Individueller Schlussbericht

Förderkennzeichen: 19I21032D

ZE: Umicore AG & Co. KG
NorCom Information Technology GmbH & Co. KGaA
AVL Deutschland GmbH
AVL Schrick GmbH
TU Darmstadt – Institut für Verbrennungskraftmaschinen und Fahrzeugantriebe (VKM)

Vorhabenbezeichnung:
Verbundprojekt KIARA - Künstliche Intelligenz zur Alterungsidentifikation realer Anwendungen von Abgaskatalysatoren

Laufzeit des Vorhabens: 01.07.2021 – 31.12.2024
Berichtszeitraum: 01.07.2021 – 31.12.2024

Autoren: Christian Tomanik, Alexander Stalp, Dhwani Vakil, **Lukas Schmidt**,
Julian Mauritsch, **Paolo Pagani, Ezra Tampubolon**
(Die Verantwortung für den Bericht liegt bei den Autoren)

Finanziert von der Europäischen Union
NextGenerationEU

Gefördert durch:
Bundesministerium für Wirtschaft und Klimaschutz
aufgrund eines Beschlusses des Deutschen Bundestages

Inhaltsverzeichnis

I. Einleitung und kurze Darstellung 3
I.1 Aufgabenstellung 4
I.1.1 Gesamtziel des Vorhabens 4
I.1.2 Wissenschaftliche und technische Arbeitsziele des Vorhabens 4
I.2 Voraussetzungen, unter denen das Vorhaben durchgeführt wurde 4
I.3 Planung und Ablauf des Vorhabens 5
I.4 Wissenschaftlicher und technischer Stand an den angeknüpft wurde 6
I.5 Zusammenarbeit mit anderen Stellen 8
II. Eingehende Darstellung 8
II.1 Eingehende Darstellung der Verwendung der Zuwendung und des erzielten Ergebnisses im Einzelnen mit Gegenüberstellung der vorgegebenen Ziele 8
II.1.1 Messkonfiguration, Fahrzeugflotte und Datenaufbereitung 9
II.1.2 Abbildung realer Fahrzeugbedingungen am Engine-in-the-Loop Prüfstand 11
II.1.3 Indikatoren und Trainingsdaten für die KI-Entwicklung aus realen und simulierten Daten 12
II.1.4 KI-Framework 17
II.1.5 Anwendung und Bewertung der KI zur Alterungsdetektion 19
II.1.6 KI-Plattform 24
II.1.7 Zusammenfassung - Technisch- wissenschaftliche Ergebnisse 32
II.2 Eingehende Darstellung der wichtigsten Positionen des zahlenmäßigen Nachweises 33
II.3 Eingehende Darstellung der Notwendigkeit und Angemessenheit der geleisteten Arbeit 33
II.4 Eingehende Darstellung des voraussichtlichen Nutzens, insbesondere der Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplan 33
II.5 Eingehende Darstellung des während der Durchführung des Vorhabens dem ZE bekannt gewordenen Fortschritts auf dem Gebiet des Vorhabens bei anderen Stellen 34
II.6 Eingehende Darstellung der erfolgten oder geplanten Veröffentlichungen des Ergebnisses nach Nr. 11 34
III. Literaturverzeichnis 34

I. Einleitung und kurze Darstellung

Der steigende Druck auf die Politik und die Gesellschaft eine nachhaltige Mobilität zu gestalten lässt sich in der nächsten Dekade und auch später nur zu einem begrenzten Anteil durch die Elektromobilität realisieren. In einer vollständigen CO_2-Well-to-Wheel-Betrachtung zeigen rein elektrisch angetriebene Fahrzeuge Nachteile im Vergleich zu konventionellen Antriebsformen, die auf der motorischen Verbrennung basieren. Diese Nachteile liegen bei der Energiegewinnung und Verteilung, die in der Betrachtung aus Sicht einer Klimawirksamkeit unbedingt berücksichtigt werden müssen.

Der Verbrennungsmotor hat aber unbestrittene Vorteile. Er ist weltweit verfügbar, hat einen hohen Reifegrad, die Versorgung mit Treibstoff ist global etabliert und nicht zuletzt nutzt er Treibstoff mit hoher Energie bei geringem Gewicht und Volumen, was für mobile Anwendungen ein großer Vorteil ist. Somit eignet er sich grundsätzlich dazu als längerfristige Brückentechnologie genutzt zu werden bis evtl. andere Antriebstechniken ausreichend verfügbar sind.

Antriebssysteme zukünftiger Fahrzeuge in den Bereichen PKW und Nutzfahrzeug werden deshalb weiterhin einen hohen Grad an verbrennungsmotorischen Anteilen aufweisen. Dabei bieten heutige Fahrzeuge mit modernen Abgasnachbehandlungssystemen (AGN) bereits ein sehr geringes Emissionsniveau. Mit zunehmender Laufleistung von Fahrzeugen nimmt jedoch die Schadstoffumsetzung in den Katalysatoren der Abgasnachbehandlungssysteme kontinuierlich ab. Dieser als „Alterung“ bekannte Effekt tritt durch hohe thermische, chemische und mechanische Belastungen auf. Eine Betrachtung dieses Effektes ist bereits teilweise in den Fahrzeugfunktionen implementiert, welche jedoch Schwächen in Bezug auf die Varianz der Nutzungsprofile haben. Unterschiedliche Anwendungsfälle machen eine gezielte Auslegung im Kontext der Fahrzeugnutzung über den Lebenszyklus unmöglich. Hier zeigt sich der Bedarf einer neuartigen Lösung. Bereits jetzt diskutierte gesetzliche Forderungen nach der sogenannten „In-Service-Conformity“ (ISC) stellt die Entwicklung nachhaltiger Abgassysteme vor neue Herausforderungen. Katalysator- und Filtersysteme müssen nach langen Nutzungsdauern, vielen Fahrzeugkilometern und in erster Linie sehr schlecht vorhersehbaren Einsatzgebieten in ihrer Leistung in Bezug auf den Schadstoffumsatz stabil und nachhaltig sein. Eine Herausforderung stellt dabei die langsam über die Lebensdauer nachlassende Konvertierungsleistung dar, die deutlich komplexer in ihrer Detektion ist, als ein plötzlich einsetzender Defekt. Auch Betriebsarten und Regelstrategien müssen auf die Alterung der Komponenten angepasst werden, die es zu detektieren gilt.

Um Alterungseffekte eines auf der Straße fahrenden Fahrzeugs zu identifizieren, ist es notwendig, die bereits in der OBD (On-Bord-Diagnose) vorhandenen Datenmengen über lange Zeiträume mittels einer robusten künstlichen Intelligenz (KI) auszuwerten, die Alterung zu quantifizieren und mit bekannten Alterungsmechanismen, sowie Motor- und Fahrzeugtests abzugleichen.

Im Projekt KIARA sollten Alterungsmuster von Abgasnachbehandlungssystemen im Realbetrieb über den Lebenszyklus der Fahrzeuge mit Hilfe von künstlicher Intelligenz – „KI-Methoden“ – detektiert, analysiert und Lösungen für die Reduzierung der Alterung erarbeitet werden. Bei Diesel-PKWs verschlechtert sich beispielsweise an untersuchten Abgasanlagen die Emissionen innerhalb von 120t km und führen zu einer Verdoppelung der Stickoxid- (NO_x) und Kohlenstoffmonoxid-Emissionen (CO), sowie einem Kohlenwasserstoff-Emissionsanstieg (HC) um ein Drittel. Die zu entwickelnden KI-Methoden sollen die Spitzenbelastungen des Abgasnachbehandlungssystems reduzieren und die Alterungseffekte abschwächen, sodass der alterungsbedingte Anstieg der Emissionen auf ca. 50 % begrenzt werden kann unter Berücksichtigung der kommenden Abgasgesetzgebungen bei einer höheren Laufleistung und zusätzlichen Abgaskomponenten.

I.1 Aufgabenstellung

Ziel des Projekts war die Entwicklung einer KI-basierten Methode zur Analyse und Reduzierung von Alterungsphänomenen bei Abgasnachbehandlungssystemen. Im Fokus stand die Erkennung und Prädiktion von Alterungsmustern einzelner Komponenten während des Fahrbetriebs, um durch gezielte Anpassungen in der Betriebsstrategie der Motoren die Alterung der Abgasnachbehandlungssysteme zu minimieren. Dabei lag ein besonderes Augenmerk darauf, die Emissionen auch im gealterten Zustand niedrig zu halten und einen hohen katalytischen Wirkungsgrad zu gewährleisten.

Im Gegensatz zu bisherigen Ansätzen, die statische Eingriffe in die Motorbetriebsstrategie ohne Rücksicht auf reale Fahr- und Betriebszustände vorsehen, zielte die entwickelte KI-Methodik darauf ab, adaptive Strategien zu ermöglichen, die direkt auf Alterungsmechanismen und deren Auswirkungen auf die Emissionierung reagieren. Angesichts verschärfter gesetzlicher Vorgaben und der gesellschaftlichen Forderung nach nachhaltigen Mobilitätslösungen war es essenziell, innovative Ansätze zu entwickeln, um eine möglichst geringe Emissionierung und eine verlängerte Lebensdauer der Systeme sicherzustellen.

I.1.1 Gesamtziel des Vorhabens

Zur Einhaltung zukünftiger Abgasnormen (Euro 7 und danach) mit verschärften Randbedingungen, niedrigeren Emissionsgrenzwerten und einer Betrachtung der Emissionierung über die verlängerte Laufleistung von Fahrzeugen, verfolgte das Vorhaben das Ziel, eine KI-Methodik zur Analyse, Bewertung und Optimierung von Abgasnachbehandlungssystemen und deren Komponenten zu entwickeln.

I.1.2 Wissenschaftliche und technische Arbeitsziele des Vorhabens

Im Rahmen des Projekts übernahm NorCom die Verantwortung für zentrale Beiträge zur Entwicklung und Anwendung von Künstlicher Intelligenz (KI) in der Analyse und Optimierung von Abgasnachbehandlungssystemen. Der Fokus lag dabei auf der Weiterentwicklung der KI-Plattform DaSense, die eine skalierbare und flexible Datenverarbeitung sowie eine effiziente Integration von Mess- und Sensordaten ermöglicht.

Ein zentrales Ziel war die Generierung hochwertiger Trainingsdaten, sowohl aus Prüfstandsmessungen als auch aus Felddaten, um eine belastbare Grundlage für die Entwicklung der KI-Modelle zu schaffen. NorCom war aktiv an der methodischen Konzeption des KI-Ansatzes beteiligt, insbesondere bei der Definition der Datenstruktur, der Auswahl geeigneter Merkmale und der Modellarchitektur.

Auf dieser Basis wurde ein KI-gestütztes Prädiktionsmodell zur Vorhersage der Katalysatorsalterung entwickelt. Dieses Modell erlaubt nicht nur die Einschätzung zukünftiger Zustände, sondern liefert durch die Analyse der Modellparameter auch Einblicke in die zugrunde liegenden Alterungsmechanismen, was zu einem tieferen Verständnis des Systemverhaltens beiträgt.

Die Praxistauglichkeit der entwickelten Methodik wurde durch eine Integration in eine virtuelle Fahrzeugumgebung am Engine-in-the-Loop (EiL)-Prüfstand demonstriert. Damit konnte erfolgreich gezeigt werden, dass sich die Ansätze auch unter realitätsnahen Bedingungen bewähren und konkrete Anwendungspotenziale in der Fahrzeugentwicklung bieten.

Mit der Kombination aus Plattformentwicklung, Datenmanagement, Modellierung und Systemintegration leistete NorCom einen wesentlichen Beitrag zur Nutzung von KI im Bereich der Abgasnachbehandlung und legte zugleich den Grundstein für eine übertragbare, industrieorientierte Lösung.

I.2 Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

- **Organisatorische Voraussetzungen:** Seitens NorCom wurde das Projekt durch ein interdisziplinäres Team aus Data Scientists, Data Engineers und Softwareentwicklern umgesetzt, von denen einige über Erfahrung im Automotive-Sektor verfügen. Die Projektorganisation lag in der Verantwortung eines Projektleiters. Die Aufgabenplanung und -umsetzung erfolgte in Abstimmung mit dem Projektpartner unter Anwendung agiler Methoden. Trotz pandemiebedingter Einschränkungen und Fachkräftemangels, die zu Verzögerungen im Projektverlauf führten, konnte das Vorhaben erfolgreich abgeschlossen werden.
- **Technische Voraussetzungen:** Bei der Durchführung des Projekts kam NorComs Produkt *DaSense* zum Einsatz. Im Verlauf des Projekts wurde das Produkt gezielt weiterentwickelt, um den spezifischen Anforderungen des Vorhabens gerecht zu werden. Darüber hinaus flossen die Fachkenntnisse des Consultants in den Bereichen Data Science, Data Engineering sowie Datenarchitektur maßgeblich in das Projekt ein.
- **Rechtliche/regulatorische Rahmenbedingungen:** Es sind keine rechtlichen oder regulatorischen Rahmenbedingungen bekannt, die Einschränkungen für das Projekt darstellen.
- **Externe Faktoren:** Pandemiebedingte Einschränkungen sowie Fachkräftemangel führten zu Verzögerungen im Projektverlauf.

I.3 Planung und Ablauf des Vorhabens

Die Untersuchungen wurden erfolgreich im Rahmen der dreieinhalbjährigen Projektlaufzeit durchgeführt. Das vorliegende Projekt wurde im Rahmen der folgenden sieben Arbeitspakete (AP) bearbeitet:

AP1 Messkonfiguration, Fahrzeugflotte und Datenaufbereitung

AP2 Analyse der katalytischen Alterung im Feld und Versuch sowie KI auf Komponenten-Ebene

AP4 Abbildung realer Fahrzeugbedingungen am Engine-in-the-Loop Prüfstand und KI-Integration

AP5 KI-Framework

AP6 Anwendung und Bewertung der KI zur Alterungsdetektion

AP7 KI-Plattform

Die Arbeitspakete sind den einzelnen Projektpartnern ihren Haupt-Innovationsbeiträgen nach zugeordnet. Eingerahmt werden die Arbeitspakete durch AP0 und AP7, die eine besondere Stellung einnehmen. AP0 beschreibt die Projektkoordination. In AP7 wird die Plattform und Infrastruktur aufgebaut, welche wichtig für den Datenaustausch zwischen den Partnern darstellt und die Bereitstellung der Ergebnisse für zukünftige Forschung und Nutzung sichert. Die zur Verfügung gestellten Daten entstammen aus verschiedenen Messungen. Eine Übersicht und Abgrenzung der Arbeitspakete sind in Abbildung 1 zusammengefasst.

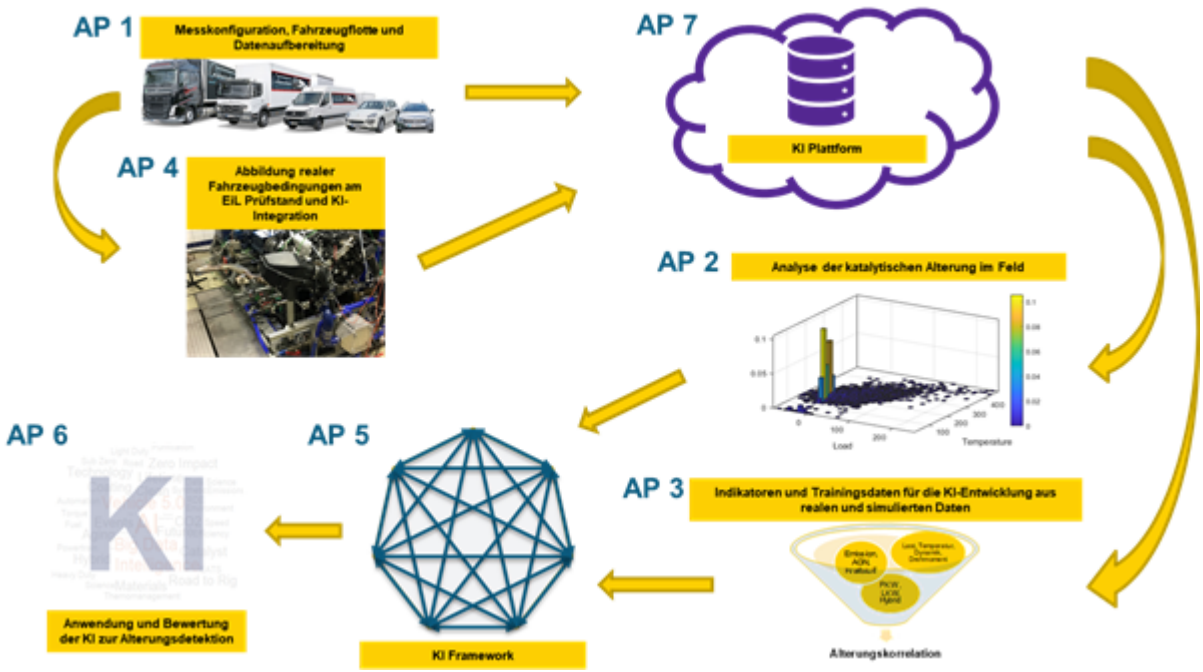

Abbildung 1: Verknüpfung der einzelnen Arbeitspakete

NorCom war dabei insbesondere in den folgenden Arbeitspaketen maßgeblich eingebunden:

- AP4 (Abbildung realer Fahrzeugbedingungen am Engine-in-the-Loop Prüfstand und KI-Integration): NorCom unterstützte die Integration der entwickelten KI-Methodik in eine virtuelle Fahrzeugumgebung am Engine-in-the-Loop-Prüfstand, um die Anwendbarkeit und Wirksamkeit der Ansätze unter praxisnahen Bedingungen zu demonstrieren.
- AP5 (KI-Framework): Hier wirkte NorCom bei der Definition der methodischen Grundlagen für die Entwicklung des KI-Modells zur Katalysatorsalterung mit. Dies umfasste sowohl die Strukturierung der Trainingsdaten als auch die Auswahl geeigneter Modellierungsansätze.
- AP6 (Anwendung und Bewertung der KI zur Alterungsdetektion): Aufbauend auf dem entwickelten Modell war NorCom verantwortlich für die Umsetzung eines datengetriebenen Prädiktionsverfahrens zur Identifikation und Bewertung von Alterungsmechanismen.
- AP7 (KI-Plattform): In diesem Arbeitspaket lag der Schwerpunkt auf der Entwicklung und Erweiterung der DaSense Plattform. NorCom stellte die technische Infrastruktur bereit, die eine strukturierte Datenaufnahme, Analyse und Ergebnisbereitstellung ermöglichte. Damit wurde ein zentraler Baustein für die Zusammenarbeit der Partner sowie für die künftige Nutzung der entwickelten Methoden geschaffen.

