

Schlussbericht

der
TWT GmbH Science & Innovation
über das Förderprojekt

newAIDE **new Artificial Intelligence based Design in Engineering**

öffentlich

Autoren:

Tobias Heel

Datum:

28.08.2024



**Finanziert von der
Europäischen Union**
NextGenerationEU

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

**Die Verantwortung für den
Inhalt dieser Veröffentlichung
liegt beim Autor.**

Förderkennzeichen: 19I21012E

Laufzeit: 01.06.2021 – 31.05.2024

Inhaltsübersicht

I	KURZE DARSTELLUNG	3
1.	Aufgabenstellung	3
	AP4 Fahrwerk	4
2.	Voraussetzungen, unter denen das Vorhaben durchgeführt wurde	5
3.	Planung und Ablauf des Vorhabens	6
	Projektorganisation und -dokumentation	6
	Projekttreffen	6
4.	Wissenschaftlicher und technischer Stand zu Beginn.....	7
5.	Zusammenarbeit mit anderen Stellen oder Firmen außerhalb des Verbundprojektes	7
II	EINGEHENDE DARSTELLUNG	8
1.	Erzielte Ergebnisse.....	8
	AP4 – Fahrwerk.....	8
2.	Wichtigste Positionen des zahlenmäßigen Nachweises	18
3.	Notwendigkeit und Angemessenheit der geleisteten Arbeit	18
4.	Wissenschaftliche, technische und wirtschaftliche Ergebnisverwertung	19
	Industrielle Anwendung	19
	Aufbauende Forschungsaktivitäten	20
5.	Während der Durchführung des Vorhabens bekannt gewordener Fortschritt auf dem Gebiet bei anderen Stellen	20
6.	Erfolgte oder geplante Veröffentlichungen der Ergebnisse	21
III	ANHANG.....	22
	Abbildungsverzeichnis.....	22
	Tabellenverzeichnis.....	22
7.	Literaturverzeichnis.....	23

I KURZE DARSTELLUNG

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Klimaschutz unter dem Förderkennzeichen 19I21012E gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.

1. Aufgabenstellung

Im Projekt newAIDE erforschten die Partner den Einsatz von Methoden der Künstlichen Intelligenz (KI) in komplexen, simulationsbasierten Auslegungsprozessen der Fahrzeugentwicklung mit dem Ziel, diese zu beschleunigen, zu optimieren und teilweise zu automatisieren. Neben der Verbesserung einzelner Auslegungsdisziplinen durch KI-Ansätze wurde im Projekt newAIDE mithilfe der Teilprojekte eine grundlegende Datenbankstruktur und Datenstrukturierung erforscht, die den Einsatz von KI-Methoden in der Fahrzeugauslegung unterstützt und vereinfacht. Dies ist eine Basis für eine flächendeckende Einführung von KI-Ansätzen in der Fahrzeugauslegung und darüber hinaus.

Für die konkrete Forschungs- und Entwicklungsarbeit adressieren die Konsortialpartner im Projekt vier Anwendungsfälle aus den komplexen Auslegungsprozessen für Crash-Strukturen, Vibroakustik, Fahrwerk und Exterieur eines Fahrzeugs. Zusammen bilden diese Auslegungsdisziplinen das Spektrum der Komplexität im Bereich der Fahrzeugauslegung ab. Jede einzelne Disziplin kann durch KI-Ansätze schneller, effizienter und in höherer Qualität gestaltet werden.

Ein Fokus des Projekts liegt auf Auslegungsprozessen, bei denen grundlegende Entscheidungen auf menschlichen Erfahrungswerten und Erfahrung aufbauen. Diese sollen durch KI-Algorithmen erlernt und unterstützt werden auf Basis von umfassenden Test-, Konstruktions- und Simulationsdaten. Dadurch können komplexe Auslegungsaufgaben, die aktuell noch immer von den Fähigkeiten und der Erfahrung des Entwicklers abhängig sind, durch KI-Methoden in über automatisierbare, datenbasierte Entscheidungshilfen verbessert werden. Dieser Ansatz senkt nicht nur den Zeitaufwand für die Entscheidungsfindung, sondern erlaubt auch die Einbeziehung von Randbedingungen und anderer Faktoren, z. B. Parameter aus der Fertigung, Ausstattungs- und Karosserievarianten der Produkte oder zusätzliche Auslegungslastfälle, die bislang aus Kapazitäts- und Komplexitätsgründen unberücksichtigt bleiben mussten. Damit ebnet das Projekt den Weg von

„traditionell“ eher starren Entscheidungsregeln bei Auslegungsprozessen hin zu vernetzten, komplexen Entscheidungen unterstützt durch Algorithmen.

Ein weiterer Fokus des Projekts newAIDE liegt auf der Entwicklung KI-unterstützender Datenbankstrukturen und Datenstrukturierungen. Die Projektpartner erforschten mithilfe der vier Anwendungsfälle, ob die verschiedenen KI-Ansätze durch eine gemeinsame Strukturierung der Daten und Datenbanken unterstützt und verbessert werden können. Eine solche Struktur fördert nicht nur einen breiteren KI-Einsatz in der Fahrzeugentwicklung, sondern kann auch die Teilergebnisse positiv beeinflussen, sowie Zusammenhänge und Abhängigkeiten zwischen den einzelnen Auslegungsdisziplinen aufdecken, die nur durch die Vernetzung der verschiedenen Datengrundlagen identifizierbar werden.

AP4 Fahrwerk

Die fahrdynamischen Eigenschaften eines Fahrzeugs werden von einer Vielzahl von Parametern beeinflusst. Bisher wurden die Regelsysteme nur geringfügig virtuell vorappliziert, wodurch die Voreinstellungen des Fahrzeugs manuell durch aufwendige Tests erfolgen musste.

Anhand von ausgewählten Use-Cases wurden KI-Ersatzmodelle entwickelt und trainiert, die auf einer möglichst großen Datenbasis aufbauen. Um eine effiziente Prozessgestaltung zu realisieren, wurden die Machine-Learning-Modelle weitgehend automatisiert, was neben der Berücksichtigung einer Reihe von Einflussparametern im Bereich Fahrwerk auch die Datenbeschaffung, bzw. -generierung umfasst. Verschiedene Methoden für die Generierung von Ersatzmodelle wurden erforscht, auf die Problemstellungen angewendet und letztlich bewertet. Anschließend wurden die Modelle für die virtuelle Vorapplikationen optimiert und validiert.

Durch den Einsatz von KI-Algorithmen entstanden im Bereich des Fahrwerks und der Fahrdynamik auf Basis von vorhandenen und erzeugten Daten virtuelle Vorapplikationen für Regelparameter oder mechanische Fahrwerksparameter. Diese Vorapplikationsmethoden können zukünftig zu einer deutlichen Reduzierung der manuellen Aufwände sowie zur Senkung der Rechen- und Entwicklungszeit beitragen.

2. Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

Die vorrangegangenen Arbeiten der Projektpartner in Hinblick auf die Aufgabenstellungen im Projekt sind zum Teil im Stand zu Projektstart beinhaltet und durch entsprechende Literaturangaben belegt. Dieses umfangreiche Vorwissen nutzten die Partner um es in den verschiedenen Entwicklungsbereichen der Projektarbeit einfließen zu lassen. Durch die Bündelung der Kompetenzen und Verknüpfung der Entwicklungsstränge konnten die Partner Synergieeffekte nutzen, um sowohl die einzelnen Auslegungsprozesse zu verbessern, als auch die methodische Einführung von KI-Methoden in der Fahrzeugentwicklung fördern.

