern bereits gefordert. Die Hersteller können basierend auf diesen Modellen bereits frühzeitig erste simulative Vorabstimmungen durchführen und die Dämpfereigenschaften mittels des digitalen Zwillings bewerten und optimieren. Das Wissen und die Verfügbarkeit solcher komplexen Modelle erhöht für KW automotive die Chance als Lieferant bei einigen Herstellern nominiert zu werden.
- Softwareoptimierungen im Bereich der Sensorsignalverarbeitung: Im KIFahr Projekt verbesserte Sensorsignalverarbeitung ermöglicht eine genauere Signalauswertung und Signalschätzung. Die optimierte Signalverarbeitung kann direkt in bestehende Regelungsansätze integriert werden und steigert dadurch auch die Regelgüte der bestehenden Reglerkonzepte.
- Entwicklungs-ECU mit höherer Prozessor-Taktung und zusätzlichen Ein- und Ausgängen: Im Zuge des Förderprojektes wurde aufgrund des Bedarfs einer höheren Rechenleistung

und der zusätzlichen Sensorsignale, ein neues Steuergerät entwickelt. Der Einsatz und die Funktionalität dieser Komponenten werden über die Projektlaufzeit hinaus untersucht. Neben der Implementierung von KI-basierten Algorithmen, stellt die Platine umfangreiche Einsatzmöglichkeiten im Bereich der Entwicklung dar. Ein erster Einsatz ist bereits, mit der Vorentwicklung eines neuen Steuergerätes für die Anwendung im Bereich von Luftfahrzeugen, gestartet worden.

Die methodischen Ansätze zum Training von KI-basierten Reglern, dem Lernen von Systemmodellen aus Messdaten und der Absicherung von KI-basierten Reglern werden im Anschluss an das Projekt innerhalb des DLR-Instituts SR abstrahiert, optimiert und weiterentwickelt. Ziel des Instituts ist es weitere methodische Fortschritte im Bereich der KI-gestützten Regelungsmethoden zu erzielen. Besonders in Bezug auf die Durchgängigkeit der Software-Werkzeugketten stellen die in KIFahr entwickelten und angewandten Softwaretools einen wichtigen Beitrag für den Fortschritt in der Umsetzung KI-basierter Regelungsmethoden dar. Die generischen Methoden der Werkzeugketten können für Regelungsprobleme in der Robotik, dem Energiesektor, der Luft- und Raumfahrt sowie dem Automobil- und Schienenfahrzeugbereich Anwendung finden.

2.4 Fortschritt auf dem Gebiet des Projekts bei anderen Stellen

Fortschritte bei anderen Stellen in der KI-basierten Regelung von semi-aktiven Dämpfern in der Fahrzeugtechnik sind den Autoren während der Durchführung des Vorhabens nicht bekannt geworden.

2.5 Erfolgte und geplante Veröffentlichungen

- Blog-Post auf der Webseite von KW automotive <https://blog-de.kwautomotive.net/dlr-und-kw-entwickeln-kunstliche-intelligenz-zur-fahrwerksregelung/>
- Blog-Post <https://vsdc.de/en/afm-on-vertical-dynamics-test-rig/> auf einer der Webseiten des DLR-Instituts inkl. Video auf Youtube <https://youtu.be/sGpFgF8YWJY> einer der Messkampagnen auf dem Stempelprüfstand von KW automotive
- Ultsch, J.; Bieri, C.; Pfeiffer, A.; Ruggaber, J.; Baumgartner, D.; Helling, B.; Brembeck, J.; Rohn, M.; Wahl, U.; Koch, M.; Ziegler, M.; Wörner, J.; Klenk, S.; Hälsig, F.; Wurst, T.: KIFahr – AI-based Vertical Dynamics Control. Poster für das „All-Hands-Meeting 2022 of BMBF funded AI-research projects“, MCML, 10. Januar 2022.
- Ruggaber, J.; Ahmic, K.; Brembeck, J.; Baumgartner, D.; Tobolář, J. AI-For-Mobility—A New Research Platform for AI-Based Control Methods. Appl. Sci. 2023, 13, 2879. <https://doi.org/10.3390/app13052879>
- (geplant) Blog-Post <https://vsdc.de/en/project-kifahr> auf der Webseite des DLR-Instituts

3 Beiträge der Autoren

Nachfolgend sind die Beiträge der Autoren zu den einzelnen Themen aufgelistet. Die Abkürzungen der Namen folgen dem Schema *Vorname.Name*.