Die Beiträge von NorCom waren somit ein entscheidender Bestandteil zur Umsetzung der wissenschaftlich-technischen Ziele des Gesamtprojekts. Die entwickelten Komponenten und Methoden flossen direkt in eine übergreifende Plattformlösung ein, die als Basis für zukünftige Forschung und industrielle Anwendungen dient.

I.4 Wissenschaftlicher und technischer Stand an den angeknüpft wurde

Abgasnachbehandlungssysteme moderner Fahrzeuge sind je nach Fahrzeugtyp und Anwendungsfalls spezifisch aufgebaut. Sie setzen sich je nach Motorkonzept aus einem (einfacher Ottomotor/ Otto-Hybrid) oder mehrerer (Nutzfahrzeugdieselmotor und moderne Diesel-PKW) hintereinander angeordneten Katalysatoren zusammen, die bedarfsgerecht dimensioniert werden. Somit ergibt sich bei einem breiten Fahrzeugspektrum eine sehr große Variantenvielfalt an Abgasnachbehandlungssystemen (Abbildung 2).

Die zunehmende Systemvielfalt und Komplexität der Abgasnachbehandlungssysteme stellen steigende Anforderungen an die Kontroll- und Überwachungssysteme des Fahrzeugs dar.

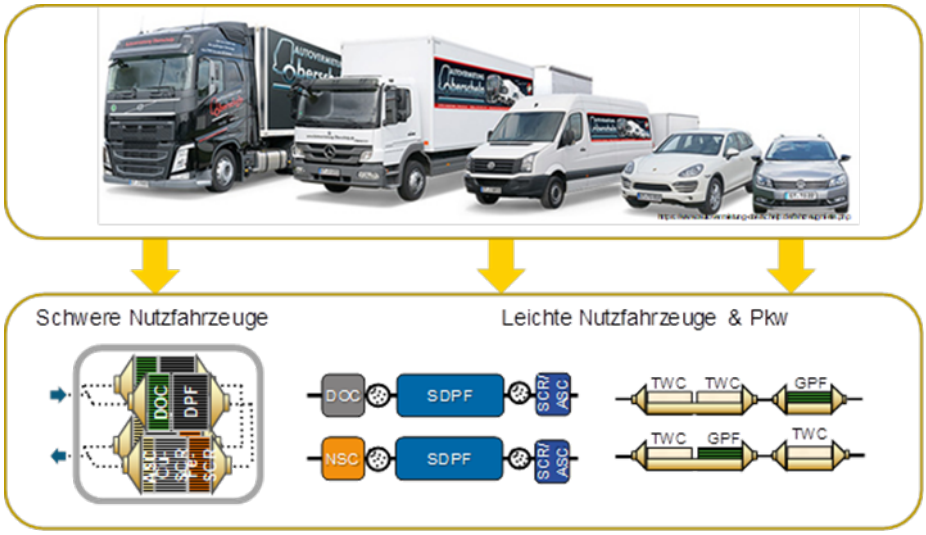

Abbildung 2: Systemvielfalt der Abgasnachbehandlungssysteme

Im Rahmen aktueller Antriebsstränge finden Abgasnachbehandlungssysteme Anwendung, für deren Betrieb das Motorsteuergerät mit zusätzlichen Steuergeräten eine möglichst optimale Betriebsstrategie der Abgasnachbehandlung gewährleisten soll. Adaptionen hinsichtlich Alterung der Katalysator- und Filtersysteme sind heute teilweise in den Betriebsstrategien insofern integriert, dass z.B. auf Umgebungsbedingungen, wie Temperaturen und Kraftstoffqualitäten eingegangen wird. So werden Regenerationsintervalle (Partikelfilter) und Entschwefelungsprozesse (NOx-Speicherkatalysator) bereits flexibel gesteuert. Auch andere erforderliche AGN- und OBD-Strategien werden entsprechend einer Priorisierung gesteuert. Diese Verfahren beziehen sich auf kurz- und mittelfristige Alterungsprozesse, sowie teils reversible Vergiftungseffekte, die gut messtechnisch und modellbasiert erfassbar sind. Der Einsatz künstlicher Intelligenz zur fahrzeugspezifischen Erkennung von Alterungszuständen und eine langfristige Anpassung der ECU Betriebsstrategien liegen zum aktuellen Zeitpunkt nicht vor.

Im Kontext wissenschaftlicher Untersuchungen und Veröffentlichungen wurde bereits 2008 die Anwendung von neuronalen Netzen und anderen maschinellen Lernverfahren zur Beschreibung der chemischen Prozesse in Katalysatoren untersucht (1) (2) (3). Die Anwendung der künstlichen Intelligenz adressiert hier die hohe Komplexität von chemischen Reaktionen, die durch heute verwendete physikalische Modellansätze nicht in vollständig beschreiben können. Die Verwendung von künstlicher Intelligenz im Fahrzeug ist im Bereich der Antriebstechnik am weitesten verbreitet. Prädiktive Betriebsstrategien finden beispielsweise im Rahmen von Hybridfunktionsentwicklungen bei Fahrzeugen Anwendung (4).

Es liegen zum aktuellen Zeitpunkt keine bekannten Arbeiten vor, die die antriebsstrangunabhängige Identifikation von Alterungsmechanismen und eine adaptive ECU Anpassung mit einem Ansatz mittels künstlicher Intelligenz verfolgen.

Die Norcom bearbeitet im Rahmen von KI / BigDataAnalytics-Consulting typischerweise Kunden-Projekte, deren Ziel darin besteht, Mehrwerte aus sehr großen, heterogenen und unstrukturierten Datenmengen zu extrahieren. Im Rahmen dessen haben wir mit den namhaften Automobil-OEMs und bekannten Industrie-OEMs (z.B. Hersteller von motorbetriebenen Handgeräten, siehe Entwicklungspartner-Referenz Homepage) DataScience Projekte durchgeführt.

Thematisch ähnlich gelagerte Zielstellungen in solchen DataScience Projekten waren beispielsweise:

- Anomalie-Detektion aus Messdaten, wobei auf Basis eines Gesamtdatensatzes (Fahrzeug-messdaten einer größeren Fahrzeug-Dauerlaufflotte) eine Root-Cause Analyse zu auftretenden Sensordefekten in Abgasanlagen durchzuführen war. Im Rahmen von Abgasnachbehandlungs-Parametrierung können die gewählten Strategien zur AGN-Regeneration Einfluss auf im Abgasstrang befindliche Sensorik haben. Diese werden aber nur bei bestimmten Lastkollektiven oder Fahrzyklen bei einzelnen Fahrzeugen sichtbar und führen zum Fehlerfall. Um in den großen Datenmengen wichtige von unwichtigen Einflüssen zu trennen, wurden use-case-agnostische statistische Berechnungen auf allen vorliegenden Mess-daten durchgeführt und nach ihrer Relevanz geordnet. Nach Ausschluss von pseudo-Korrelationen wurden dann Testhypothesen formuliert und anhand der Daten überprüft. Als Ergebnis konnte ein Zusammenhang zwischen bei einigen Fahrzeugen auftretenden Lernwert-Adaptionen des Motorsteuergeräts und Auftreten von Sensordefekten festgestellt werden.
- Erkennung von Umgebungsdaten und -beschaffenheit auf Basis von Mess- und Kameradaten für den Anwendungsfall eines teilautonomen Fahrzeugs. In einem ersten Schritt sollten für ein mobiles Gartengerät verschiedene Klassen von Untergrund erkannt werden (z.B. Gras, Beton, usw.). Der Prototyp hat zehn verschiedene Sensoren, die Bild- und Zeitreihen-Daten sammeln, und deren Qualität verglichen werden sollte. Die Größe und Ressourcenverbrauch der Modelle zur Prozessierung der Daten sollen schließlich zum Embedded-System des Prototyps angepasst werden. Als Voraussetzung wurde eine On-Prem Umgebung für das Laden, Extraktion und BigData-Datenanalyse bereitgestellt. Auf dieser Umgebung wurde eine Auswahl der aktuellsten Deep-Learning Modelle für die Erkennung mehrerer Untergrund-Klassen aus Bild- und Zeitreihen-Daten mit Transfer-Learning Methoden auf Basis TensorFlow neu trainiert. Danach wurden die besten Modelle für die Anwendung auf Embedded Devices optimiert: Es konnte dabei trotz der begrenzten Ressourcen eine typische Genauigkeit >95% mit Geschwindigkeit > 10 fps und Modellgröße < 10 MB erreicht werden, was für den Prototypstatus die Übergabe in produktive Weiterentwicklung bedeutete.

I.5 Zusammenarbeit mit anderen Stellen

Es wurde im Konsortium mit IVD Deutschland GmbH (D-64285 Darmstadt) zusammengearbeitet. IVD Deutschland GmbH war als Unterauftragnehmer von Umicore und der TU Darmstadt beteiligt. Neben der Bearbeitung und Verantwortung der jeweiligen Arbeitspakete gab es Schnittstellen über die gesamte Projektlaufzeit.

II. Eingehende Darstellung

II.1 Eingehende Darstellung der Verwendung der Zuwendung und des erzielten Ergebnisses im Einzelnen mit Gegenüberstellung der vorgegebenen Ziele

Die Untersuchungen gliederten sich entsprechend der Zuständigkeiten der Projektpartner in verschiedene Arbeitspakete, die im Rahmen eines eng abgestimmten Arbeitsplans zahlreiche Schnittstellen und Zusammenarbeit zwischen den Partnern aufwiesen. Auch wenn sich dieser Bericht auf die Arbeiten von NorCom konzentriert, wurden die Arbeiten der Projektpartner – als solche kenntlich – trotzdem genannt, um die Arbeiten in ihrem Kontext verständlich zu machen.

Das Projektergebnis lässt sich in drei zentrale Bereiche unterteilen: die entwickelte Methodik, die zugrundeliegenden Datensätze sowie das finale Modellergebnis.

Im Zusammenspiel der Partner konnte eine Methodik zur unabhängigen Analyse der Katalysatorsalterung erarbeitet werden. Dabei flossen die industriellen Erfahrungswerte von Umicore und AVL sowie die wissenschaftlichen Erkenntnisse des VKM in die Entwicklung der Prüfstands- und Fahrzeugversuche ein.

NorCom brachte sein Spezialwissen im Bereich Datenanalyse und -aufbereitung maßgeblich ein: Die firmeneigene Expertise wurde genutzt, um die bereitgestellten Daten umfassend aufzubereiten und für die KI-Modellentwicklung nutzbar zu machen. In enger Abstimmung mit allen Partnern erfolgte die Datenintegration und Harmonisierung der Datensätze, die schließlich die Grundlage für die Erstellung des finalen Prädiktionsmodells bildeten.

Die Umsetzung und Validierung des Modells erfolgte auf Basis dieser gemeinsamen Datengrundlage, wobei NorComs analytischer Beitrag entscheidend zum Erfolg und zur Präzision des Modells beitrug.

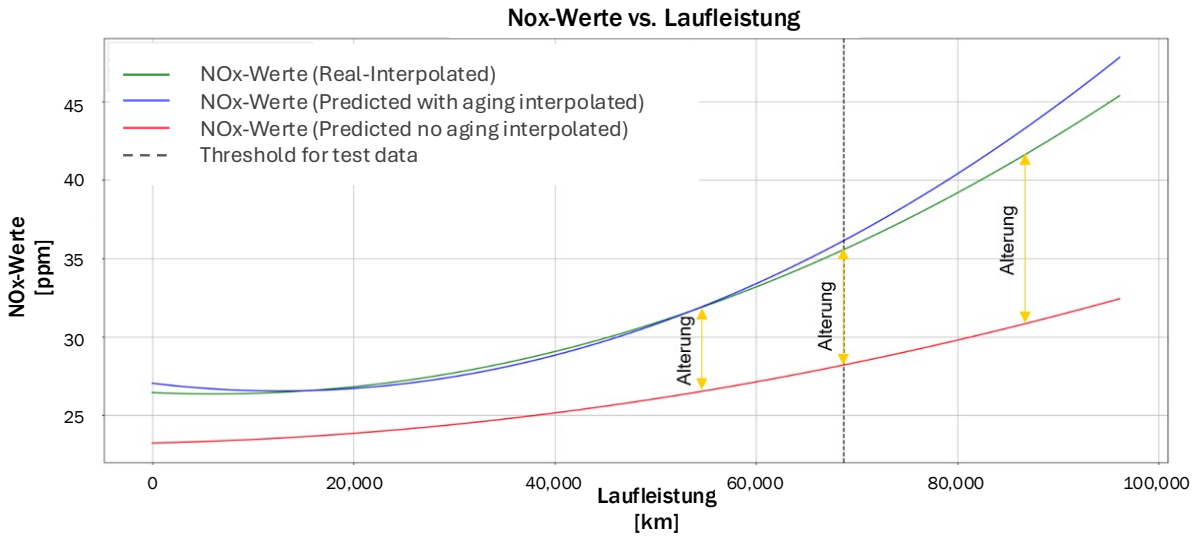

Abbildung 3: Ergebnis des KI-Modells

Das Vorgehen wird in detaillierten Arbeitspaketen analysiert.

II.1.1 Messkonfiguration, Fahrzeugflotte und Datenaufbereitung

Im Rahmen des Arbeitspakets AP1 wurde ein Hybridfahrzeug durch die Universität, in Zusammenarbeit mit dem Unterauftragnehmer IVD Deutschland GmbH, gezielt für die Anforderungen des Projekts ausgerüstet. Ziel war es, eine robuste Sensorik zu integrieren, die eine präzise Datenerfassung für die spätere Modellentwicklung ermöglicht.

Abbildung 4: Sensoren im Abgasstrang des BMW 330e; Temperatur (grün), Druck (blau), NO_x (rosa), NH_3 (gelb)

Für die Datenerfassung und Übertragung kam ein Datenlogger der Firma IPETRONIK zum Einsatz. Dieser Logger ist in der Lage, sowohl analoge Signale als auch CAN-basierte Daten simultan zu erfassen, zu verarbeiten und auf einen zentralen FTP-Server hochzuladen. Neben den zusätzlichen Sensordaten wurden auch relevante fahrzeuginterne Daten, die über die ECU ausgelesen werden konnten, in den Datensatz integriert und zusammen mit den externen Sensormessungen gespeichert. Dadurch wurde eine kontinuierliche und lückenlose Überwachung des Systems gewährleistet.

Die Daten, die auf dem von NorCom bereitgestellten FTP-Server gesammelt wurden, bildeten die Grundlage für die weitere Verarbeitung in der KI-Plattform (siehe Kapitel II.1.6). Die Kombination aus umfassender Sensorintegration, effizienten Datenloggern und einer zentralen Datenspeicherlösung ermöglichte eine systematische Erfassung und Bereitstellung der für das Projekt notwendigen Daten. Der detaillierte Messstellenplan für das Hybridfahrzeug ist in Abbildung 5 dargestellt und dokumentiert die spezifische Platzierung der Sensorik und die Konfiguration der Messhardware.