Um Ihrer Mission des „Technisch-Wissenschaftlichen Transfers“ gerecht werden zu können, war die TWT GmbH seit 1995 Partner in zahlreichen nationalen und international geförderten Forschungsprojekten erfolgreich und ist auch aktuell an 10 Forschungskonsortien beteiligt. Die drei für das newAIDE-Projekt wegberreitendsten Forschungsvorarbeiten fanden in den folgenden Projekten statt: Angefangen beim AUTOSIM-Projekt (6. EU-Rahmenprogramm), in dem der Weg für die effektive Nutzung von Simulationen in der europäischen Fahrzeugindustrie bereitet wurde; über die Entwicklung eines Co-Simulations-Interfaces (FMI-Standard) im als exzellent ausgezeichneten ITEA3-Projekt ACOSAR; und die Umsetzung Cyber-Physikalischer-Systeme basierend auf einer integrierten Werkzeugkette von der Modellierung über die Simulation bis zur Prüfung im EU-Projekt INTO-CPS (Horizon 2020).

Die TWT GmbH setzt den Schwerpunkt im Projekt auf die Entwicklung und prototypischen Ausgestaltung innovativer Methoden in der Fahrwerksentwicklung. Der Fokus liegt dabei auf der Schaffung eines neuen Ansatzes zur Metamodellierung, der die Vorteile einer nachvollziehbaren und realitätsnahen physikalischen Phänomenbeschreibung mit den enormen Geschwindigkeitsvorteilen neuartiger KI-Methoden kombiniert. Grundlage für die Erstellung dieses Ansatzes sowie der effizienten Einbindung der weiteren hier beschriebenen und noch zu entwickelnden Methoden ist zudem die notwendige IT-Befähigung des Workflows. Die TWT GmbH legt hierbei das Hauptaugenmerk auf den Workflow von MKS-Modellen mittels Simpack und den Zweispurmodellen (Matlab/Simulink).

3. Planung und Ablauf des Vorhabens

Projektorganisation und -dokumentation

Das Verbundvorhaben newAIDE unterteilt sich in 4 verschiedene Arbeitspakete. Die verschiedenen Verbundpartner sind je nach eigenem gesetztem Schwerpunkt unterschiedlich in den Arbeitspaketen repräsentiert. Die Bearbeitung der APs erwartet somit eine stetige Abstimmung untereinander. Abbildung 1 zeigt die Organisation innerhalb von newAIDE auf.

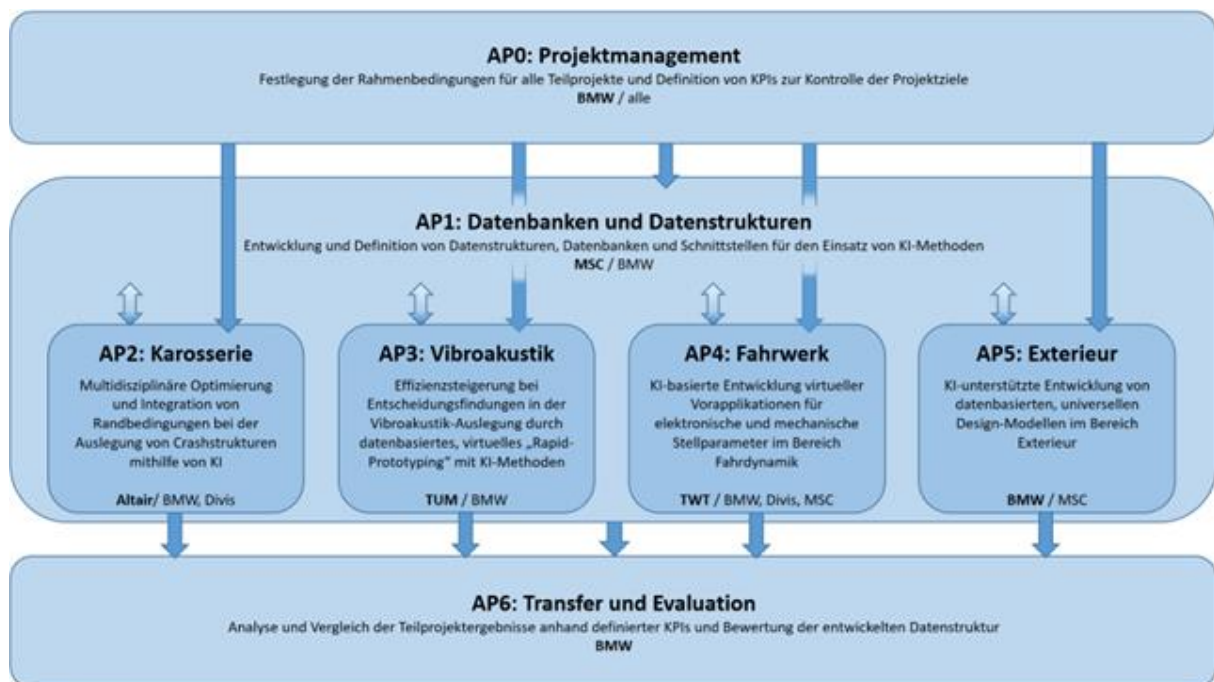


Abbildung 1: Übersicht der newAIDE-Arbeitspakete und Bearbeitungsschwerpunkte der jeweiligen Partner.

Die Arbeiten der TWT GmbH verteilen sich auf das Arbeitspakete AP4. Die Projektorganisation des Gesamtprojekts erfolgte von BMW, die Organisation des AP4 von der TWT. Es wurden die Tools Jira und Confluence von der Firma Atlassian zur Organisation und Dokumentation verwendet.

Projekttreffen

Der Austausch innerhalb des Konsortiums erfolgte durch zwei regelmäßige Formate. Zum einen das Konsortialtreffen alle 6 Monate und zum anderen das zweimonatige Regeltreffen, genannt Double-Monthly.

Das Konsortialtreffen fand immer in Präsenz statt und hatte eine Dauer von zwei Tagen. Der Fokus war hierbei auf dem persönlichen Austausch und die vertiefte fachliche

Diskussion der Arbeiten und Ergebnisse der Teilpakete. Bei den zweimonatigen Regeltreffen lag der Fokus auf den organisatorischen Themen und der Verknüpfung zwischen den Arbeitspaketen ohne detailliert in die fachliche Tiefe zu gehen. Entsprechend war hier der Umfang mit einem halben Tag geringer. Zur Reduktion des Reiseaufwandes und der -kosten wurden diese Treffen rein virtuell durchgeführt.

Zudem gab es einen zu Beginn wöchentlichen, später zweiwöchentlichen Regeltermin der Partner im AP4 zur Koordination und Organisation der Inhalte dieses Arbeitspakets, organisiert von der TWT.

4. Wissenschaftlicher und technischer Stand zu Beginn

Konstruktionen, Verfahren und Schutzrechte wurde nicht als Basis für die Durchführung genutzt, sondern die erwähnte Fachliteratur als allgemein verfügbare Quelle sowie das vorhandene Fachwissen der TWT und der Partner.