- Konzept, Ausrüstung und Vermessung des Versuchsträgers: D.B., J.R., U.W., M.Z., M.R., S.K., T.K., J.U., J.B., M.K.
- Modellierung der Synthesemodelle: J.U., J.T., A.P.
- Modellierung und Simulation des Vollfahrzeugs und Software-in-the-Loop: J.T., J.B., J.R., T.K., D.B.
- Implementierung der Software-Toolketten: J.U., A.P., T.K., J.R., S.K.
- Entwicklung, Training und Integration des Regelsystems: J.U., J.R., A.P.
- Erprobung des Regelsystems: U.W., J.R., M.R., D.B., T.K., J.B., J.U.
- Projektleitung und -management: J.B., A.P., M.R., J.U.

Die Autoren bedanken sich bei Christina Schreppel, Benedikt Helling und Caspar Bieri für die Unterstützung bei der Umsetzung des Projekts.

4 Literatur

- [1] S. M. Savaresi, C. Poussot-Vassal, L. Dugard, O. Sename und C. Spelta, *Semi-Active Suspension Control Design for Vehicles*, Elsevier Ltd., 2010.
- [2] M. Fleps-Dezasse, „Linear Parameter-Varying Control of Full-Vehicle Vertical Dynamics using Semi-Active Dampers,“ Dissertation, Fakultät für Luft- und Raumfahrttechnik, Universität der Bundeswehr München, 2018.
- [3] J. Ultsch, J. Brembeck und R. Castro, „Learning-Based Path Following Control for an Over-Actuated Robotic Vehicle,“ in *VDI-AUTOREG, 2019*, Mannheim, 2019.
- [4] T. P. Lillicrap, J. J. Hunt, A. Pritzel, N. Heess, T. Erez, Y. Tassa, D. Silver und D. Wierstra, „Continuous control with deep reinforcement learning,“ *ICLR (arXiv preprint arXiv:1509.02971)*, 9 9 2016.
- [5] M. Howell, G. Frost, T. Gordon und Q. Wu, „Continuous action reinforcement learning applied to vehicle suspension control,“ *Mechatronics*, pp. 263-276, 1997.
- [6] S. Tognetti, S. M. Savaresi, C. Spelta und M. Restelli, „Batch Reinforcement Learning for semi-active suspension control,“ in *2009 IEEE Control Applications*, 2009.
- [7] M. Akraminia, M. Tatari, M. Fard und R. Jazar, „Designing active vehicle suspension system using critic-based control strategy,“ *Nonlinear Engineering*, 2015.

- [8] T. Haarnoja, A. Zhou, P. Abbeel und S. Levine, „Soft Actor-Critic: Off-Policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor,“ in *Proc. of the 35th Int. Conf. on Machine Learning*, Stockholm, Schweden, 2018.
- [9] J. Ruggaber, K. Ahmic, J. Brembeck, D. Baumgartner und J. Tobolář, „AI-For-Mobility—A New Research Platform for AI-Based Control Methods,“ *Applied Sciences*, Bd. 13, p. 2879, February 2023.
- [10] Institut für Systemdynamik und Regelungstechnik, DLR, „Introducing the all new AI For Mobility Research Platform,“ 01 03 2021. [Online]. Available: <https://vsdc.de/en/the-basic-vehicle-platform-of-afm/>. [Zugriff am 22 05 2023].
- [11] Institut für Systemdynamik und Regelungstechnik, DLR, „The Sensor, Computer and Actuator Architecture of the AFM,“ 01 06 2022. [Online]. Available: <https://vsdc.de/en/sensor-and-actuator-setup-of-the-afm/>. [Zugriff am 22 05 2023].
- [12] International Organization for Standardization, ISO 8608:2016 Mechanical vibration - Road surface profiles - Reporting of measured data, 2016.
- [13] M. Fleps-Dezasse, J. Tobolar und J. Pitzer, „Modelling and parameter identification of a semi-active vehicle damper,“ in *Linköping Electronic Conference Proceedings*, 2014.
- [14] A. Pfeiffer, „Optimization Library for Interactive Multi-Criteria Optimization Tasks,“ in *9th International Modelica Conference*, München, 2012.
- [15] Modelica Association, „FMI Standard,“ MA, 2023. [Online]. Available: <https://fmi-standard.org/>.
- [16] A. Raffin, A. Hill, A. Gleave, A. Kanervisto, M. Ernestus und N. Dormann, „Stable-Baselines3: Reliable Reinforcement Learning Implementations,“ *Journal of Machine Learning Research*, Bd. 22, pp. 1-8, 2021.
- [17] A. Raffin, *RL Baselines3 Zoo*, GitHub, 2020.
- [18] M. Unterreiner, Modellbildung und Simulation von Fahrzeugmodellen unterschiedlicher Komplexität. Dissertation, Universität Duisburg-Essen, 2014.