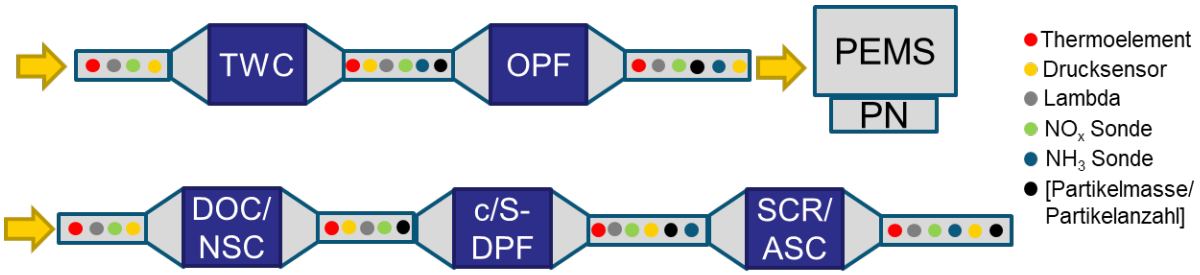

Abbildung 5: Messstellenplan für Otto-Hybrid (oben) und Dieselfahrzeuge (unten)

Im Rahmen von Arbeitspaket AP2 wurden mehrere Fahrzeugtypen eingesetzt, um Daten zur katalytischen Alterung unter realen Betriebsbedingungen zu sammeln und zu analysieren. Ziel war es, eine möglichst breite Bandbreite an Fahrprofilen und Betriebsszenarien abzudecken, um relevante Bedingungen und Ereignisse zu identifizieren, die zur Alterung der Katalysatoren beitragen. Die untersuchten Fahrzeuge wiesen spezifische Einsatzmuster auf, die im Folgenden beschrieben werden.

Die folgenden Fahrzeuge wurden untersucht:

- BMW 330e Hybrid (Pendlerfahrzeug)
- Renault Kadjar (Dauertest auf der Rolle)
- Mercedes Sprinter (Langstreckenfahrzeug im Verteilerverkehr)
- Müllsammelfahrzeuge (festgelegte Route mit niedrigen Lasten)

Die spezifischen Fahrprofile der unterschiedlichen Fahrzeuge ermöglichten eine umfassende Abdeckung des motorischen Kennfelds.

II.1.2 Abbildung realer Fahrzeugbedingungen am Engine-in-the-Loop Prüfstand

Im Rahmen des Projekts wurde ein Engine-in-the-Loop (EiL)-Prüfstand an der Technischen Universität Darmstadt aufgebaut und erfolgreich in Betrieb genommen. Dieser stellte eine zentrale Plattform für die detaillierte Untersuchung von Alterungseffekten in Abgasnachbehandlungssystemen dar. Die Nachbildung realer Fahrzeugbedingungen unter kontrollierten Bedingungen und die Integration einer KI-gestützten Methodik waren zentrale Meilensteine des Projekts.

Als Prüfling wurde ein BMW B48-Motor ausgewählt, der auch im Versuchsträgerfahrzeug, einem BMW 330e Hybrid, verbaut ist. Diese Auswahl stellte sicher, dass die Motorbedingungen auf dem Prüfstand weitgehend mit denen im Fahrzeug übereinstimmen. Die Automatisierungssoftware „Puma“ und die Echtzeitplattform „Model Connect“ von AVL ermöglichten eine präzise Steuerung und Datenverarbeitung in Echtzeit.

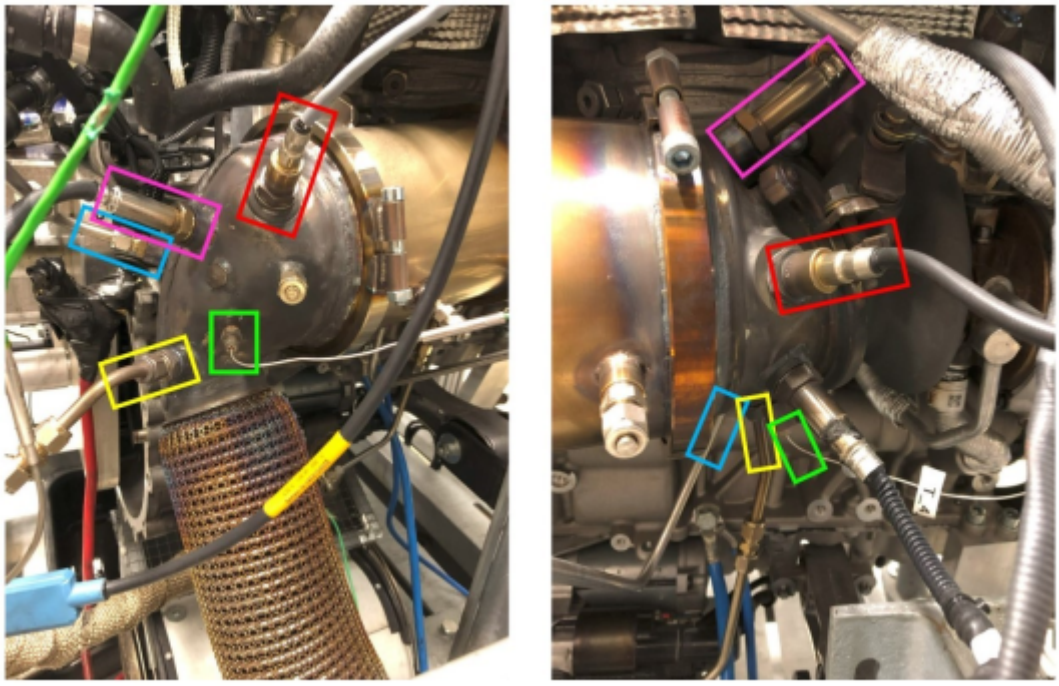

Abbildung 6: Ausstattung des Prüfstands mit Sensoren zur Bestimmung von Temperatur (grün), Druck (gelb), Abgaskonzentrationen (blau – FTIR; lila – NO_x-Sensoren) sowie Lambda (rot)

Die Prüfstandsmessungen zeigten deutliche Alterungseffekte der Katalysatoren über die verschiedenen Phasen des Alterungszyklus.

- Die Temperatur vor und nach dem Katalysator bewegte sich während des gesamten Zyklus im oberen Bereich der Betriebstemperaturen, wobei in der Volllastphase Spitzen von über 800 °C erreicht wurden. Dies führte zu einer beschleunigten Alterung des Katalysators.
- Die NO_x-Emissionen zeigten zunehmende Durchbrüche, insbesondere in den Stationärpunkten und Volllastbereichen, was darauf hindeutete, dass der Katalysator in diesen Phasen sein maximales Umwandlungspotenzial erreichte.
- Die gemessenen Emissionen vor und nach dem Katalysator erlaubten eine präzise Bewertung der Konvertierungsleistung und zeigten, wie sich diese im Alterungsverlauf verschlechterte.

II.1.3 Indikatoren und Trainingsdaten für die KI-Entwicklung aus realen und simulierten Daten

Unter Alterungsindikatoren werden im Rahmen dieses Projekts physikalische Messgrößen verstanden, die eine Alterung von Katalysatoren hervorrufen, oder in Korrelation zur Alterung stehen. Eine Alterung von Katalysatoren äußert sich in einer Verschlechterung der Katalysatorleistung und führt damit zu erhöhten Schadstoffemissionen. Da die Einflussgrößen auf die Alterung sehr vielschichtig und komplex sind, ist die Verwendung eines KI-Modells zur Analyse und Prädiktion der Alterung erforderlich.

Zunächst wurden daher für die Alterung kritische Fahrszenarien betrachtet und die messtechnische Erfassung geprüft. Abbildung 7 zeigt beispielhaft, welche Fahrszenarien relevant für die Katalysatoralterung sind. Eine DPF-Regeneration, also das gezielte Abbrennen von angesammelten Partikeln im Partikelfilter, führt z.B. zu hohen Spitzentemperaturen, sowohl im Partikelfilter als auch im vorgelagerten Oxidationskatalysator. Diese thermischen Belastungen sind entsprechend der Literatur relevant für die Katalysatoralterung.

Event	Beschreibung Event	Messtechnische Erfassung	Alterungsmechanismus	Sonstiges
DPF Reg	Thermische DPF Regeneration	Thermoelemente, Lambdasonden	Thermische Alterung	Partikelpeaks, Lambda-unterschied
Beschleunigung nach Schleppen	Rußausstoß	Thermoelemente, Partikelsensor	Thermische Alterung, mech. Spannungen	
Volllast	Hohe Temperatur	Lambdasonde, Thermoelemente	Thermische Alterung, unkontrollierter Rußabbrand	HC und CO durch Lambda
Schwefeleintrag Diesel	Verschwefelung	Lambdasonde, Thermoelemente	Chem. Vergiftung	Umsatzreduzierung langzeitig
$DeSO_x$ (inkl. Abbruch)	Entschwefelung	Thermoelemente, Lambda	Thermische Alterung	
$DeNO_x$ (inkl. Abbruch)	Bei NSC, Mager-Fett Betrieb	Thermoelemente, NO_x-Sonde, Lambda	Thermische Alterung	
Partikeldurchbruch nach DPF Reg	Partikeldurchbruch nach DPF Reg	NO_x-Sonde, Lambda, Partikel, NH_3	Beschädigung Filter	
Ölvergiftung	Verbennungsrück-stände Öl	Lambda, NO_x ,	Teils irreversible Vergiftung	Je nach Rückstand

Abbildung 7: Beispiele für Fahrszenarien, die eine Katalysatoralterung hervorrufen können und die dazugehörige messtechnische Erfassung.

II.1.3.1 Modelle zur Erweiterung der Messdaten

II.1.3.1.1 Modell zur Bestimmung des Abgasmassenstroms am Sprinter

Die Datenlage der Versuchsfahrzeuge, die im Rahmen dieses Projektes im Einsatz waren, war für die benötigten Eingänge der KI-Modelle nicht immer ausreichend. Um Datenlücken zu schließen, wurde vom Projektkonsortium ein datenbasiertes Modell in Matlab/Simulink aufgebaut, welches den Abgasmassenstrom des LCV anhand anderer Größen berechnet. Das Modell ist dabei stark vereinfacht, da durch die kennfeldbasierte Berechnung keine dynamischen Effekte berücksichtigt werden. Entsprechend ist die Modellgüte limitiert. Die Daten für das Modell werden durch einen Motor generiert, der am VKM auf dem Prüfstand aufgebaut ist und Ähnlichkeiten zum Versuchsfahrzeug aufweist. Wie im Fahrzeug handelt es sich um einen Vierzylinder-Dieselmotor mit zwei Litern Hubraum.

Das von dem Projektkonsortium entwickelte Modell zur Bestimmung des Abgasmassenstroms am Sprinter wurde von NorCom in die Datenvorverarbeitungspipeline auf der Datenplattform integriert, sodass diese Größen für die weiteren Analysen als Schätzwerte zur Verfügung standen.

II.1.3.1.2 Entwicklung eines Semiphysikalischen Modells zur Alterungsbestimmung

Ein semiphysikalisches Modell war eines der zentralen Ergebnisse von AP 3. Es basiert auf einer Kombination aus physikalischen Grundsätzen und statistischen Methoden, die es ermöglichen, die Alterung der Katalysatoren basierend auf Temperatur-, Druck- und Emissionsdaten zu beschreiben.

Das semiphysikalische Modell wurde in Zusammenarbeit mit der IVD Deutschland GmbH und NorCom entwickelt und basiert auf einem bereits bestehenden Modell. Im Kern des Ansatzes steht die Einteilung von erkannten Konstantpunkte in Cluster, wobei die Parameter Abgasmassenstrom und Temperatur als zentrale Einflussgrößen dienen. Im Rahmen dieses Projekts sowie der Entwicklung geeigneter KI-Modelle zur Beschreibung der Katalysatoralterung ist die Einführung sogenannter *Konstantpunkte* von zentraler Bedeutung. Ziel dieser Maßnahme ist es, die dynamischen Einflüsse aus den Messdaten zu eliminieren, um die langfristigen, strukturellen Veränderungen im Systemverhalten – also die eigentliche Alterung – isoliert betrachten zu können. Obwohl Alterungsprozesse grundsätzlich durch dynamische Betriebszustände beeinflusst werden können, liefern diese kurzfristigen Effekte keine unmittelbar verwertbaren Informationen zur nachhaltigen Beschreibung der Alterungstendenz.

Die Definition der Konstantpunkte erfolgte unter der Prämisse, ausschließlich stationäre Betriebszustände in das Modell zu integrieren. Hierzu wurden mehrere Filterkriterien implementiert, um stark dynamische Effekte sowie Extremzustände systematisch auszuschließen.

Ein wesentliches Kriterium war die Auswahl eines geeigneten Temperaturbereichs. Dabei wurde ein Temperaturfenster definiert, das typische Betriebsbedingungen des Fahrzeugs abdeckt. Gleichzeitig wurden Phasen mit sehr hohen Temperaturen sowie Aufwärmphasen ausgeschlossen, da diese Sonderzustände keinen repräsentativen Charakter für den regulären Betrieb besitzen. Zusätzlich musste die Abgastemperatur innerhalb eines Zeitintervalls von mindestens 10 Sekunden annähernd konstant bleiben. Konkret wurde hierfür gefordert, dass der Temperaturgradient in dieser Zeitspanne unterhalb eines definierten Schwellenwertes liegt, um kurzzeitige Schwankungen auszufiltern.

Neben der Temperatur wurde auch der Lambda-Wert als relevantes Kriterium zur Auswahl der Konstantpunkte herangezogen. Hierbei wurden ausschließlich Datenpunkte berücksichtigt, die einem typischen Betrieb des jeweiligen Fahrzeugs entsprechen. Bei Ottomotoren wurden zum Beispiel Betriebszustände wie Anfettung ($\lambda < 1$) oder Phasen hoher Luftüberschüsse ($\lambda \gg 1$), beispielsweise beim Schubbetrieb oder im Hochlastbereich, ausgeschlossen, da sie zu nicht-repräsentativen Emissionsverhältnissen führen.

Zusätzlich wurden Leerlaufphasen entfernt, da der Motor in diesen Zuständen oftmals in einem nicht optimalen thermodynamischen Gleichgewicht arbeitet, was sich negativ auf die Konsistenz der Daten hinsichtlich des NO_x-Ausstoßes und der Alterung auswirkt. Ergänzend wurden auch Einschränkungen hinsichtlich des Abgasmassenstroms sowie des Motormoments vorgenommen. Nur Betriebszustände mit Werten innerhalb eines als „normal“ definierten Bereichs wurden in die Analyse einbezogen, um außergewöhnliche Belastungszustände zu vermeiden.

Durch die Einführung dieser Konstantpunkte wird eine robuste und interpretierbare Datenbasis geschaffen, die es ermöglicht, den Alterungsprozess unabhängig von kurzzeitigen dynamischen Effekten zu analysieren und in datengetriebenen Modellen abzubilden.

Zur Sicherstellung einer gleichmäßigen und aussagekräftigen Verteilung der Datenpunkte innerhalb der Konstantpunkt-Cluster wurde der K-Means-Algorithmus eingesetzt. K-Means ist ein unüberwachtes Clustering-Verfahren, das darauf abzielt, eine gegebene Menge von Datenpunkten in k Gruppen (Cluster) zu unterteilen, sodass die Varianz innerhalb eines Clusters minimiert und die Varianz zwischen den Clustern maximiert wird. Dies geschieht iterativ durch die Zuordnung jedes Datenpunkts zum nächstgelegenen Clusterzentrum und anschließender Neuberechnung dieser Zentren als Mittelwert der jeweils zugehörigen Punkte (vgl. (5)).

Nach der Clusterbildung beginnt die Berechnung der benötigten Größen und Gewichtungsfaktoren. Für jedes Cluster wird ein NO_x-Wert in g/kWh berechnet. Um eine präzise Analyse zu ermöglichen, wird die gesamte Laufleistung des Fahrzeugs in gleichmäßige Abschnitte unterteilt. Diese Abschnitte werden so gewählt, dass in jedem genügend Konstantpunkte vorliegen, die das gesamte Motorkennfeld repräsentieren. Für jeden dieser Abschnitte wird ein gemittelter NO_x-Wert berechnet, der alle Clusterwerte einbezieht.

Durch das Auftragen der gemittelten NO_x-Werte über die Zeitabschnitte entsteht eine Kurve, die die Alterung des Katalysators abbildet (vgl. Abbildung 8).