Die Verwendung vieler, alternativer Methoden des Machine Learning zur Metamodellierung von Simulationsmodellen ist heute Stand der aktuellen Forschung, auf dem im Projekt aufgebaut werden soll (siehe z. B. Bäck et al. [1]). Methoden der automatischen Hyperparameteroptimierung zur Umsetzung eines Automated Machine Learning Ansatzes [2] werden heute in der Automobilindustrie zur reinen Optimierung der Algorithmenparameter eingesetzt, nicht jedoch zur online-Auswahl des jeweiligen Metamodells wie bei der kombinierten Algorithmenselektion und Hyperparameteroptimierung [3]. Zur automatischen Auswahl des Machine Learning Modells, auch während der Optimierung, gibt es erste Ansätze [4, 5], die allerdings noch nicht für die rechenzeitintensiven Anwendungen in der Automobilentwicklung erweitert worden sind. Das gilt ebenfalls für neue Ansätze, in denen neben der Zielfunktion auch Restriktionen während der Optimierung gelernt werden [6, 7].

5. Zusammenarbeit mit anderen Stellen oder Firmen außerhalb des Verbundprojektes

Es wurde innerhalb des Projektes nicht mit anderen Stellen oder Firmen außerhalb der Verbundpartner gearbeitet.

II EINGEHENDE DARSTELLUNG

1. Erzielte Ergebnisse

Die inhaltlichen Arbeiten und Ergebnisse der TWT GmbH werden im Folgenden für das von der TWT bearbeitete Hauptarbeitspaket AP4 dargestellt.

AP4 – Fahrwerk

AP4.0 Definition der Use-Cases

In AP4.0 wurden gemäß Planung basierend auf den für die Fahrwerksauslegung relevanten Fahrdynamik-Phänomenen Use-Cases identifiziert, ausformuliert und so weit konkretisiert, dass damit im Rahmen der darauf aufbauenden Arbeitspakete weitergearbeitet werden kann. Dazu wurden in von TWT organisierten Workshops die notwendigen Informationen von Fach-Expert*innen der Entwicklungsabteilungen von BMW eingeholt und die Fahrdynamik-Phänomene zusammen mit den Konsortialpartner hinsichtlich eines Kriterienkatalogs für die Eignung im Projekt bewertet. Zu diesen Kriterien zählte neben der fachlichen Relevanz und simulativen Abbildbarkeit auch deren Eignung für eine spätere Multi-Objective-Optimierung. Der Schwerpunkt der Aktivitäten lag auf der Ausarbeitung des Use-Cases Aufbaubewegung.

Es wurden vier Use-Cases im Rahmen des Forschungsprojekts definiert und im Anschluss näher beleuchtet:

- Aufbaubewegung des mechanischen Fahrzeugs
- Kippen unter Regelsystembeteiligung
- Bremsen unter Regelsystembeteiligung
- μ -Split-Detektion unter Regelsystembeteiligung

AP4.1 Fahrwerk - Automatisierung Workflow

AP4.1.1 Workflow MKS

Ergänzend zu den umfangreichen Prozessautomatisierungen beim Adams-Workflow wurde die Anbindung der bei BMW ebenfalls verwendeten Simpack-Prozesskette u.a. an dem High-Performance-Computing-Cluster (HPC), sowie notwendige Automatisierungen an einem reduzierten Use-Case Aufbaubewegung von TWT umgesetzt bzw.

getestet. Die Nutzung von performanten Rechensystemen wie dem HPC zur Datengenerierung, ist bei der großen Anzahl an notwendigen Trainingsdaten und der sehr limitierten Entwicklungszeit notwendig.

Als Grundlage für die Nutzung der HPC-Infrastruktur wurde im Rahmen des Forschungsprojekts dazu eine bestehende Schnittstelle eines Automatisierungstools der Fahrwerksabteilung genutzt. Es wurde eine Fahrzeugvariante einer Limousine der Mittelklasse von TWT zusammen mit BMW identifiziert, die alle Anforderungen erfüllt. Die für den Use-Case notwendigen Steuerdateien zur Erzeugung der Modellvarianten und der Manöverdefinition wurden von TWT im JSON-Format aufgebaut.

Das MKS-Modell wurde von TWT so modifiziert, dass es die Vielzahl der benötigten Simulationssignale generiert. Dabei wurden diverse Möglichkeiten des weiteren Post-Processings untersucht. Letztendlich wurde für die Berechnung der CVs wie im Adams-Workflow auf das von der Fachabteilung bereitgestellte Postprocessing-Tool gesetzt. Einen Transfer der darin integrierten Berechnungsvorschriften auf einen stabileren bzw. besser integrierten Workflow wurde von TWT zusammen mit BMW evaluiert, hätte den Rahmen des Forschungsprojekts allerdings gesprengt.

Die Grundlage für einen durchgängigen Prozess im Sinne einer automatisierten globalen Optimierung ist damit geschaffen. Der Arbeitsablauf ist in der folgenden Abbildung 2 dargestellt.

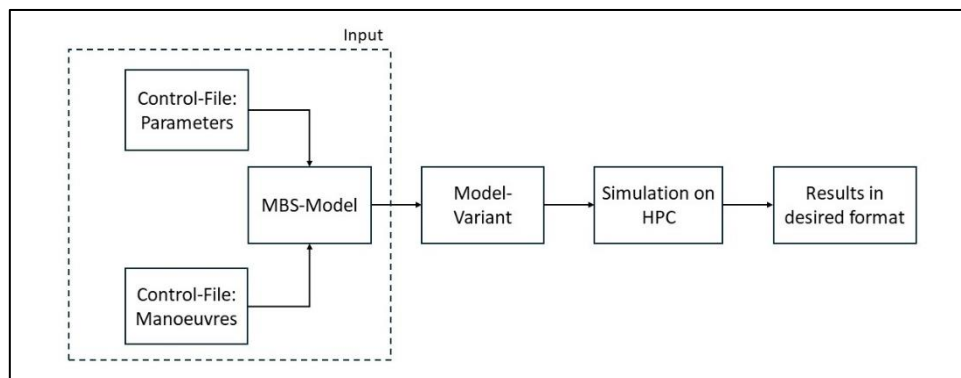


Abbildung 2: Workflow zur Generierung der Simulationsergebnisse der DOE.

AP4.1.2 Workflow Regelung und Erlebbarkeit

Der Kerngedanke dieses Arbeitspakets ist es, die Regelsysteme des Fahrzeugs mit einem hochrealistischen Mehrkörpersimulationsmodell zu verbinden, um die Vorhersagegüte deutlich zu verbessern. Ausgangslage war dabei eine Kopplung der Regelsysteme, mit einem einfachen, dafür aber schnell zu implementierenden Zweispurmodell, um das mechanische Systemverhalten des Fahrzeugs anzunähern. Die

Regelsysteme, die meist als Black-Box-Modelle vorliegen, werden aktuell in der BMW-Umgebung zusammengeführt. Eine Herausforderung bei der direkten Integration eines 3D MKS-Modells ist die Implementierung der Kommunikation von den Regelsystemmodellen mit einem MKS-Solver eines Drittanbieters. Eine Synchronisierung der Daten zwischen mechanischem Modell, dem Regelsystemmodell und dem System Fahrsimulator ist für jeden Berechnungsschritt notwendig.

Der **online-Fall** beschreibt die Situation am realen Fahrsimulator, bei dem echtzeitfähige Modelle genutzt werden, um das Systemverhalten des zu testenden Fahrzeugs abzubilden und die Bewegungen des Simulators und das generelle Feedback an den Testfahrer zu erzeugen, sowie die Fahreranweisung aufzunehmen und in eine Systemantwort umzusetzen.

Im Online-Fall wird kein Fahrmanöver programmiert, da die gesamte Kommunikation *online* bzw. aktiv entsprechend der Eingabe des Fahrers in Echtzeit erfolgt. Im Rahmen des Forschungsprojekts wurde von TWT in enger Absprache mit BMW die MKS-Software mit den Controllern der diversen Regelsysteme und dem eigentlichen Fahrsimulator verbunden. Das MKS-Modell nutzt dabei neben der Kommunikation mit dem Leitsystem auch die Eingaben des Fahrers bzw. des Fahrsimulators als Input. Der erste Schritt bei der Umsetzung war dabei die Definition des Regelverbunds, um die benötigten Signale zu definieren. Verschiedene Möglichkeiten dies umzusetzen, wurden dabei wie bereits beschrieben miteinander verglichen und teilweise erprobt. Die Kommunikation zwischen den drei verschiedenen Teilnehmern wird durchgeführt unter Verwendung der Open-Source-Software Silkit in der Loop-Bibliothek und des speziellen Distribution Linux-Betriebssystems, das Echtzeitzugriff auf den Speicher bietet. Dadurch kann auf die Variablen des MKS-Modells zugegriffen werden und sie können in Abhängigkeit von den Rückmeldungen des Fahrers und des Kontrollsystems in Echtzeit aktualisiert werden.

Die aufgebaute Kommunikationsstruktur und die einzelnen Teilnehmer sind in der Abbildung 3 zu sehen.

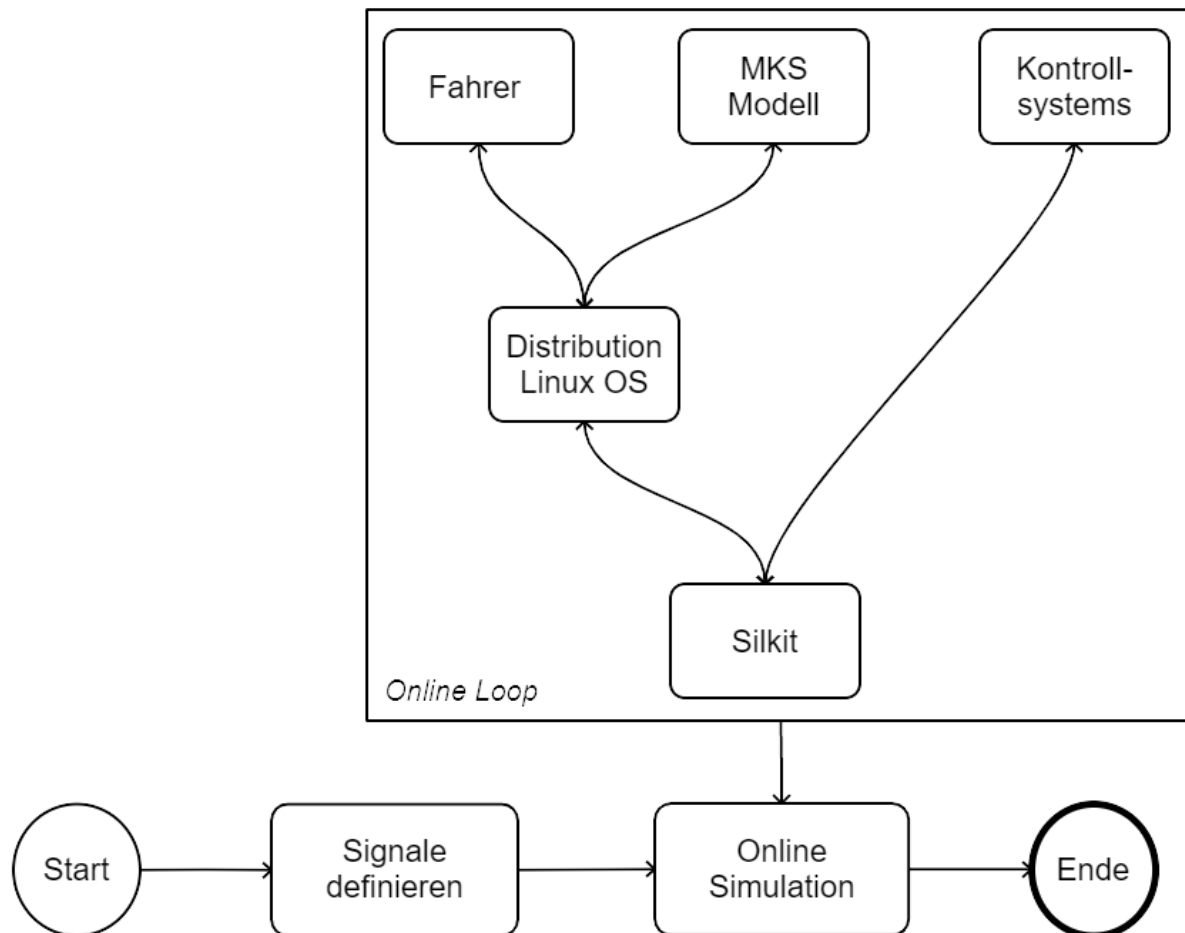


Abbildung 3: Kommunikationsstruktur im Online-Workflow.

Im **Offline-Fall** ist weder der reale Fahrsimulator noch ein Testfahrer beteiligt. Der Input für das Fahrzeugmodell erfolgt virtuell. Der Offline-Fall ist wichtig, um effizient Probleme an den Modellen oder den Kommunikationsschnittstellen zu identifizieren und zu lösen, damit kostspielige Standzeiten am realen Fahrsimulator reduziert werden können.

Das Fahrmanöver ist bereits in der MKS-Umgebung programmiert. Daher benötigt dieser Fall kein spezielles Betriebssystem oder die Eingabe eines aktiven Benutzers und kann zur Bewertung aller klassischen Manöver mit aktiven Regelsystemen verwendet werden.

Die Arbeit von TWT konzentrierte sich somit auf die Kommunikation zwischen dem laufenden MKS-Modell und den Regelsystemen.

Die Kommunikationsstruktur und die einzelnen Teilnehmer sind in der Abbildung 4 zu sehen.