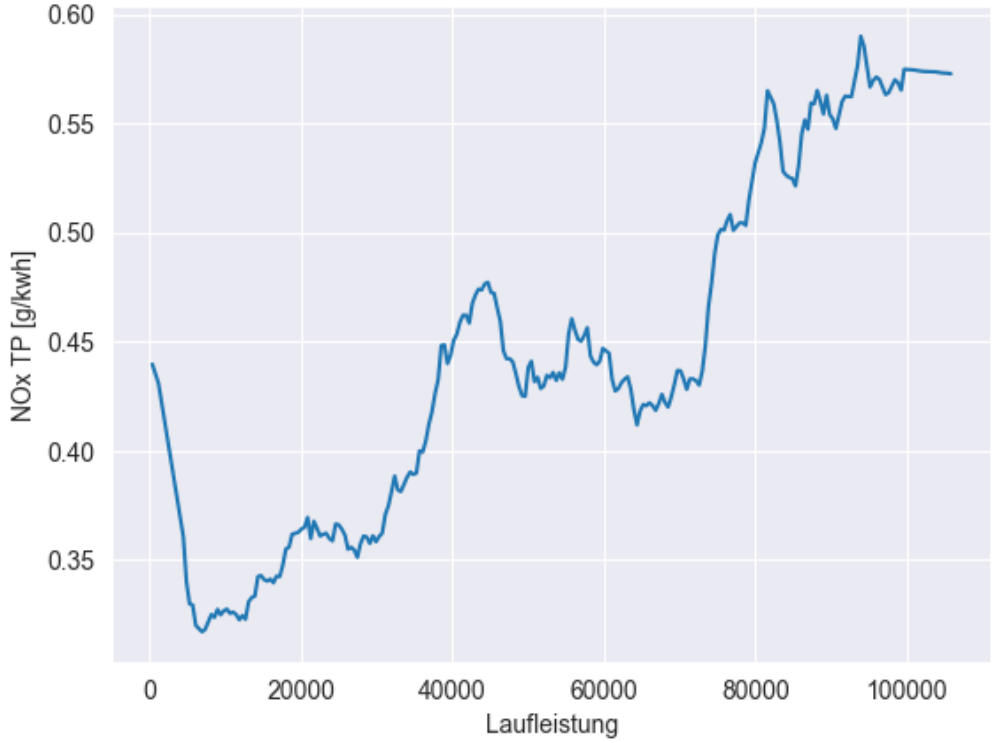

Abbildung 8: Gewichtete NO_x nach TWC eines Rollendauerläufers (Renault Kadjar)

Die in Abbildung 8 dargestellte Kurve zeigt deutlich die Alterung des Katalysators während der Laufleistung des Fahrzeugs. Die stetig steigenden NO_x-Werte verdeutlichen die zunehmende Verschlechterung der Konvertierungsleistung, was auf Alterungseffekte des Katalysators zurückzuführen ist.

Dieser Ansatz erlaubt eine präzise und nachvollziehbare Darstellung der Alterungsentwicklung und bietet somit eine fundierte Grundlage für die Weiterentwicklung und Optimierung des KI-Modells.

II.1.3.2 Identifikation von Alterungsindikatoren und Bereitstellung für das KI-Modell

Im Rahmen dieses Projekts wurde ein KI-Modell entwickelt, das auf den oben beschriebenen stationären Bedingungen basiert. Diese filtern lediglich außergewöhnliche Fahrsituationen heraus. Aufgrund der verschiedenen vorhandenen Kanäle für die Fahrzeugarten wurden fahrzeugspezifische KI-Modelle entwickelt.

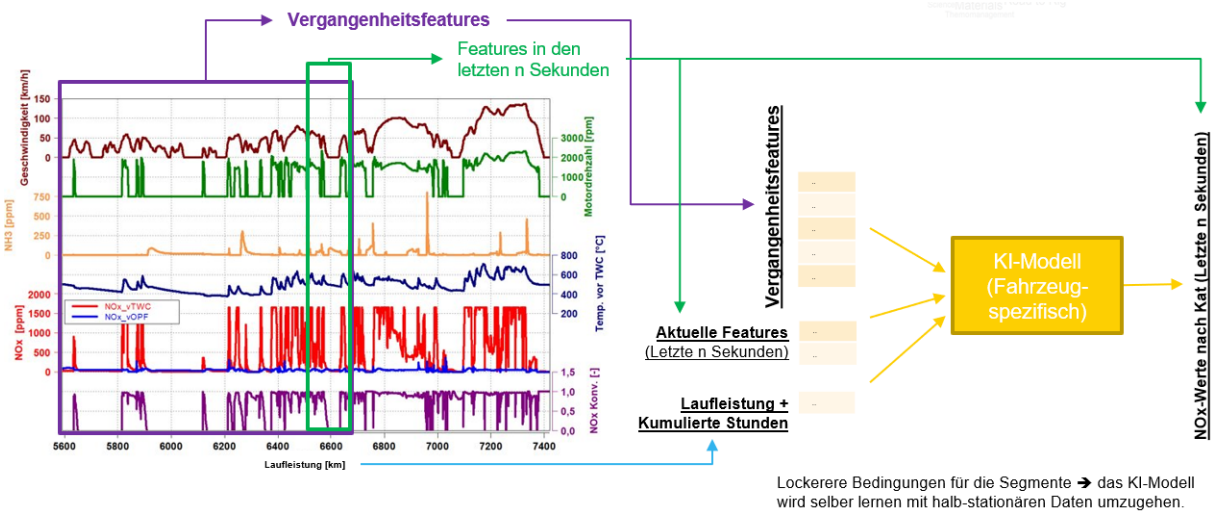

Abbildung 9: Definition der Modell Eingangsgrößen

Die stationären Bedingungen werden auch in diesem Fall genutzt, um Segmente zu definieren, aus denen die Trainingsdaten generiert werden. Diese Segmente werden anschließend in **Sliding Windows** mit einer konstanten Breite unterteilt. Für jedes Zeitfenster wird ein Datenpunkt erstellt, der die folgenden drei Arten von Features enthält:

- **Laufleistung bzw. kumulierte Betriebsstunden**
- **Vergangenheitsfeatures**
- **Aktuelle Features (Merkmale der letzten *n* Sekunden)**

Laufleistung und kumulierte Betriebsstunden sind kumulierte Features, die Fahrt für Fahrt monoton ansteigen.

Aktuelle Features beschreiben die Statistiken der letzten *n* Sekunden. Dazu gehören beispielsweise der Durchschnittswert, das Minimum, das Maximum und die Standardabweichung jedes betrachteten Kanals (fahrzeugspezifisch).

Vergangenheitsfeatures geben an, wie häufig eine bestimmte aktuelle Eigenschaft in der Vergangenheit innerhalb eines definierten Wertebereichs lag. Beispielsweise kann für die durchschnittliche GPS-Geschwindigkeit analysiert werden, wie oft das Fahrzeug in der Vergangenheit langsam, mittelschnell oder schnell unterwegs war. Zusätzlich zu den Kanalstatistiken werden auch bestimmte Ereignisse (z.B. Regenerationsvorgänge, Fuel Cut-off usw.) definiert, erfasst, kumuliert und als Vergangenheitsfeatures berücksichtigt. Die Wertebereiche werden automatisch so festgelegt, dass die Anzahl der Datenpunkte pro Bereich möglichst gleichmäßig verteilt ist. Diese drei Bereiche werden für jedes Feature individuell angepasst.

Die betrachteten Kanäle, zusammen mit den entsprechenden Segmentierungsbedingungen und Ereignissen für jede Fahrzeugart, werden in einer Konfigurationsdatei gespeichert, sodass der Benutzer später in der App lediglich die Fahrzeugart auswählen muss.

Als Ausgabe liefert das neue KI-Modell den vorhergesagten NO_x-Wert nach dem Katalysator für die letzten *n* Sekunden.

Das Modell soll lernen die Effekte der Alterung (Laufleistung, Kumulierte Stunden und Vergangenheitsfeatures) von den Effekten der aktuellen Fahrbedingung (aktuelle Features) zu trennen.

Die besondere Struktur dieses Modells ermöglicht 2 Anwendungen gleichzeitig:

1. Analyse der Alterungsfaktoren
2. Anbindung an den Prüfstand, um eine Live-Abschätzung der Alterung zu haben.

<u>Anwendung 1</u>

Für die erste Anwendung werden die im Feld aufgenommenen Daten analysiert, und darauf basierend wird ein KI-Modell trainiert, das den aktuellen NO_x-Wert vorhersagt. Um die für die Alterung relevanten Merkmale zu identifizieren, werden anschließend die **Feature Importances (Gini-Importance** (6)**)** des trainierten KI-Modells untersucht.

Die **Feature Importances** zeigen, welche Merkmale den größten Einfluss auf die Vorhersage des NO_x-Werts haben. Vergangenheitsmerkmale mit hoher Bedeutung können ein Hinweis darauf sein, dass sie zur Alterung des Katalysators beitragen. Beispielsweise könnte eine hohe Temperaturdifferenz als besonders wichtig eingestuft werden, was darauf hindeutet, dass sie einen Einfluss auf den Alterungsprozess hat.

Eine alternative Methode ist die **SHAP-Analyse** (7). Sie zeigt nicht nur die Bedeutung der einzelnen Merkmale, sondern auch, ob ihr Einfluss positiv oder negativ auf den vorhergesagten NO_x-Wert wirkt.

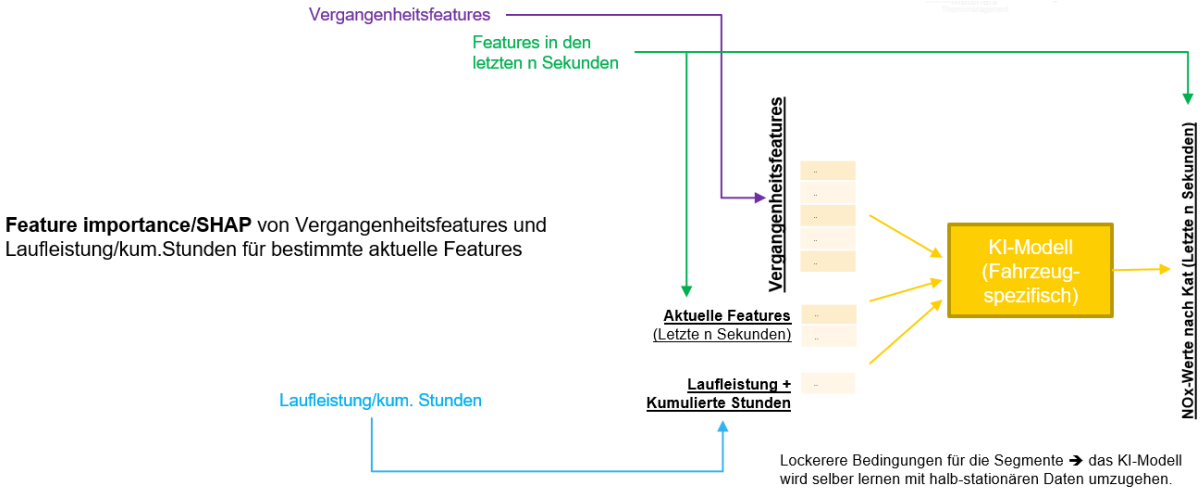

Abbildung 10: Analysekonzept des KI-Modells

<u>Anwendung 2</u>

Die zweite Anwendung ist für die **Live-Alterungsabschätzung** konzipiert. In diesem Fall können Live-Daten (z. B. aktuelle Merkmale aus einem Prüfstand) verwendet werden, während den anderen Merkmalen Werte zugewiesen werden, die sie hatten, als der Katalysator noch neu war (z. B. Laufleistung = 0).

Dadurch erhält man einen NO_x-Wert, der dem eines nicht gealterten Katalysators entspricht. Dieser kann dann mit dem real gemessenen NO_x-Wert vom Prüfstand verglichen werden. Die **Differenz** zwischen beiden Werten gibt die Alterung in ppm an. Eine genaue Beschreibung der Anbindung an den Prüfstand wird in Abschnitt 22II.1.5.2 gegeben.

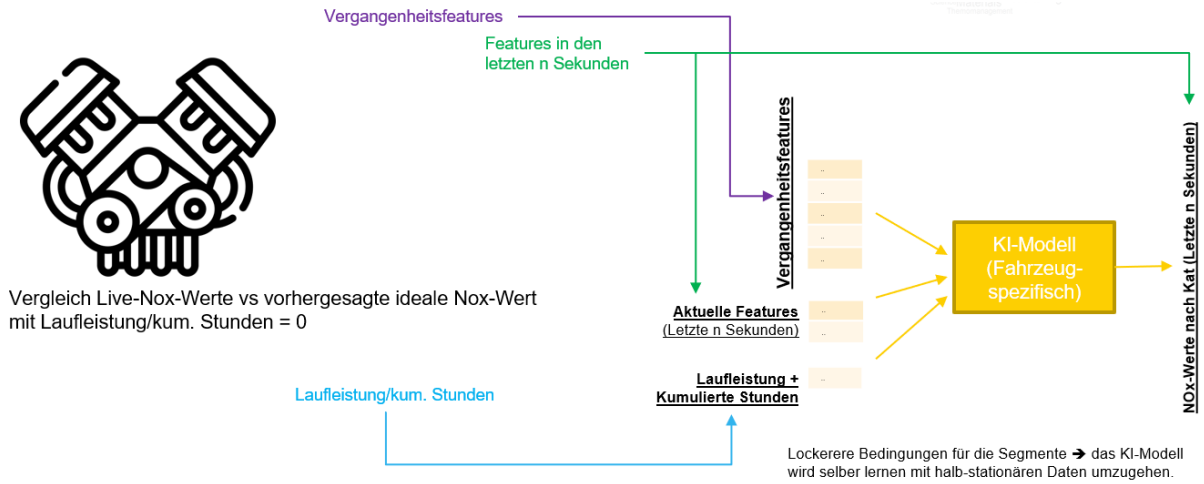

Abbildung 11: Konzept zur Übertragung des KI Modells an den Prüfstand

II.1.4 KI-Framework

Im Rahmen des Arbeitspakets AP5 KI-Framework wurden verschiedene Klassen von KI-Modellen eingesetzt, um die Vorhersage der NO_x-Werte nach dem Katalysator zu optimieren. Dabei wurden die Eingangsgrößen der Modelle genutzt, um die NO_x-Werte vorherzusagen und diese anschließend mit den

tatsächlichen Werten zu vergleichen, die nicht in den Eingangsdaten enthalten waren. Dieser Bericht fasst die Methodik, die Ergebnisse und die weiteren Schritte des Projekts zusammen.

Ein zentraler Bestandteil des Projekts war die Entwicklung eines transparenten und interpretierbaren KI-Modells auf Basis von XGBoost (8). Dabei wurde besonderer Wert auf Explainable AI gelegt, um die Entscheidungsprozesse des Modells nachvollziehbar zu machen. Die Methodik umfasste das automatische Generieren von Features, das Training des Modells und die Analyse der Feature-Relevanz. Dies ermöglichte es, den Einfluss der verschiedenen Eingangsgrößen auf die NO_x-Vorhersage zu bewerten.

Neben dem XGBoost-Modell wurden auch neuronale Netzwerke (NN) entwickelt, trainiert und optimiert. Die Performanz der Modelle wurden anschließend anhand RMSE (Root mean squared error, d.h. eine Kennzahl der Abweichung zwischen vorhergesagten und realen Werten) verglichen. Dabei kommt die Cross-Validation-Methode zum Einsatz, um die Leistungsfähigkeit des Modells auf bislang unbekannten Daten zu bewerten. Die Ergebnisse (Abbildung 12) zeigten, dass die XGBoost-Modelle bei der aktuellen Datenmenge und den betrachteten Features die neuronalen Netzwerke übertrafen. Daher wurde die weitere Arbeit mit NN-basierten Modellen eingestellt. Zudem zeigten die Ergebnisse, dass die Kombination aus akkumulierten und Vergangenheits-Features die Modellgüte verbessert.

Model	Zeitreihe/ Akummulierte AF?	Mit Vergangenheits Feature?	cv_rmse_mean (ppm)
XGB	Akk.	Ja	8.05
XGB	Akk	Nein	10.22
XGB	Zeitreihe	Ja	9.14
XGB	Zeitreihe	Nein	10.67
Dense Network (NN)	Akk	Ja	10.49
Dense Network (NN)	Zeitreihe	Ja	10.31

Abbildung 12: Leistungsfähigkeit neuronaler Netzwerk-Modelle und Vergleich mit einem entscheidungsbaum-basierten Modell (mittlerer RMSE der Vorhersagewerte).

Die Ergebnisse wurden in Form von Diagrammen und Tabellen dargestellt, die die Leistungsfähigkeit der verschiedenen Modelle veranschaulichen. Ein Bild der Report-Seite der entwickelten App ist im Anhang zu finden.

Um das Modell weiter zu analysieren, wurde die SHAP-Methode (7) (SHapley Additive exPlanations) eingesetzt. Diese ermöglichte es, die Beiträge einzelner Features zur Vorhersage zu quantifizieren und zu visualisieren. Zusätzlich wurden What-if-Szenarien durchgeführt, um das Verhalten des Modells unter verschiedenen Bedingungen zu testen und zu validieren.

Es wurde festgestellt, dass komplett synthetisch generierte Daten nur begrenzt nutzbar sind, da sie nur einen geringen Informationszugewinn für das Modell bieten. Allerdings erwies sich die Generierung einzelner Kanäle als sehr hilfreich, insbesondere wenn Sensoren ausfielen. Die Trainingsdatenerstellung wurde mithilfe der Module der Kanal-Ergänzungsapp (vgl. Kapitel II.1.6.2) durchgeführt, um die Datenqualität zu verbessern.

Während der Projektlaufzeit wurde ein Modellwechsel vorgenommen, da weniger Daten zur Verfügung standen als ursprünglich angenommen. Die Zwischenergebnisse wurden dokumentiert und in Form von Bildern und Diagrammen visualisiert, um den Fortschritt und die Anpassungen nachvollziehbar zu machen.

Das entwickelte Modell wurde am EiL (Engine-in-the-Loop) eingesetzt, um seine Praxistauglichkeit zu überprüfen. Dabei wurden zwei Schnittstellen evaluiert:

Die Ergebnisse dieser Evaluation werden in Abschnitt II.1.5.2 detailliert beschrieben.

II.1.5 Anwendung und Bewertung der KI zur Alterungsdetektion

II.1.5.1 Relevanz und Plausibilität des KI Modells

Auswahl der Zielgrößen

Das entwickelte KI-Modell dient der Vorhersage der Alterung eines Fahrzeugkatalysators. Die Modellierung basiert auf der Analyse des NO_x-Werts nach dem Katalysator, welcher als Indikator für die katalytische Leistungsfähigkeit herangezogen wird. Eine direkte Messung der Alterung ist jedoch nicht trivial, da sie von zahlreichen Einflussfaktoren abhängt. Eine gängige Methode zur Charakterisierung der Alterung ist der Vergleich mit dem Neuzustand des Katalysators. Dieser Ansatz wurde in modifizierter Form für das Modell angewandt, um eine zuverlässige und präzise Alterungsvorhersage zu ermöglichen.

Ein direkter Vergleich der NO_x-Konvertierung vor und nach der Alterung ist in der Praxis schwierig, da gängige NO_x-Sensoren in Fahrzeugen insbesondere in dynamischen Fahrsituationen ihre Messgrenzen erreichen und daher ungenaue oder unplausible Werte liefern. Daher wurde entschieden, den NO_x-Rohwert des Motors lediglich zu überwachen, um sicherzustellen, dass keine Verschlechterung der Motorleistung vorliegt. Das Modell bezieht sich ausschließlich auf den NO_x-Wert nach dem Katalysator und bestimmt die Alterung durch den Vergleich zwischen dem initial erfassten NO_x-Wert eines neuen Katalysators und den aktuellen Messwerten. Die Differenz dieser Werte dient als Indikator für die Alterung.

Darüber hinaus wurde untersucht, ob die alleinige Betrachtung der NO_x-Konzentration in ppm ausreicht oder ob eine Umrechnung in g/kWh eine genauere Einschätzung der Alterung ermöglicht. In der Abbildung 13 wird der Vergleich der NO_x-Werte in beiden Einheiten dargestellt. Hierbei zeigt sich, dass der ähnliche Trend der gewichteten NO_x-Werte in g/kWh mit dem Verlauf der NO_x-Konzentration in ppm übereinstimmt. Dies bedeutet, dass die reinen Konzentrationswerte ausreichen, um das Modell zu trainieren. Generell ist zu erwarten, dass die NO_x-Konzentration stark vom aktuellen Betriebszustand des Fahrzeugs abhängig ist, während die Gewichtung diese Abhängigkeit reduziert. Dennoch zeigt sich eine geringe Abhängigkeit der gewichteten NO_x-Werte vom Betriebszustand, da bei höheren Lasten und entsprechend höheren NO_x-Rohkonzentrationen die katalytische Umwandlung tendenziell ineffizienter ist.

Durch die Vorgehensweise, wie sie in Abschnitt II.1.3 beschrieben ist, wurde die Dynamik aus den Messdaten entfernt, sodass stets passende Abschnitte berücksichtigt wurden, die einen gemittelten Wert anzeigen. Die Auswahl der Intervalle erwies sich als korrekt, da jeder Abschnitt einen gleichwertig repräsentativen Fahrzustand darstellt. Ebenso bestätigt sich, dass die Auswahl der Konstantpunkte korrekt

gewählt wurde, da die Dynamik in diesen Abschnitten eine untergeordnete Rolle spielt. Dies führte dazu, dass die starke Streuung der NO_x-Werte durch die definierten Bedingungen so reduziert wurde, dass sie eine ähnliche Güte aufweisen wie die gewichteten NO_x-Werte. Der Vorteil dieser Methode liegt darin, dass durch die Nutzung der reinen Konzentration keine zusätzliche Fehlerquelle eingeführt wird, die bei der Berechnung der NO_x-Werte in g/kWh entstehen würde.

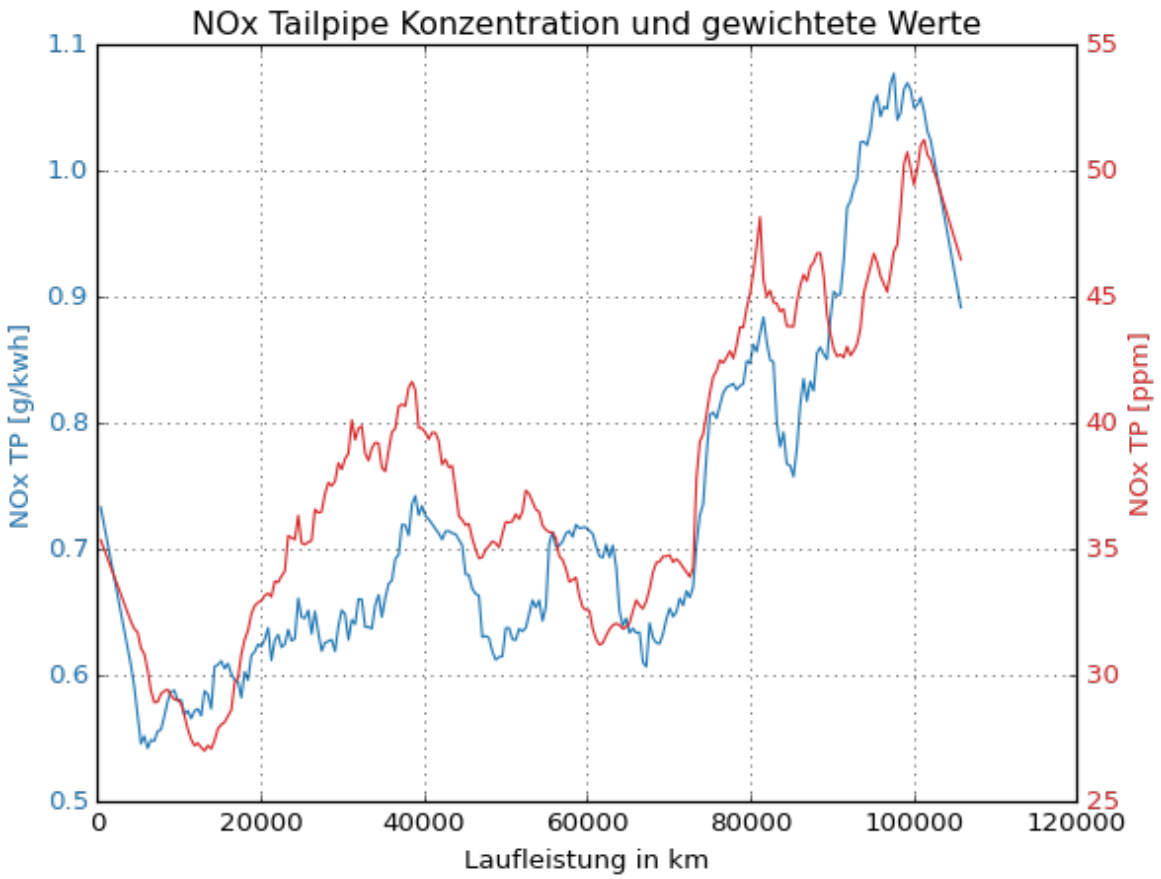

Abbildung 13: NO_x-Tailpipe Konzentration und gewichtete Werte

Eine detaillierte Untersuchung der Feature-Importance des Modells, welche in Abbildung 14 dargestellt ist zeigt, dass insbesondere die Laufleistung einen erheblichen Einfluss auf die Modellvorhersage hat. Dies bestätigt, dass das Modell in der Lage ist, die Alterung des Katalysators über die Zeit korrekt zu erfassen. Zudem spielen Geschwindigkeit und Drehmoment eine zentrale Rolle, da sie sowohl die Katalysatortemperatur als auch den Volumenstrom durch den Katalysator beeinflussen. Beide Parameter sind entscheidende Faktoren für die Katalysatoralterung. Weitere wichtige Einflussgrößen sind die Temperatur und das Lambda-Verhältnis, die sowohl den aktuellen Zustand als auch die langfristige Alterung des Katalysators beeinflussen.

Nr.	Feature	Importance
0	km_stand	20703
1	hist_time_idle_hours_bw_-inf_0.08443333	6464
2	geschwindigkeit_sw_af_avg	6230
3	geschwindigkeit_sw_af_std	4372
4	drehmoment_sw_af_std	4156
5	drehmoment_sw_af_avg	4043
6	t_nach konv_sw_af_std	3581
7	lambda_vor_konv_sw_af_avg	3509
8	lambda_nach_konv_sw_af_std	3404
9	hist_time_idle_hours_bw_0.08443333_1.04816666	3368
10	lambda_nach konv_sw_af_avg	3325
11	lambda_vor konv_sw_af_std	3046
12	motordrehzahl_sw_af_std	3045
13	Ansaugluftemperatur_sw_af_std	2811
14	t_vor_konv_sw_af_std	2615
15	lambda_vor_konv_sw_af_min	2518
16	delta_kat_sw_af_std	2429
17	lambda_vor_konv_sw_af_max	2408
18	motordrehzahl_sw_af_avg	2208
19	t_nach_konv_sw_af_avg	2157
20	hist geschwindigkeit avg_bw_105.8601_109.1853	2041

Abbildung 14: Feature-Importance des finalen KI-Modells

Somit kann gesagt werden, dass die physikalischen Zusammenhänge der Alterung durch das Modell korrekt erfasst wurden, was sich in den Überprüfungen der Modellvorhersagen zeigt. Eine exemplarische Modellvalidierung ist in Abbildung 15 dargestellt. Das Diagramm zeigt die real gemessenen NO_x-Werte (grüne Linie) in ppm über die Laufleistung des Fahrzeugs. Dabei ist erkennbar, dass die NO_x-Konzentration erwartungsgemäß mit zunehmender Fahrleistung steigt. Die blaue Linie zeigt die durch das Modell berechneten NO_x-Werte. Der Trainingszeitraum endet an der gestrichelten vertikalen Linie, während die Daten danach für das Modell unbekannt sind. Die Vorhersagegenauigkeit bleibt nach der Trainingsphase hoch, wobei die berechneten Werte weiterhin der steigenden NO_x-Konzentration folgen.

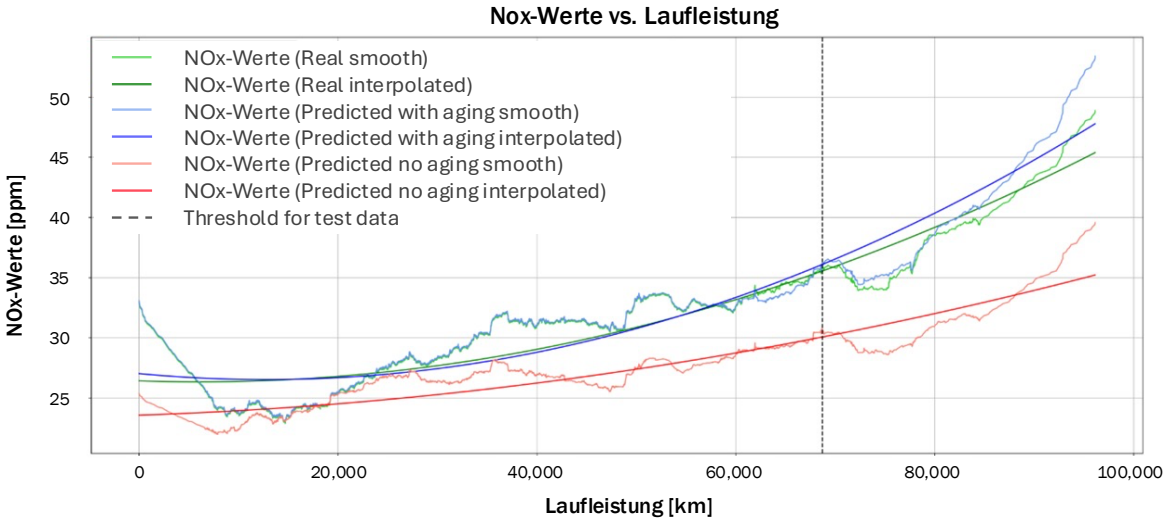

Abbildung 15: Verlauf der realen und modellierten NOx-Werte

Zusätzlich wird die NO_x-Konzentration eines hypothetisch neuen Katalysators berechnet (rote Linie). Diese Werte bleiben weitgehend konstant, da ein neuer Katalysator eine gleichbleibend hohe Umsetzungsrate aufweisen sollte. Eine leichte Abweichung in späteren Betriebsphasen ist auf Unterschiede im Lastprofil zurückzuführen, hat jedoch keinen signifikanten Einfluss auf die Alterungsvorhersage. Da für die Alterung die Differenz von Bedeutung ist.

Das Diagramm in Abbildung 16 stellt die berechnete Alterung des Katalysators dar, indem die Differenz zwischen den realen und simulierten NO_x-Werten bestimmt wird. Dabei zeigt sich eine initiale Verbesserung, was darauf hinweist, dass der Katalysator nach einer Einfahrphase seine optimale Konvertierung erreicht. Anschließend folgt eine kontinuierliche Verschlechterung, die den Alterungsprozess widerspiegelt.

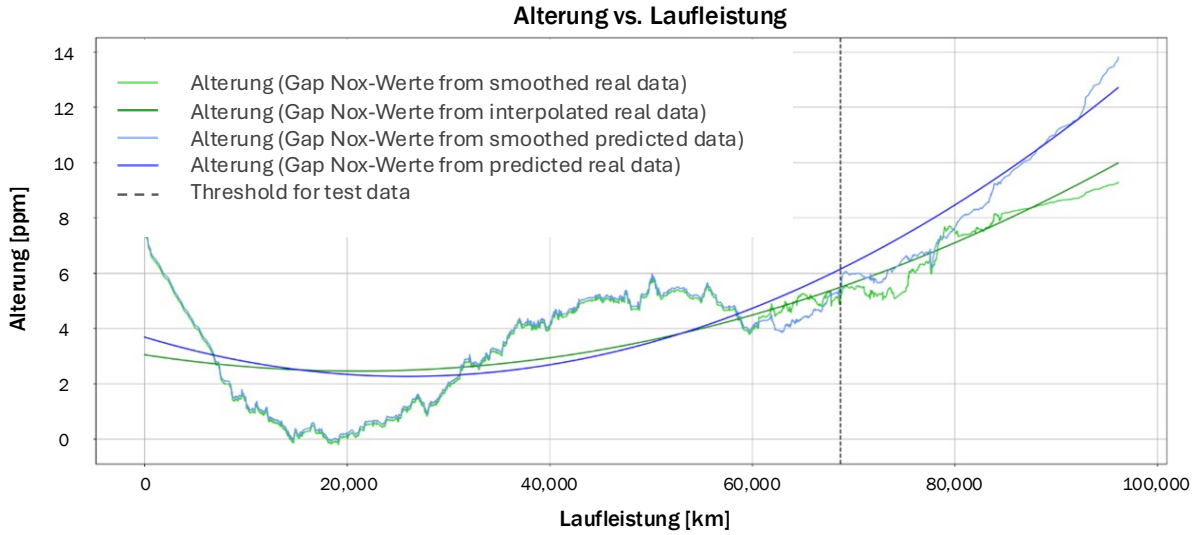

Abbildung 16: Wahre und modellierte NOx Werte

Somit zeigt das entwickelte Modell bietet mehrere Vorteile:

1. Es ermöglicht eine direkte Alterungsvorhersage ohne zusätzliche Messfehlerquellen, da auf gemessene NO_x-Werte zurückgegriffen wird.
2. Die Berechnung der Differenz zwischen den aktuellen NO_x-Werten und denen eines neuen Katalysators erlaubt eine klare Quantifizierung der Alterung.
3. Das Modell kann nicht nur die NO_x-Emissionen über die Zeit simulieren, sondern auch fundierte Aussagen über die Emissionseinhaltung des Katalysators treffen.

Insgesamt zeigt sich, dass das Modell eine robuste Methode zur Alterungsvorhersage darstellt und in der Lage ist, die physikalischen Zusammenhänge der Katalysatoralterung realistisch abzubilden.