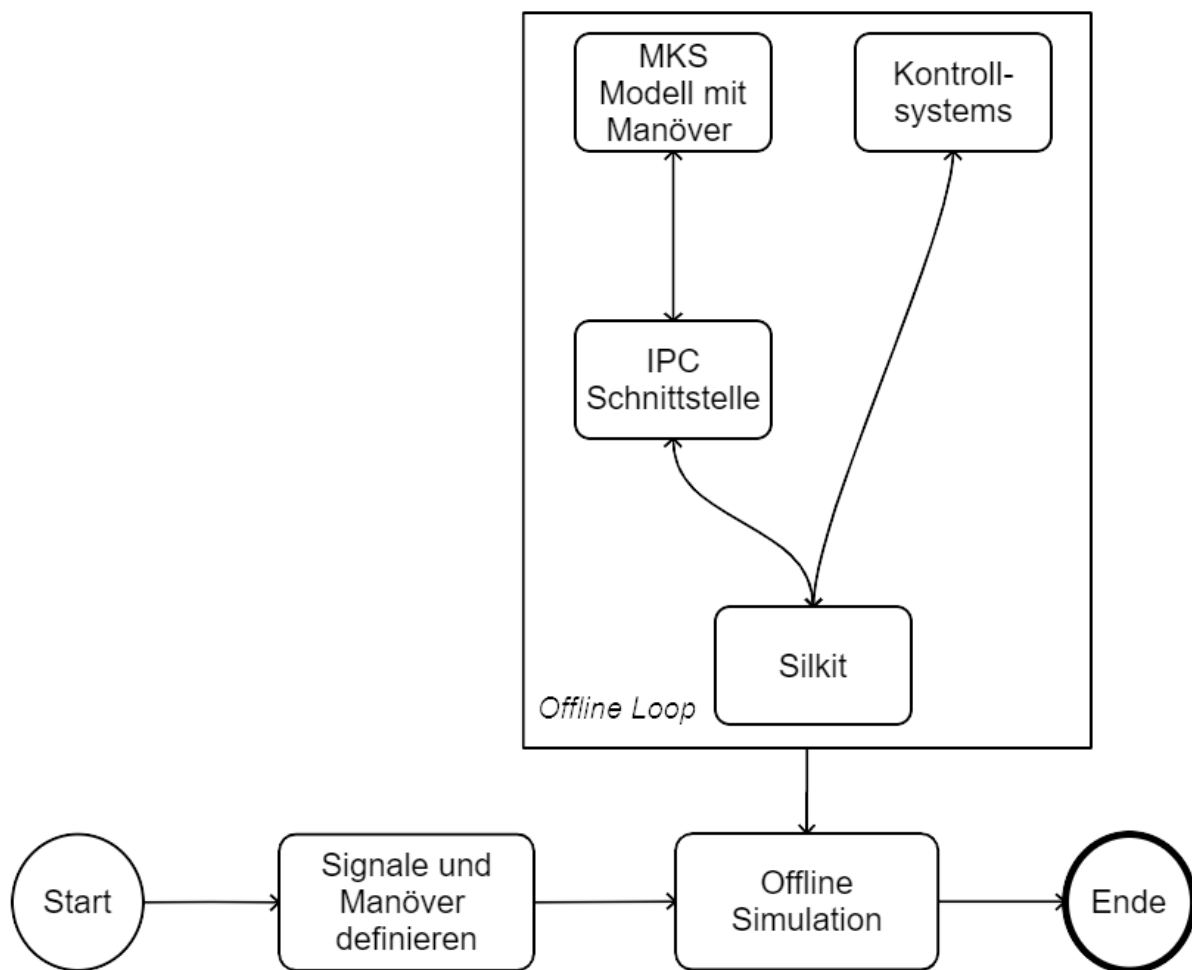


Abbildung 4: Kommunikationsstruktur im Offline-Workflow.

Auch hier ist der erste Schritt die Auswahl der Signale und den zu testende Controller. Es wurde ein kleiner Testfall mit einem einfachen Webmanöver erstellt und alle benötigten Signale wurden in das MKS-Modell implementiert. Der Controller wurde im Rahmen dieses Projekts nicht verändert und als eine Blackbox, die Signale sendet und empfängt, behandelt. Die Genauigkeit und die internen Berechnungen werden als akkurat erachtet, und es mussten keine Arbeiten an dieser Seite vorgenommen werden.

Somit ist dieser Teilnehmer der Kommunikationsstruktur bereits eingestellt und kann angerufen werden. Der nächste Schritt bestand darin, den anderen Teilnehmer für die Kommunikation einzurichten, nämlich das MKS-Modell zur Kommunikation mit dem Controller. Die Herausforderung dabei ist, dass der MKS-Solver ebenfalls eine Blackbox ist, die losgelöst von der gesamten Kommunikation läuft. Um auf die Daten des MKS-Solvers zugreifen zu können, wird ein zusätzlicher Schritt bzw. ein Programm benötigt, das auf die Daten zugreifen, sie abrufen und aktualisieren kann. Dafür wurden erneut Funktionen der Silkit-Bibliothek genutzt, die eine synchronisierte Kommunikation

zwischen Simpack über die Inter-Process Communication (IPC)-Schnittstelle auf der einen Seite und dem Regelsystemverbund auf der anderen Seite ermöglichen.

Die dargestellten Kommunikationsstrukturen des Offline-, wie auch des Online-Falls konnten von TWT bzw. BMW erfolgreich getestet werden. Die Methode kann somit zukünftig in den Entwicklungsprozess überführt werden.

AP4.3 Datenbeschaffung

In Kapitel AP4.1.1 wurde bereits der Workflow für die Nutzung des HPC-Rechenclusters beschrieben. Der von TWT aufgebaute HPC-Workflow wurde schließlich erfolgreich mit einer reduzierten Variante des bereits durchgeführten DoE für den Use-Case Aufbaubewegung getestet. Konkret wurden folgende Manöver betrachtet:

- Hydopuls (eine Variante)
- CSST
- QSSC
- SWD
- WEAVE

und diese mit drei Fahrzeugvarianten einer Mittelklasse-Limousine in einer DoE kombiniert. Dabei wurde darauf geachtet alle Parametertypen der vollständigen DoE abzubilden. Der erfolgreich durchgeführte Test diente der Validierung des Workflows unter Einbindung des HPCs, die Ergebnisse wurden nicht weiter für das Training von Modellen verwendet.

AP4.4 Ersatzmodellerstellung

Dieses Kapitel beschäftigt sich mit der Erzeugung von KI-Methoden, um performante Ersatzmodelle mit hoher Prädiktionsgüte zu erzeugen, sowie deren Anwendung auf definierte Use-Cases.

Datengrundlage Aufbaubewegung

Basierend auf den in Adams/Car berechneten DoE-Ergebnissen aus dem Use-Case Aufbaubewegung, konnten im nächsten Schritt Ersatzmodelle generiert werden, welche im weiteren Prozess eine Anwendung effizienter Optimierungs-Methoden zulassen. Als Trainings- und Test-Grundlage diente dabei die aggregierte Input-Output-Matrix, welche im Format einer CSV-Tabelle zur Verfügung gestellt worden ist. Eine anschließende Sichtung der Metamodell-Güten ergab, dass sich die für die Optimierung relevanten Zielgrößen überwiegend gut modellieren ließen, sodass eine nachträgliche Anpassung des DoE-Workflows nicht notwendig erschien. Dennoch musste eine nachträgliche Änderung der auszuwertenden Größen vorgenommen

werden, da nach Sichtung der Ergebnisse befunden wurde, dass für die Bewertung des Fahrkomforts bei vertikaler Anregung ein anderer charakteristischer Wert geeigneter ist als der, der initial in Abstimmung mit dem Fachbereich festgelegt worden war entsprechend wurde eine aktualisierte Fassung der Input-Output-Matrix im CSV-Format erarbeitet und zur Verfügung gestellt.

Ensemble-Regressionmethoden

Ensemblemethoden sind für ihre Generalisierungsfähigkeit bekannt, insbesondere bei verrauschten Daten. Und sie können bei mittleren bis großen Datensätzen mit geringem Rechenaufwand eine hervorragende Genauigkeit erzielen. Daher haben Ensemblemethoden das Potenzial, das dynamische Verhalten von Fahrzeugen genau zu erfassen und die für die Simulation erforderliche Zeit zu verkürzen. Dies bedeutet, dass ein genaues Ensemblemodell die Anzahl der erforderlichen Simulationsiterationen reduzieren und so die Kosten senken und die Entwurfs- und Entwicklungsphasen beschleunigen kann.

In diesem Arbeitspaket wurde von TWT unter anderem eine Methodik auf Basis der Prinzipien der Ensemble-Regressionmethoden aufgebaut und getestet. Sie stellt einen neuartigen Ansatz namens dynamisch gewichteten Ensembles vor, bei dem die Gewichtung der einzelnen Modelle in Abhängigkeit der Eingangsdaten adaptiert wird. Ziel ist eine Verbesserung der Vorhersagegenauigkeit im Vergleich mit einer starren Gewichtung. Die Prozessschritte sind dabei:

1. Datenclustering: Die Trainingsdaten werden vorverarbeitet (normalisiert) und mithilfe von Clustering-Techniken wie K-Means oder dem Gaußschen Gemischmodell (GMM) in Cluster partitioniert.
2. Upsampling: Jedes Cluster wird mithilfe von exakten Kopien oder verteilungsbasierten Methoden upgesampelt, um Klassenungleichgewichte auszugleichen und die Darstellung von Minderheitsklassen zu verbessern.
3. Modelltraining: Schwache Lernmodelle, einschließlich Entscheidungsbäumen (DTs), Support Vector Regression (SVR) und künstlichen neuronalen Netzen (NNs), werden auf jedem Cluster-Teilsatz trainiert.
4. Ensemblekonstruktion: Die beste Ensemblekonfiguration wird basierend auf dem minimalen mittleren quadratischen Fehler auf einem zurückgehaltenen Testdatensatz bestimmt. Das Ensemble kann aus einer Kombination von schwachen Lernmodellen bestehen, die auf verschiedenen Cluster-Teilmengen trainiert wurden.

5. Dynamische Gewichtung: Ein dynamischer Gewichtungsmechanismus wird implementiert, um den Einfluss einzelner Modelle basierend auf ihrer Leistung auf neuen Dateninstanzen anzupassen. Dadurch tragen Modelle mit höherer Vorhersagegenauigkeit stärker zur endgültigen Ensemblevorhersage bei, wie in der Abbildung 5 unten dargestellt.

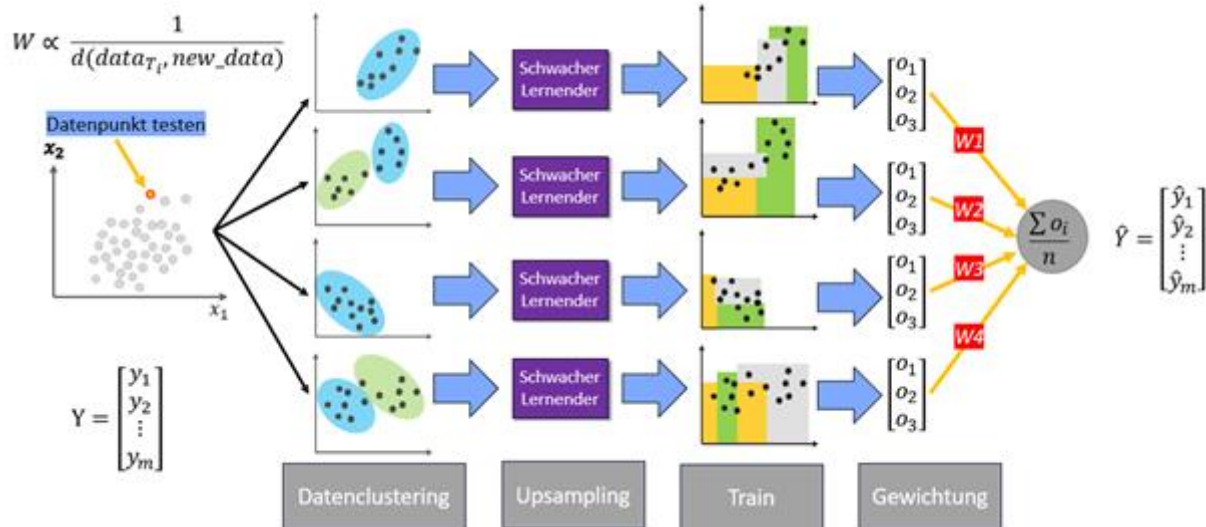


Abbildung 5: Ensemble Methode: Gewichtung.

Die Ergebnisse des dynamischen gewichteten Ensemble-Ansatzes, auf Basis des Datensatzes des Use-Cases *Aufbaubewegung*, wurden mit einem Basis-Neuronalen Netzwerk (NN)-Modell verglichen, das eine flache Architektur mit zwei versteckten Schichten aufweist und den Adam-Optimierer verwendet. Darüber hinaus wurden Vergleiche mit einer anderen Ensemble-Methode angestellt, die mit verschiedenen Clustering-Methoden trainiert wurde. Zur Bewertung wurden Leistungsmetriken wie der mittlere absolute Fehler (MAE), der mittlere quadratische Fehler (MSE) und die Wurzel des mittleren quadratischen Fehlers (RMSE) verwendet. Tabelle 1 zeigt die Metriken der verschiedenen Ensemble-Methoden und der NN-Modelle.

Methode	MAE	MSE	RMSE
NN	0.036810	0.004128	0.059434
Kmeans-DT	0.041082	0.003680	0.058420
GMM-DT	0.040988	0.003710	0.058785
Random-DT	0.040648	0.003617	0.058004
Kmeans-WDT	0.040589	0.003561	0.057362

Tabelle 1: Metrikfehler verschiedener Ensembles und NN

Nach Analyse der Ergebnisse ist klar, dass das NN-Modell den niedrigsten MAE erzielt, was auf seine Fähigkeit hinweist, die zugrunde liegenden Muster in den Daten effektiv zu erfassen. Im Gegensatz dazu wies das Kmeans-WDT-Modell den niedrigsten MSE und RMSE auf, was auf seine überlegene Leistung bei der Minimierung quadratischer Vorhersagefehler hinweist. Diese Diskrepanz in der Leistung unterstreicht die nuancierten Kompromisse zwischen Modellkomplexität, Verallgemeinerungsfähigkeit und Empfindlichkeit gegenüber Rauschen bei Regressionsaufgaben. Eine weitere Untersuchung der spezifischen Merkmale des Datensatzes und der Modellierungsansätze könnte tiefere Einblicke in diese beobachteten Unterschiede liefern. Die Wirksamkeit der Kmeans-WDTs-Methode basiert auf ihrer clusterbasierten Stichprobenahme, dem Ensemble-Lernen, der gewichteten Mittelwertbildung und der Modellinterpretierbarkeit. Die Clusterung ermöglicht eine gezielte Stichprobenahme innerhalb ähnlicher Datencluster, was die Verallgemeinerung des Modells verbessert. Das Ensemble-Lernen kombiniert verschiedene schwache Lernmodelle, um eine breitere Palette von Mustern zu erfassen, während die gewichtete Mittelwertbildung sich an sich ändernde Datenverteilungen anpasst, indem sie Gewichte basierend auf der Nähe zu vorhandenen Clustern zuweist. Darüber hinaus erleichtert die inhärente Interpretierbarkeit von Entscheidungsbäumen das Verständnis des Entscheidungsprozesses des Modells und bietet Transparenz in der Analyse.