II.1.5.2 KI-Integration in den Prüfstand

Zur genaueren Bewertung des entwickelten KI-Modells wurde eine Methode entwickelt, beliebige KI-Modelle in die Echtzeitsimulation eines Prüfstands zu integrieren. Nachdem ein grundlegender Rahmen für die KI festgelegt und der Prüfling erfolgreich am Motorenprüfstand in Betrieb genommen worden war, bestand der nächste Schritt darin, das KI-Modell auf dem Prüfstand zu integrieren, um Echtzeitvorhersagen zu ermöglichen.

Für eine KI-Integration am EiL-Prüfstand wurden mehrere Möglichkeiten in Betracht gezogen. Von Seiten der AVL-D wurden verschiedene Anschlussmöglichkeiten (Interface) erarbeitet und diskutiert. Gemeinsam mit TU Darmstadt und NorCom wurde entschieden, dass die Umsetzung bzw. Ausführung des KI-Modells in Form eines Python-Skripts ideal ist.

Im Rahmen des Projekts wurden mehrere Plattformen zur Anbindung des KI-Modells an den Engine-in-the-Loop-Prüfstand evaluiert. Zunächst wurde eine CAN-Anbindung über AVL PUMA R6™ getestet, die jedoch aufgrund begrenzter Datenübertragungsraten keine zuverlässige Echtzeitverbindung ermöglichte. Anschließend wurde das Python-Modell mithilfe von PythonFMU in eine FMU konvertiert und über AVL Model.CONNECT™ eingebunden. Obwohl damit eine Echtzeitkommunikation technisch möglich war, traten modellbedingte Einschränkungen auf, die die Aussagekraft begrenzten. Auch die Integration über AVL CAMEO 5™, etwa über Python-API, XCP oder WebAPI, bot interessante Ansätze, erwies sich jedoch während der Projektlaufzeit als nicht vollständig umsetzbar für Echtzeitanforderungen. Insgesamt zeigte sich, dass keine der getesteten Schnittstellen eine vollständig zufriedenstellende Lösung für die Echtzeitintegration des KI-Modells am Prüfstand bot.

Gemeinsam mit den Projektpartnern wurde das bestehende Python-Skript für das KI-Modell an das WebAPI-Format angepasst und modifiziert, um ein funktionierendes Skript zu erstellen. Im letzten Schritt musste das Format der Kanäle (Messdaten), die ausgegeben und eingelesen werden, noch definiert werden. Die ursprüngliche Idee, die Kanäle im Vektorformat zu speichern, wurde verworfen. Stattdessen wurde das Skript so angepasst, dass die Kanalwerte zusammen mit den Zeitstempeln in einer separaten Datei gespeichert wurden.

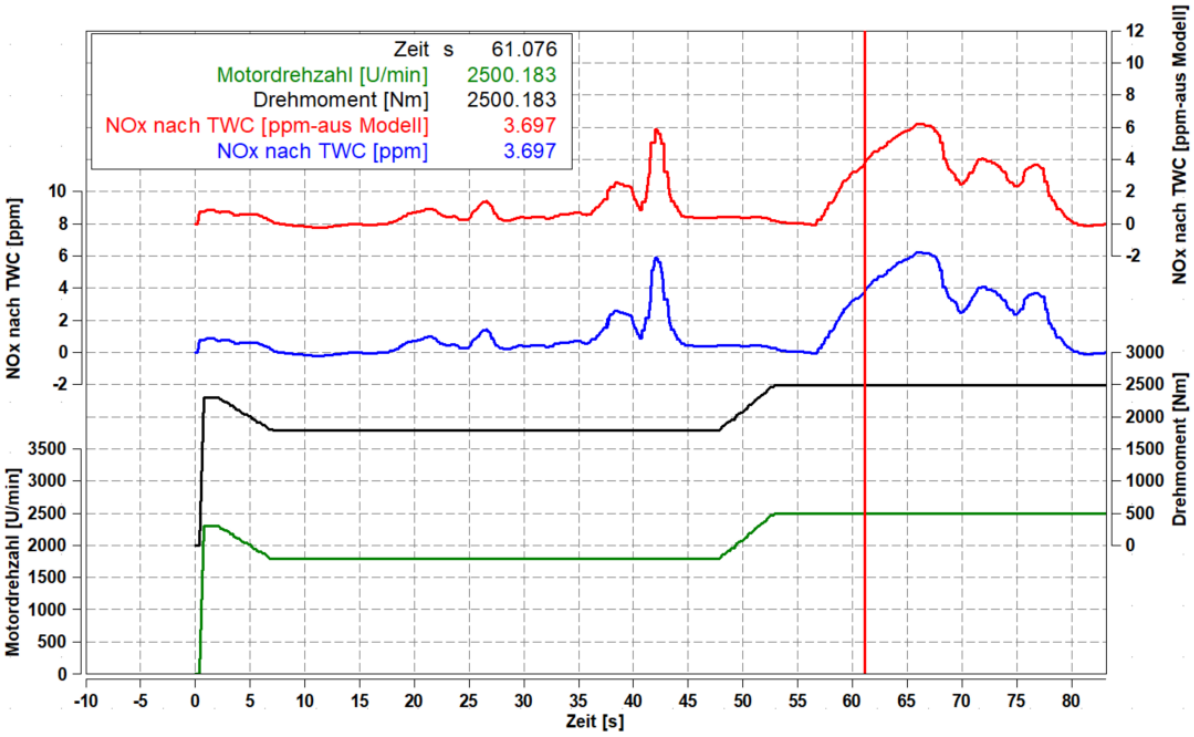

Abbildung 17: Ergebnisse KI-Integration

Es wurden mehrere Probeläufe in einer simulierten Testumgebung durchgeführt, um die Robustheit des Systems und die Echtzeitfähigkeit zu testen. Nach Erreichen zufriedenstellender Ergebnisse wurde der gesamte Systemaufbau am EiL-Prüfstand gemeinsam mit den Projektpartnern emuliert und erfolgreich in Betrieb genommen. Dieses erste KI-Modell wurde auf die Signale des Testbeds und eines Prüflings der Flotte abgestimmt. Die ersten Ergebnisse sind im oben gezeigten Bild zu sehen.

Damit wurde eine grundlegende Toolchain-Architektur entwickelt, die generisch verwendet werden kann. Der gesamte Aufbau und der CAMEO-Test können von einem Fahrzeug bzw. Prüfstand auf ein anderes übertragen werden, wobei lediglich das fahrzeugspezifische KI-Modell ausgetauscht werden muss. Dieses Plug-and-Play-Konzept war ein bedeutendes Ergebnis für das Projekt und kann für jeden Prüfling implementiert werden.

Model-Deployment als eigenständiger Serving-Container

Im Rahmen des Projekts wurden Module entwickelt, um eine dockerisierte Umgebung für das Model-Serving zu erstellen. Diese lässt sich innerhalb von DaSense nutzen, kann aber auch eigenständig auf Linux-Systemen eingesetzt werden. Der Model-Serving container agiert als eigenständiger Prädiktor, wobei Anfragen über HTTP-Requests erfolgen. Dadurch bietet er eine Alternative zum manuellen Aufsetzen des Modells auf einem externen Rechner, beispielsweise einem Prüfstand. Dies kam anhand eines modifizierten Modells für den Prüfstand bereits im Projekt zum Einsatz.

II.1.6 KI-Plattform

Im Rahmen von AP7 wurde die Daten- und Analyseplattform DaSense so ausgebaut, dass die großen Mengen an anfallenden Fahrzeugdaten gesichtet, verwaltet und mit KI-Methoden analysiert werden können.

DaSense besteht aus zwei Teilen: Der Data Management Umgebung und der Data Analytics Umgebung.

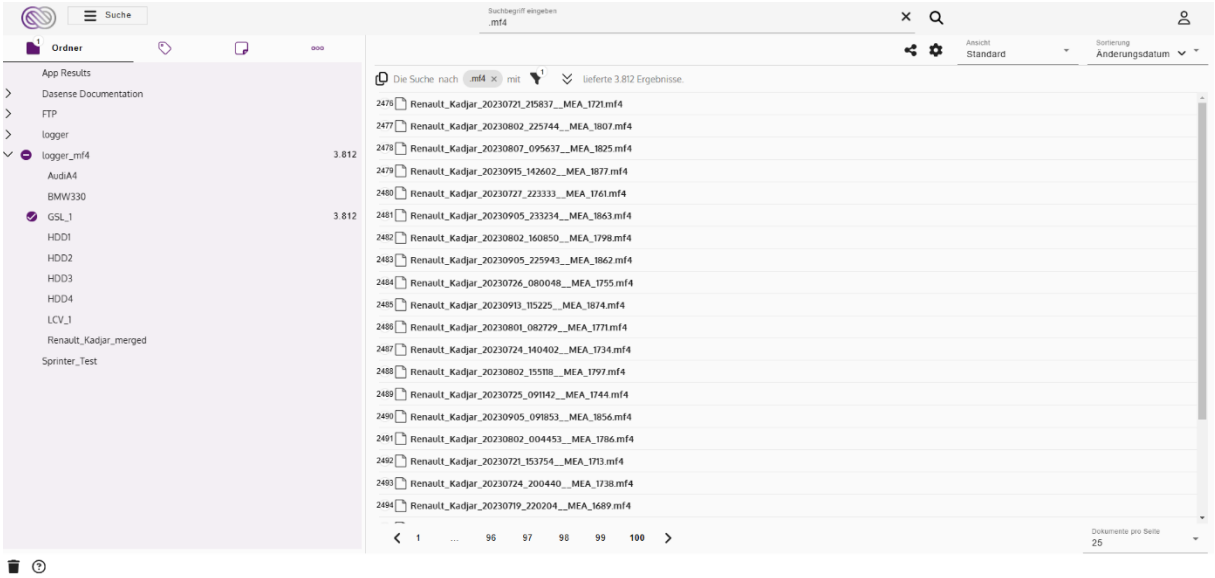

Abbildung 18: Data Management Umgebung

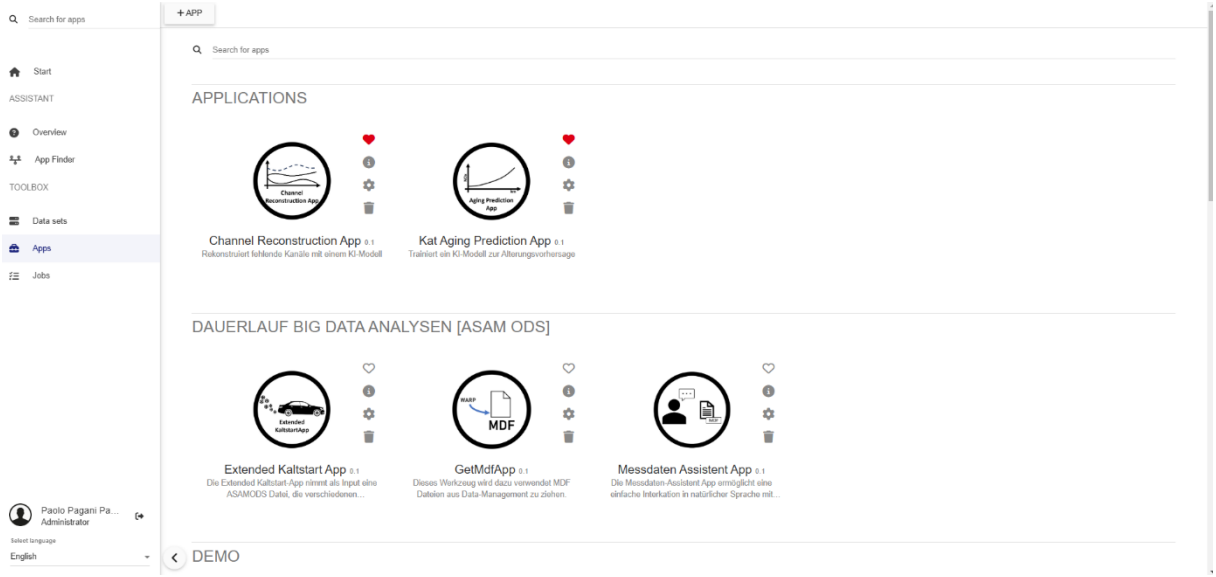

Abbildung 19: Data Science Toolkit

Die DaSense Data Management Umgebung soll dem Nutzer einen Überblick über die vorhandenen Daten verschaffen. Dazu sollen zum einen die Daten organisiert werden und zum anderen gesichtet und angereichert werden können.

Die DaSense Data Analytics Umgebung soll dem Nutzer ermöglichen, die gesichteten Daten mit modernen Big Data- und KI-Technologien auszuwerten. Dazu können die Daten in sogenannten Datensätzen verwaltet werden und in einem ersten Schritt über Jupyter Notebooks mit Clusteranbindung analysiert werden. Um auch Nicht-Programmierer in die Lage zu versetzen, bestimmte Analysen wiederholt durchzuführen, können diese Jupyter Notebooks mit Hilfe eines SDKs in eine „App“ mit grafischer Oberfläche überführt werden.

Im Folgenden werden konkrete Projektergebnisse näher beschrieben:

<u>Metadaten Anreicherung mit Informationen aus mf4 Daten</u>

In der DaSense App wurden Features entwickelt, die die Anreicherung der Metadaten der MF4-Dateien ermöglichen. Die Metadaten werden beim Ingest als Facetten den Dateien zugewiesen, sodass es möglich ist, die Messdaten nach bestimmten Kriterien zu filtern (z. B. alle Dateien, in denen bestimmte Messkanäle vorhanden sind).

Die angereicherten Daten können in verschiedene Kategorien gruppiert werden:

- Straßentyp (Stadt, Landstraße, Autobahn) anhand der durchschnittlichen Geschwindigkeit
- Fahrzeug-ID (z. B. Sprinter oder Kadjar)
- Vorhandene Kanäle
- Durchschnittliche Geschwindigkeit
- GPS-Koordinaten
- usw.

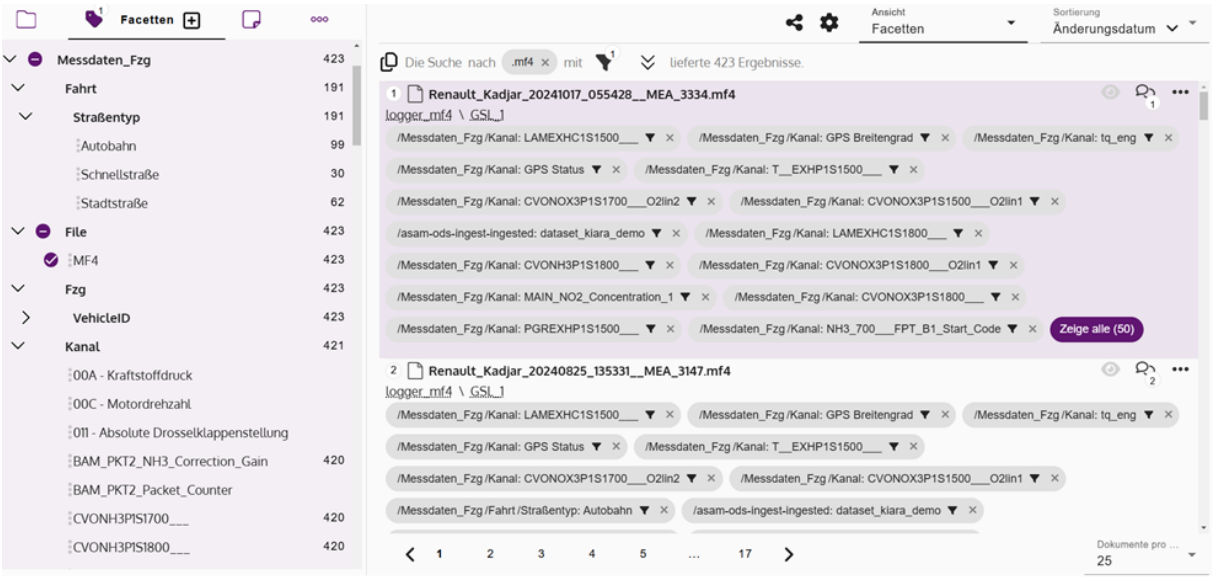

Abbildung 20: Mit Metadaten angereicherte Messdaten in DaSense

Zusätzlich kann die Fahrstrecke dank einer beim Ingest erstellten GPS-Karte visualisiert werden, die der Benutzer öffnen kann.