Zusammenfassend wurde mit der Ensemble-Regressionmethode eine innovative Methodik vorgestellt, die Clustering-Techniken mit Ensemble-Lernen kombiniert, um Vorhersagemodellierungsaufgaben auf kleinen bis mittleren Datensätzen anzugehen. Unsere Ergebnisse zeigen die Wirksamkeit des vorgeschlagenen Kmeans-WDTs-Ansatzes auf, der eine wettbewerbsfähige Leistung in Bezug auf MSE und RMSE im Vergleich zu traditionellen Methoden wie NN und Ensembles von DTs, SVR und NN demonstriert. Dieser Erfolg basiert auf mehreren Schlüsselementen: Erstens ermöglicht das Clustern der Trainingsdaten das Erfassen komplexer Datenmuster und verbessert die Generalisierung des Modells. Darüber hinaus nutzt das Ensemble-Lernen die Modellvielfalt zur weiteren Leistungssteigerung. Auch stellt unser adaptiver Gewichtungsmechanismus sicher, dass neue Datenpunkte angemessene Gewichte erhalten, die auf Ähnlichkeiten zu vorhandenen Clustern basieren, was eine Anpassung des Modells an sich ändernde Datenverteilungen ermöglicht. Insgesamt unterstreichen unsere Ergebnisse das Potenzial unseres Ansatzes für Vorhersagemodellierungsaufgaben, insbesondere in Szenarien, die das Erfassen komplexer Datenmuster erfordern. Zukünftige Forschung könnte alternative Clustering-Techniken, vielfältige schwache Lernmodelle und die Skalierbarkeit auf

größere Datensätze und komplexe Problemfelder untersuchen. Eine Integration der Methode in den Gesamtworkflow ist noch ausstehend.

AP4.5 Optimierung

Use-Case Regelsysteme: μ -Split

Im Use-Case μ -Split wird eine Methode zur globalen Optimierung der relevanten Parameter innerhalb des Lösungsraumes erarbeitet.

Abbildung 6: Status Quo des μ -Split Use-Cases zeigt den Status Quo in der Applikation. Als Grundlage dienen reale Messdaten, die in Kombination mit einer Open-Loop Simulation es ermöglichen, eine Aussage, über die Identifikationsgüte und den Verzug bis zur Identifikation von μ -Split als objektive Zielgrößen zu treffen.

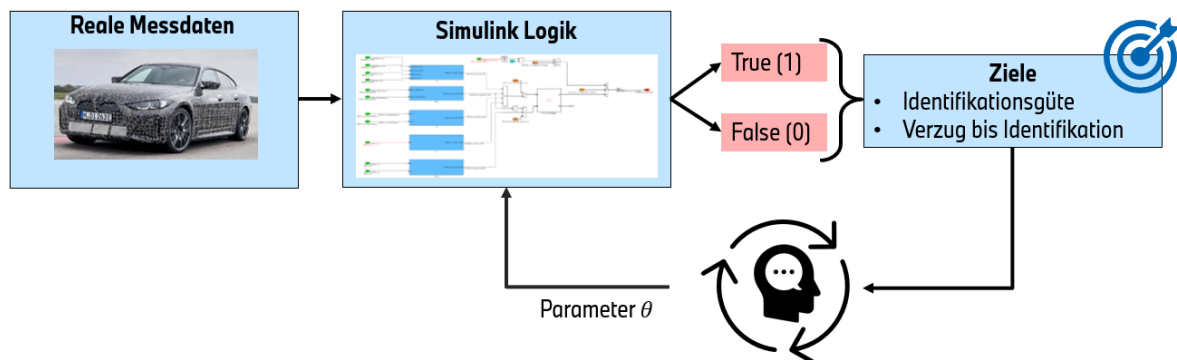


Abbildung 6: Status Quo des μ -Split Use-Cases

Eine prototypische Umsetzung einer Automatisierungslösung basierend auf Matlab/Simulink wurde von TWT umgesetzt. Dazu wurden die Regelsystemmodelle zur μ -Split-Erkennung für Standalone-Simulationen (außerhalb eines Regelsystemverbunds) adaptiert. Eine automatisierte Grundbedatung des μ -Split Modells und die Herstellung eines simulationsfähigen Zustands wurden erzeugt. Des Weiteren wurde die Parametrierbarkeit des Modells durch die Verwendung von erstellten Matlab-Templates ermöglicht. Templates wurden ebenfalls dafür verwendet, verschiedene Messfahrten und Parameterbereiche bei der Durchführung von Simulationen abbilden zu können. Abschließend hat die TWT einen Entwurf einer Methodik entwickelt, um die relevanten Zielgrößen der Detektionsgeschwindigkeit und der Detektionsgüte der μ -Split-Erkennung aus den Simulationsergebnissen zu berechnen und dem Optimierungsprozess zuzuführen.

2. Wichtigste Positionen des zahlenmäßigen Nachweises

Die wichtigsten Positionen des zahlenmäßigen Nachweises laut Nachkalkulation werden in Tabelle 2 aufgeführt. Des Weiteren wird ein Vergleich der gesamten Selbstkosten des Vorhabens für die TWT in Vor- sowie Nachkalkulation in Tabelle 3 vorgestellt.

Position	Gesamtnachkalkulation (in €)
0837 Personalkosten	408.921,74
0838 Reisekosten	2.194,23
0847 Abschreibungen auf vorhabenspezifische Anlagen	0,00
0850 sonstige unmittelbare Vorhabenkosten	9.534,44
0881 Selbstkosten	420.650,41
Eigenanteil der TWT GmbH (von 0881)	178.712,91
Bundesanteil (von 0881)	241.937,50

Tabelle 2: Wichtigste Positionen des zahlenmäßigen Nachweises

Position 0881 gesamte Selbstkosten des Vorhabens	
Gesamtvorkalkulation (€)	403.229,00
Gesamtnachkalkulation (€)	420.650,41

Tabelle 3: Vergleich der gesamten Selbstkosten des Vorhabens

3. Notwendigkeit und Angemessenheit der geleisteten Arbeit

Das Projekt newAIDE hat gezeigt, dass es möglich ist, Methoden des maschinellen Lernens in mehreren Bereichen einer Fahrzeugentwicklung einzusetzen. Diese Methoden können in den nächsten Schritten zur Durchführung von Optimierungen verwendet werden und den Zeitaufwand deutlich reduzieren. Durch eine Mehrzieloptimierung können die dynamischen Eigenschaften des Fahrzeugs deutlich verbessert werden. Diese Kombination von ML mit realen Simulationen konnte nur in einem gemeinsamen Projekt demonstriert werden, da viele verschiedene Systeme verbunden waren, die kein Partner unabhängig entwickeln konnte, da für jedes einzelne Modul Spezialisten und Experten benötigt wurden.

Für die Arbeiten und Ergebnisse der TWT GmbH waren insbesondere die Zusammenarbeit mit den Projekt-Partnern im AP4 von entscheidender Bedeutung. Das hohe Risiko und der anfängliche Aufwand, die mit diesen innovativen Themen und Entwicklungen verbunden sind, wären bei TWT ohne eine finanzielle Unterstützung und ohne die fachliche Expertise des Partners nicht allein möglich.

4. Wissenschaftliche, technische und wirtschaftliche Ergebnisverwertung

Industrielle Anwendung

Als Dienstleister mit Kunden in der Automobilbranche, der Luft- und Raumfahrtbranche und im Bereich der Medizintechnik betreut die TWT GmbH die gesamte Wertschöpfungskette, vom OEM über Tier-1- bis zu Tier-2-Zulieferern. In den Bereichen Systemauslegung und -optimierung gibt es in unserem Kundenumfeld einen wachsenden Bedarf an Lösungen aus den Feldern datenbasierte Prädiktion, große Datenmengen sowie gesamthafte Optimierungslösungen.