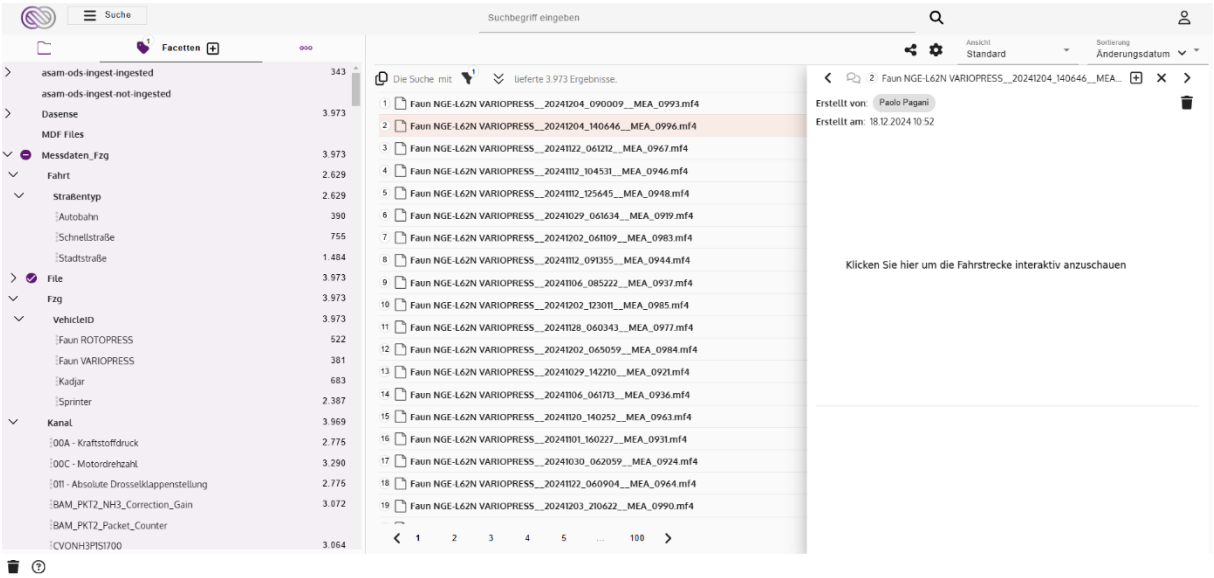

Abbildung 21: Suche in den Messdaten und Visualisierung der Fahrstrecke

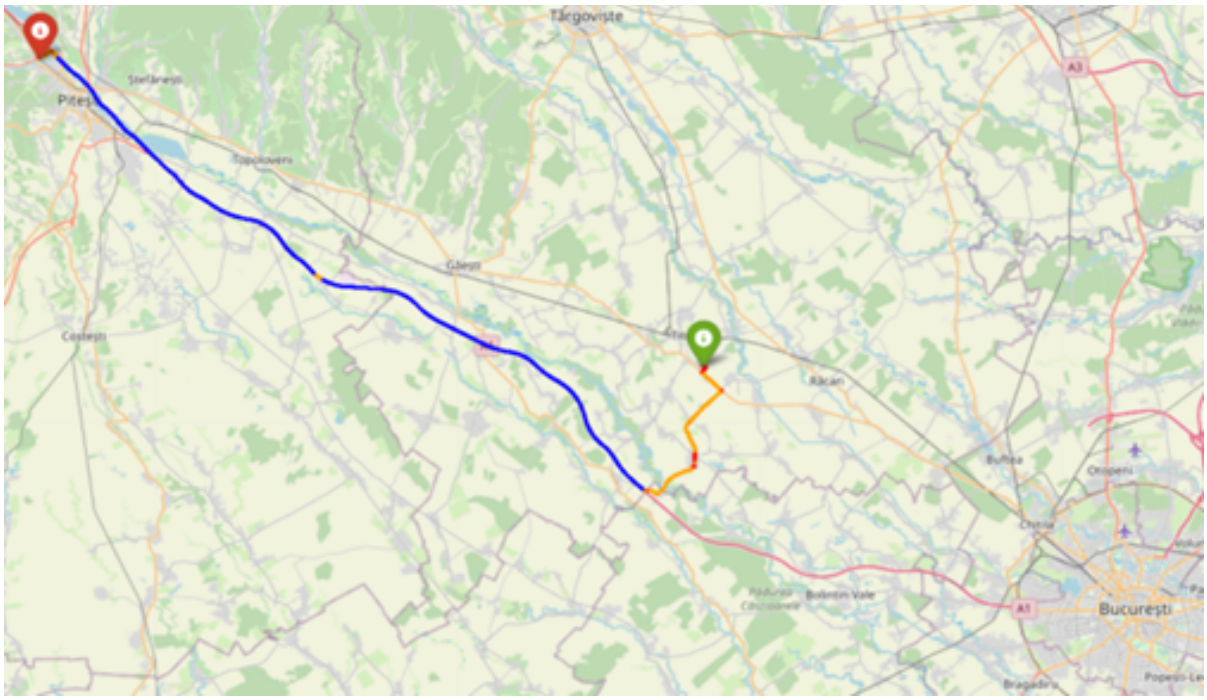

Abbildung 22: Visualisierung der Fahrstrecke

II.1.6.1 Entwicklungsumgebungen

Jupyter Notebook

Für die initiale Datenanalyse und das Prototyping wurde das Jupyter Notebook innerhalb der DaSense-Analytics-Plattform genutzt. Im Rahmen des KIARA-Projekts wurde diese Umgebung speziell für den Anwendungsfall der Alterungsanalyse angepasst. Die Anpassungen umfassten die Optimierung der Schnittstelle zum Datenmanagement sowie die Anbindung an die GPU für das Training.

DaSense SDK

Im Rahmen des KIARA-Projekts wird das DaSense SDK zur Erstellung von Applikationen verwendet. Diese Funktionalität ermöglicht es Entwicklern, schnell Anwendungen aus vorgefertigten Vorlagen zu

erstellen. Im Zuge des KIARA-Forschungsprojekts wurde das DaSense SDK weiterentwickelt und stabilisiert. Besondere Arbeiten konzentrierten sich auf die Optimierung der Schnittstelle zwischen der Eingabemaske und der Applikationslogik sowie auf die reibungslose Integration mit dem Datenmanagement. Darüber hinaus wurden Maßnahmen zur Verbesserung der Ergonomie der Ergebnisseite umgesetzt.

ASAM-ODS Utils und DaSense DSL

Für eine performante Verarbeitung der Fahrzeugdaten wurde zunächst die ASAM-ODS-Utils-Bibliothek von NorCom verwendet. Diese Bibliothek konvertiert Sensordaten im MF4-Format in ein big-data-konformes Format, das eine parallele Verarbeitung mit Apache Spark ermöglicht. Das zugrunde liegende Format (ASAM-ODS Format) entspricht dem ASAM-Standard (9). Für die Verarbeitung der Daten in ASAM-ODS Format wurde NorComs Bibliothek DSL verwendet. Konkret werden mithilfe diesem Bibliothek Ereignisse (z. B. stationäre Bereiche) extrahiert, deren Parameter in Abstimmung mit den Projektpartnern festgelegt werden. Im Rahmen des Projekts führte NorCom Arbeiten zur Sicherstellung der Stabilität der Bibliotheken durch und passte diese an die Anforderungen von KIARA an.

Erweiterung der Entwicklungsumgebung für KI-Algorithmen

Im Rahmen des Projekts wurde die Plattform in Microsoft Azure Cloud installiert und mit dem entsprechenden Cluster dort angebunden. Für Trainingszwecke wurden zusätzlich GPU-Instanzen (Cloud und On-Prem angebunden) an die Plattform angebunden.

Für ein Arbeiten ohne externen Cluster wurde ein sogenannter Standalone Cluster-Typ eingeführt, der Berechnungen intern ausführt und bei kleineren Rechenlasten ausreichend ist. Dadurch können insbesondere in der Cloud Kosten gespart werden.

Für einen schnellen und stabilen Datenzugriff speziell im Rahmen des KIARA-Projekts über die Entwicklungsumgebung (z.B. Jupyter Notebook) wurde das aktuelle Framework (PyEagle) für die Interaktion mit Data-Management und auch DM-Abstraktionsstrukturen (Facetten) überarbeitet und erweitert.

Eine GPU ist erforderlich, um das Training von Modellen auf Basis neuronaler Netzwerke zu ermöglichen. NorCom entwickelt die notwendige Schnittstelle zur Erstellung eines solchen Modells. Dies umfasst unter anderem die Einrichtung und Konfiguration einer GPU-Trainingsumgebung, die Entwicklung von Modulen zum Modelltraining sowie die Implementierung von Modulen zur Protokollierung des Experimentverlaufs in MLFlow. Weiter werden in DaSense die Möglichkeit zur GPU-Anbindung von Jupyter-Notebook und Apps realisiert, sodass einwandfreies Arbeiten mit Neuronalen Netzwerke für Plattformnutzer ermöglicht werden.

II.1.6.2 Entwickelte Apps

DataScreening-App

Für den ersten Datenüberblick durch den Plattformnutzer hat NorCom eine App zur Datenüberprüfung entwickelt. Der DM-Nutzer kann die zu prüfenden Datensätze auswählen und an die App übermitteln. Diese analysiert die Dateien auf Datenlücken, Abtastraten sowie fehlende Kanäle. Zusätzlich besteht die Möglichkeit, Bedingungen für unplausible Daten in Form von Schwellwerten festzulegen. Anhand dieser Vorgaben identifiziert die App Stellen, an denen die Daten als unplausibel einzustufen sind. Im Folgenden wird exemplarisch die Ergebnisseite der App vorgestellt:

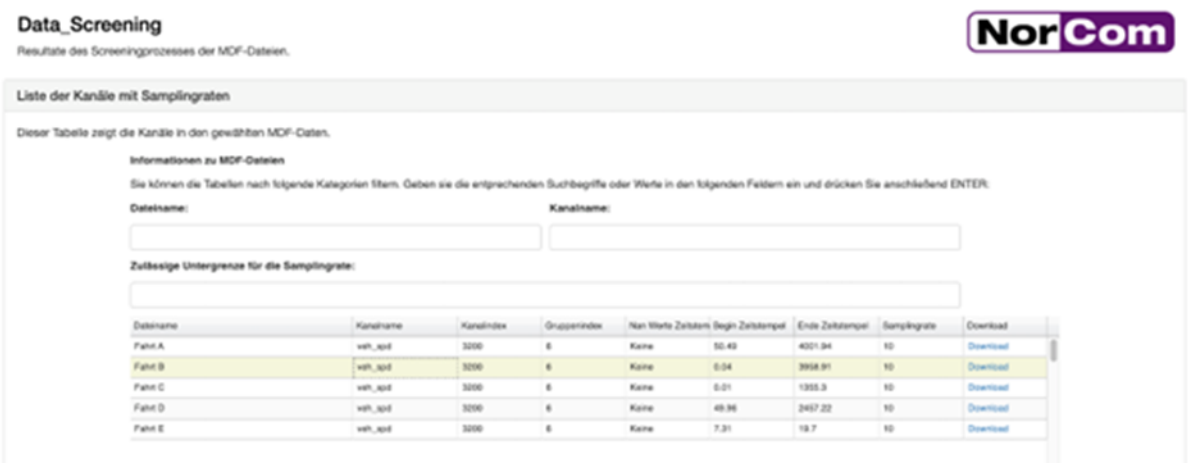

Abbildung 23: DataScreening App - Ergebnisseite

Histogramm-App

Im Rahmen des Projekts hat NorCom eine App entwickelt, die Daten mithilfe von Histogrammen auswertet. Die Anwendung ermöglicht einen ersten Überblick über die Daten, unterstützt die Überprüfung ihrer Plausibilität und liefert erste Hinweise zur Identifikation von Alterungsmerkmalen. Als Eingabe dienen die im Data Management gespeicherten Daten. Als Ergebnis werden die Zeitreihen und Histogramme gegenübergestellt. Im Folgenden wird exemplarisch die Ergebnisseite der App dargestellt:

Abbildung 24: Histogramm-App Ergebnisseite

Zur Erstidentifikation von Alterungsmerkmalen kann beispielsweise die Histogrammdarstellung herangezogen werden. Kanäle, bei denen sich signifikante Unterschiede zwischen gealterten und nicht gealterten Fahrzeugen zeigen, liefern wertvolle Hinweise auf Alterungsprozesse und sollten weitergehend analysiert werden.

MDF Ingest App

Sobald die Daten in DaSense anhand von Metadaten gefiltert und ausgewählt wurden, kann man sie mit der MDF Ingest App in einen Datensatz in Parquet Format umwandeln.

Das kann man in 4 Schritten machen:

1. (Leeren) Datensatz im Data Science Toolkit erstellen
2. Gefilterte Dateien in Data Management auswählen
3. Mit dem SendTo Button die Daten an die MDF Ingest App schicken
4. Den Job der MDF Ingest App starten

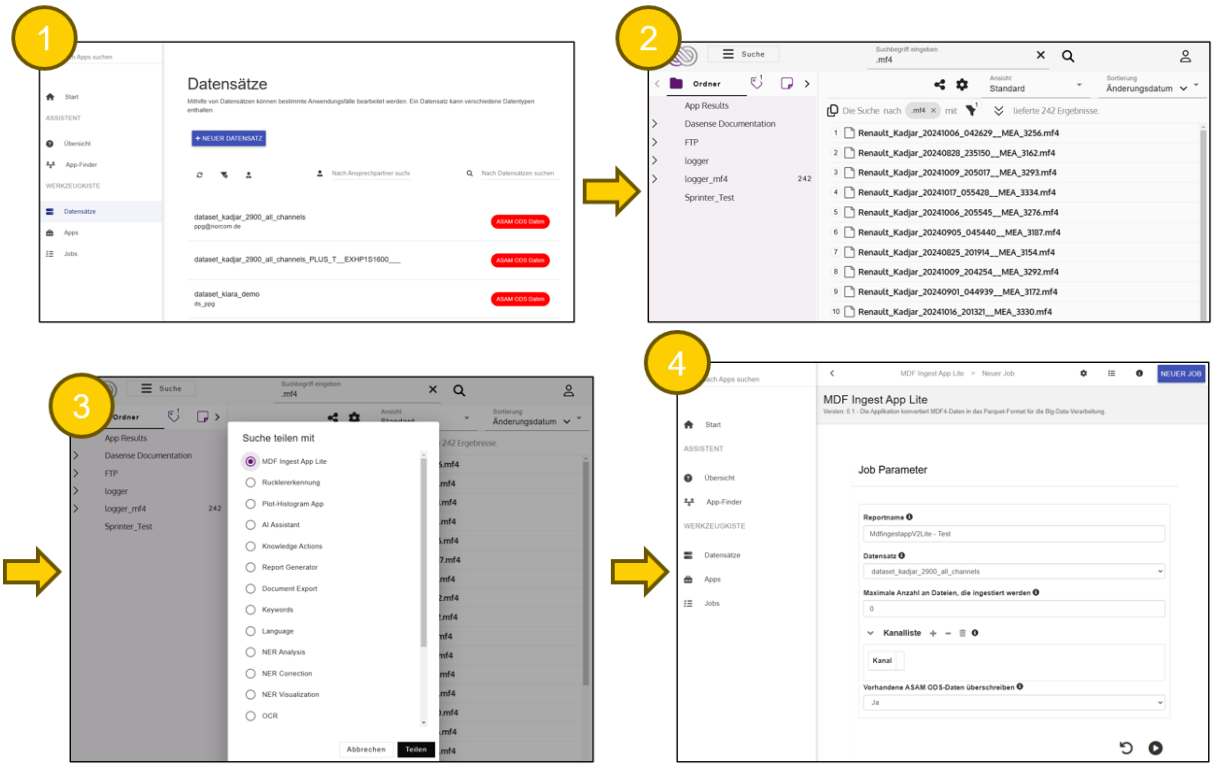

Abbildung 25: Workflow der MDF Ingest App

Die Datensätze kann man anschließend mit verschiedenen im Rahmen des Projekts entwickelten Apps verwenden, um dank der Big Data Format schnelle Datenverarbeitungen und Analysen durchzuführen.

Kanalergänzungsapp

Mit der Kanalergänzungsapp kann man fehlende Kanäle in dem Datensatz rekonstruieren. Bei Messdaten fehlen oft ganze Kanäle wegen Ausfällen von Sensoren oder falsche Übertragung der Datei. Diese App hilft, mit einem Machine Learning Verfahren, die fehlenden Kanäle anhand der vorhandenen Kanäle zu rekonstruieren.

Um eine Rekonstruktion der Kanäle zu starten, muss man in der entsprechenden Eingabemaske die folgenden Parameter eingeben:

- Den zu rekonstruierenden Datensatz
- Die Art von Fahrzeug
- Die fehlenden Kanäle
- Der Kanal, aus dem die Zeitstempel übernommen werden
- Die Anzahl an Experimenten für das Hyperparameter-Tuning

Abbildung 26: Eingabemaske der Kanalergänzung App

Als Ergebnis bekommt man einen neuen ergänzten Datensatz und eine Übersicht über die Rekonstruktion der Daten.