Im Rahmen von newAIDE konnte mit dem systematischen Aufbau von Simulationsdaten, der Entwicklung von komplexer Prädiktionsalgorithmik auf Basis verschiedenster Methoden sowie der Einbindung in das holistische Optimierungssystem, insbesondere über durchdachte Schnittstellen und Standards in den Softwarelösungen die Basis für Ansätze, Methoden und Kompetenzen geschaffen werden, welche TWT langfristig in innovative Dienstleistungen und Kundenprojekte zu überführen sucht. Durch den sehr hohen Mehrwert der erzeugten Methoden u.a. für den Automotive Entwicklungsprozess sehen wir dafür sehr gute Chancen.

Die TWT GmbH hat ihre Kompetenzen im Bereich der Workflowoptimierung, der künstlichen Intelligenz sowie der Echtzeitfähigkeit von kombinierten Modellen stark vertieft und dabei Methoden entwickelt, die auch in anderen Bereichen angewandt werden können. Das Forschungsprojekt newAIDE wurde bereits in circa 50 Kundenterminen als wertvolle Referenz vorgestellt und hat damit zum Gewinn von mehreren laufenden Projekten beigetragen.

Durch die Übertragung der gewonnenen methodischen Einsichten konnten bereits Projekte für unsere Kunden bereichert werden. Dies zeigte sich sowohl durch gesteigerte Qualität und bessere Lösungen als auch durch schnellere Ergebnisfindung (finanzieller Return on Invest).

Außerdem konnten die gewonnenen Methodenkompetenzen sowie Erfahrungen aus newAIDE in mehreren Akquisevorgängen platziert werden, z.B. in einem Projekt zur Optimierung von Bauteilen im Automotive Kontext. Hier ergibt sich eine Chance der Verwertung und Verbreiterung der erlangten Kompetenzen.

Zudem konnte im Rahmen von newAIDE das Netzwerk der TWT in der Automobilbranche erweitert werden, indem neue Partnerschaften geknüpft und gefestigt wurden. Aktuell laufen Gespräche über potenzielle neue Industrieaufträge im Automotive Umfeld.

Aufbauende Forschungsaktivitäten

Als Innovationsdienstleister verfolgt TWT das Ziel zukunftsweisende Technologien voranzutreiben und innerhalb von Kundenprojekten einzusetzen. Um mit dem hohen Innovationstempo mithalten zu können, benötigt die TWT ein Netzwerk von qualifizierten und engen Forschungspartnern. Der innovative Charakter von newAIDE im hochaktuellen Feld der datenbasierten Prädiktion und holistischen Optimierung, die erzielten Projektergebnisse sowie die Vernetzung im newAIDE Konsortium erschließen TWT zukünftige Forschungsaktivitäten und Folgeprojekte:

- Zusammen mit den meisten newAIDE Projektpartnern wird ein weiteres Forschungsvorhaben im Umfeld neuartiger KI-Methoden angestrebt. Einzelne Themen aus dem Vorhaben werden voraussichtlich in anderer Form in Zukunft weiterverfolgt.
- Die TWT GmbH verfolgt KI-Ersatzmodelle als Themenkomplex weiterhin als einen der Forschungsfokuspunkte und wird beispielsweise im Rahmen der anstehenden ITEA PO Days weitere Forschungsideen in diesem Feld verfolgen.
- Durch das newAIDE-Projekt wurde zudem die Vernetzung zum Projektpartner TU München weiter verfestigt, Gespräche über weitere gemeinsame Vorhaben haben bereits stattgefunden.

5. Während der Durchführung des Vorhabens bekannt gewordener Fortschritt auf dem Gebiet bei anderen Stellen

Während der Projektdurchführung wurde der Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen verfolgt und bewertet. Hierbei sind von dritter Seite

keine Ergebnisse bekannt geworden, die mit den Projektansätzen und -ergebnissen direkt vergleichbar sind oder die für die Durchführung des Vorhabens unmittelbar relevant sind.

6. Erfolgte oder geplante Veröffentlichungen der Ergebnisse

Im November 2024 sollen die Ergebnisse des Projekts auf der simVEC vorgestellt werden. TWT spielt sowohl bei der Vorbereitung als auch bei der Durchführung eine Schlüsselrolle. Ein Mitarbeiter wird auf der Konferenz präsentieren und das Projekt und insbesondere die Beiträge der TWT GmbH erläutern.

III ANHANG

Abbildungsverzeichnis

Abbildung 1: Übersicht der newAIDE-Arbeitspakete und Bearbeitungsschwerpunkte der jeweiligen Partner.	6
Abbildung 2: Workflow zur Generierung der Simulationsergebnisse der DOE.	9
Abbildung 3: Kommunikationsstruktur im Online-Workflow.	11
Abbildung 4: Kommunikationsstruktur im Offline-Workflow.	12
Abbildung 5: Ensemble Methode: Gewichtung.	15
Abbildung 6: Status Quo des μ -Split Use-Cases.	17

Tabellenverzeichnis

Tabelle 1: Metrikfehler verschiedener Ensembles und NN	15
Tabelle 2: Wichtigste Positionen des zahlenmäßigen Nachweises.	18
Tabelle 3: Vergleich der gesamten Selbstkosten des Vorhabens	18

7. Literaturverzeichnis

- [1] Th. Bäck, C. Fousette, P. Krause: Automatic Metamodeling of CAE Simulation Models. *ATZ Worldwide* 117(5), 36-41, 2015.
- [2] F. Hutter, L. Kotthoff, J. Vanschoren: *Automated Machine Learning*. Springer, 2019.
- [3] Kotthoff L., Thornton C., Hoos H.H., Hutter F., Leyton-Brown K. (2019) Auto-WEKA: Automatic Model Selection and Hyperparameter Optimization in WEKA. In: Hutter F., Kotthoff L., Vanschoren J. (eds) *Automated Machine Learning*. The Springer Series on Challenges in Machine Learning. Springer, Cham. https://doi.org/10.1007/978-3-030-05318-5_4
- [4] D. Vermetten, H. Wang, Th. Bäck, C. Doerr: Towards Dynamic Algorithm Selection for Numerical Black-Box Optimization: Investigating BBOB as a Use Case. *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO 2020)*, Cancun, Mexico, July 13-17, 2020, 654-662. ACM New York, NY, 2020.
- [5] D. Vermetten, H. Wang, C. Doerr, Th. Bäck: Integrated vs. Sequential Approaches for Selecting and Tuning CMA-ES Variants. *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO 2020)*, Cancun, Mexico, July 13-17, 2020. ACM New York, NY, 2020.
- [6] P. Koch, S. Bagheri, W. Konen, C. Fousette, P. Krause, Th. Bäck: A New Repair Method for Constrained Optimization. In: *GECCO '15: Proceedings of the 17th Annual Conference on Genetic and Evolutionary Computation*, Madrid, Spain, July 11-15, 2015, 273-280. ACM Press, New York, NY, 2015.
- [7] S. Bagheri, W. Konen, M. Emmerich, Th. Bäck: Self-adjusting parameter control for surrogate-assisted constrained optimization under limited budgets. *Applied Soft Computing* 61, 377-393, 2017.