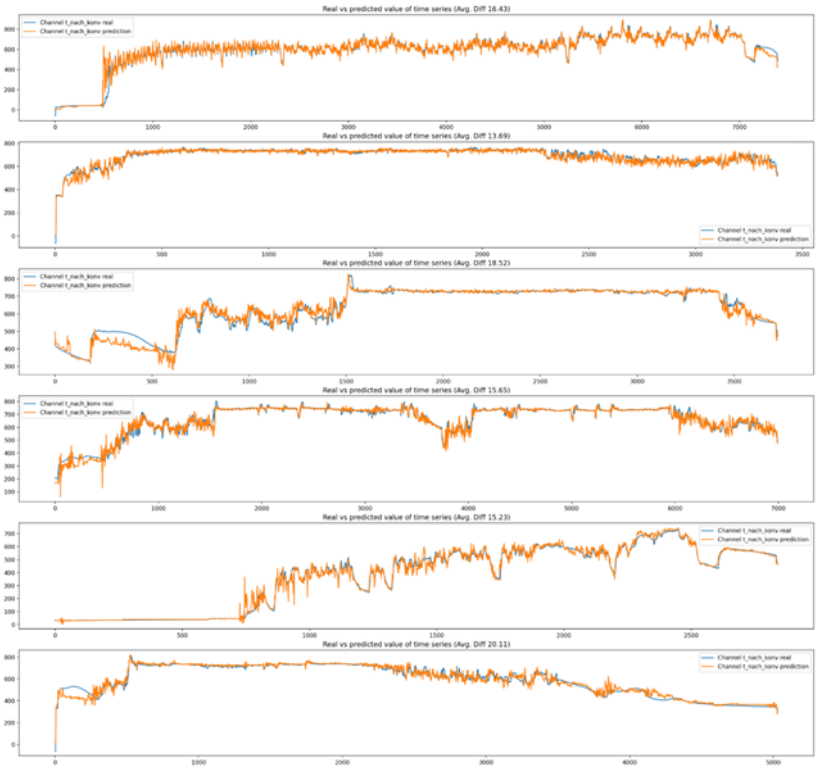

Abbildung 27: Ergebnisseite der Kanalergänzung App – rekonstruierte Kanäle

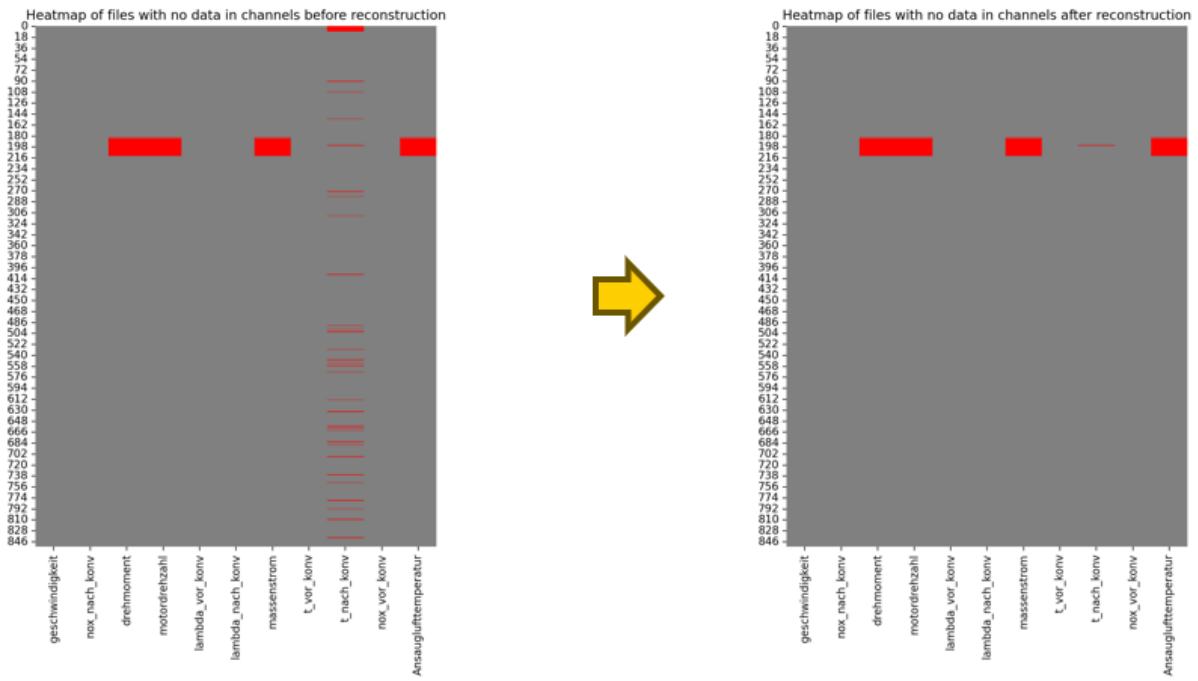

Abbildung 28: Ergebnisseite der Kanalergänzung App – Übersicht über die rekonstruierten Kanäle

Alterungsvorhersage App

Die Alterungsvorhersage App dient zur Visualisierung des Alterungsprozesses des Katalysators und zur Bestimmung der Alterungsfaktoren, die am meisten zur Alterung beigetragen haben.

Der Benutzer muss die folgenden Daten in einer Eingabemaske eintragen:

- Name des Datensatzes als Datenquelle
- Art des Fahrzeuges (Kadjar, Sprinter, …)
- Bedingungen für die stationären Segmente (für die Berechnungen der NOx-Werte)
- Parameter zur Segmentierung der Sliding Windows für die Erstellung der Trainingsdaten
- Parameter für die Erstellung der Vergangenheitsfeatures (Anzahl an Cluster für bestimmte Größen, z.B. niedrige, mittlere, hohe Werte für Durchschnittliche Geschwindigkeit in den Trainingsdaten).
- Parameter fürs Training (Training/Testaufteilung, Anzahl der Experimente für die Hyperparameteroptimierung).

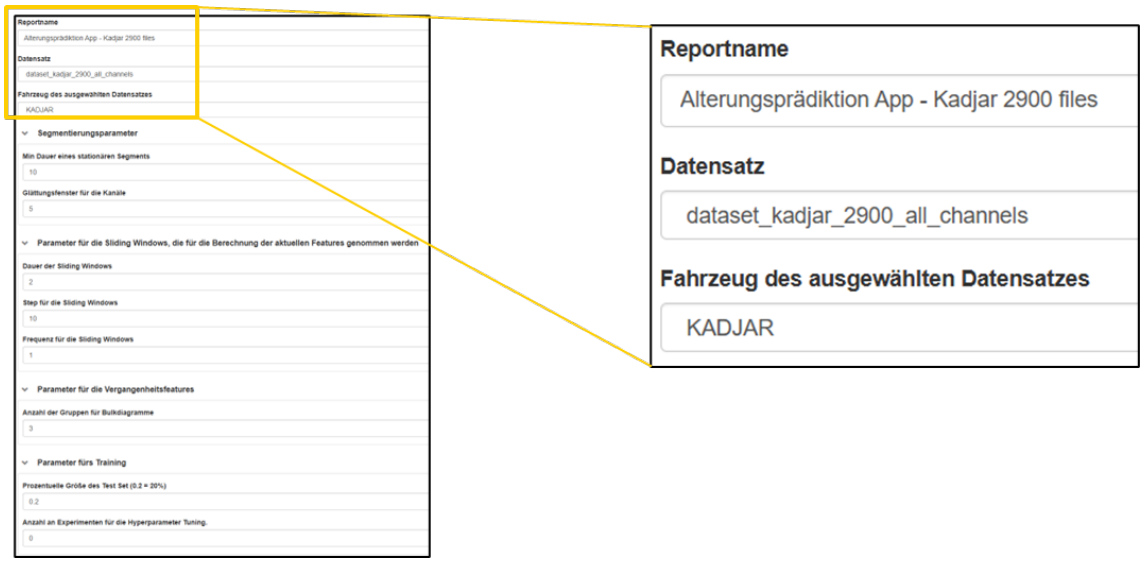

Abbildung 29: Eingabemaske der Alterungsvorhersage App

Als Ergebnis liefern die App verschiedene Information und Visualisierungen über den Alterungsprozess und die wichtigsten Alterungsfaktoren.

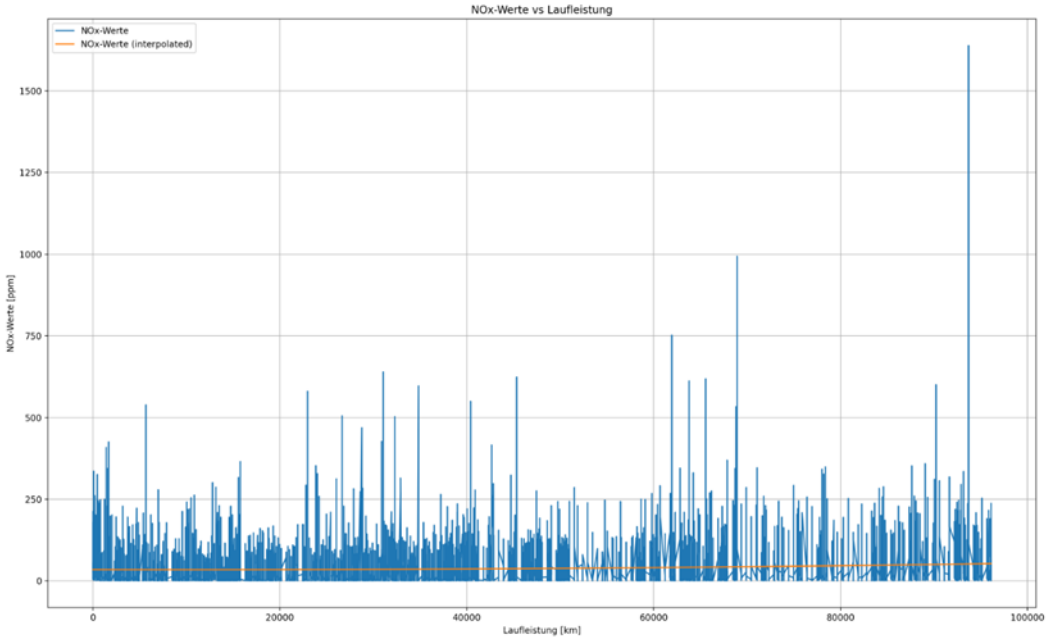

Abbildung 30: Ergebnisseite der Alterungsvorhersage App – Steigende NOx-Werte

Weitere Ergebnisse der App kann man im Kapitel II.1.5 zu sehen.

II.1.7 Zusammenfassung - Technisch- wissenschaftliche Ergebnisse

Das Projekt zielte darauf ab, ein KI-Modell zur Prädiktion der Alterung von Abgasnachbehandlungssystemen zu entwickeln. Zu Beginn wurde eine Fahrzeugflotte definiert, die ein möglichst breites Einsatzspektrum abdeckte, um eine repräsentative Datengrundlage zu schaffen. Die Fahrzeuge wurden mit spezieller Messtechnik ausgestattet, um das Verhalten der Abgasnachbehandlungssysteme detailliert analysieren und beschreiben zu können.

Die erfassten Daten wurden aufbereitet und für das Training des KI-Modells vorbereitet. Dabei wurden im Vorfeld zentrale Faktoren identifiziert, die das Alterungsverhalten maßgeblich beeinflussen. Das

Modell wurde gezielt auf diese Faktoren trainiert, um eine präzise und praxisnahe Prädiktion zu gewährleisten. Auf Basis dieser Erkenntnisse konnte zudem ein Prüfstandszyklus entwickelt werden, der ein beschleunigtes und gleichzeitig feldnahes Altern von Katalysatoren ermöglicht.

Ein weiterer Schwerpunkt des Projekts lag auf der Evaluierung und Implementierung von Methoden zur Integration des entwickelten KI-Modells in die Prüfstandsautomatisierung. Diese Integration unterstützt die Forschung und Entwicklung von Abgasnachbehandlungssystemen, indem sie die Alterungseffekte effizient analysierbar macht und so zur Optimierung der Systeme beiträgt.

Durch die Kombination aus praxisnaher Datenerhebung, gezieltem KI-Training und innovativer Prüfstandsintegration leistet das Projekt einen wichtigen Beitrag zur Weiterentwicklung emissionsmindernder Technologien.

II.2 Eingehende Darstellung der wichtigsten Positionen des zahlenmäßigen Nachweises

Die zahlenmäßigen Nachweise werden gesondert zur Verfügung gestellt.

II.3 Eingehende Darstellung der Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die Vorgaben zur Reduzierung von Emissionen sowohl der Schadgase als auch von Treibhausgasen stellen Hersteller und Zulieferer von Fahrzeugen mit Verbrennungsmotoren vor große Herausforderungen. Eine wichtige Rolle bei der Vermeidung von Emissionen spielt das Alterungsverhalten der Abgasnachbehandlungssysteme und Katalysatoren. Im Projekt „KIARA“ sollen Alterungsmuster von Abgasnachbehandlungssystemen im Realbetrieb über den Lebenszyklus der Fahrzeuge mit Hilfe von künstlicher Intelligenz – „KI–Methoden“ – detektiert, analysiert und Lösungen für die Reduzierung der Alterung erarbeitet werden. Dieser Ansatz zur Problemlösung ist noch sehr neu und es kann noch nicht sicher vorhergesagt werden, ob er letztendlich erfolgreich sein wird. Zur Erreichung der hohen Anforderungen an die Einsatzfähigkeit, Zuverlässigkeit, Lebensdauer und Wirtschaftlichkeit sowie die Einhaltung zukünftiger Emissionsgrenzwerte ist erheblicher Entwicklungsaufwand im Bereich der Abgasnachbehandlungssysteme erforderlich. Dieser ist mit einem großen finanziellen Risiko für die Unternehmen verbunden. Weltweit sind auch noch verschiedene andere Konzepte für Fahrzeuge mit reduzierten CO2-Emissionen in der Entwicklung, wie zum Beispiel reine Batteriefahrzeuge oder Brennstoffzellenfahrzeuge. Daher besteht durchaus noch ein Risiko bezüglich des zukünftigen Marktanteils der Fahrzeuge mit Verbrennungsmotor. Nur mit Hilfe der Zuwendung des Bundes kann dieses Risiko auf ein Maß reduziert werden, dass überhaupt erst die Durchführung eines gemeinsamen Entwicklungsprojektes unter Einbeziehung aller wichtigen Partner und Kompetenzen in diesem Bereich ermöglicht.

II.4 Eingehende Darstellung des voraussichtlichen Nutzens, insbesondere der Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplan

- NorCom hat durch die Mitarbeit an KIARA Lösungskompetenz und Erfahrung bezüglich Analyse von Alterungsprozessen gewonnen und kann sein Consultingangebot erweitern.
- NorCom plant die in KIARA erarbeiteten Konzepte innerhalb der Daten- und Analyse Plattform DaSense seinen Kunden zur Verfügung zu stellen. Zum Beispiel wird NorCom die Konzepte zu KI-gestützte Analysen von Messdaten entlang der Datenwertschöpfungskette auf der Daten- und Analyseplattform DaSense zur Anwendung zu bringen und damit Kunden aus der Automobilindustrie aber auch aus anderen Bereichen einen Mehrwert bieten.

- Ein weiteres Beispiel ist die Realisierung von skalierbaren Daten- und Analyseninfrastrukturen nach dem Beispiel des Alterungserkennung und -analyse, was sich auch in andere Anwendungsbereiche übertragen lässt.

II.5 Eingehende Darstellung des während der Durchführung des Vorhabens dem ZE bekannt gewordenen Fortschritts auf dem Gebiet des Vorhabens bei anderen Stellen

Im Projektzeitraum wurden zwei Veröffentlichungen anderer Stellen durchgeführt. Beiden hatten keinen Einfluss auf das Projekt Kiara.

- Yao, D., Hu, X., Wu, F., Li, X., & Li, Y. (2023). Hydrothermal Aging Mechanism and Modeling for SCR Catalysts. *ACS Omega*, 8, 2421 - 2434. https://doi.org/10.1021/acsomega.2c06902.

- Rama Krishna Dadi and Rohil Daya and Ashok Kumar and Saurabh Y. Joshi and Hongmei An and Michael J. Cunningham and Neal W. Currier and Aleksey Yezerets (2021). A modeling and experimental study on hydrothermal aging deactivation of NO oxidation activity on Pt-Pd catalyst. Applied Catalysis B: Environmental Vol. 283. https://doi.org/10.1016/j.apcatb.2020.119655

II.6 Eingehende Darstellung der erfolgten oder geplanten Veröffentlichungen des Ergebnisses nach Nr. 11

Folgende Veröffentlichungen des Projektergebnisses sind bereits erfolgt:

[1] Conin, Michael; Stalp, Alexander; Hummel, Nicolas; Beidl, Christian; Schmidt, Lukas; Tampubolon, Ezra; Tomanik, Christian;
Heintzel, A. (Hrsg.) (2024): Entwicklung eines KI-Modells zur Prädiktion von Alterungseffekten an Emissionsminderungssystemen.
In: Experten-Forum Powertrain: Komponenten und Kompetenzen zukünftiger Antriebe 2022. Band 2, Simulation und Test, S. 127-136, Wiesbaden, Springer Vieweg, Experten-Forum Powertrain, Hanau, 09.11.2022-10.11.2022, ISSN 2198-7432, e-ISSN 2198-7440, ISBN 978-3-658-42940-9, DOI: 10.1007/978-3-658-42940-9_10, Konferenzveröffentlichung

[2] Stalp, Alexander: Enhancing OBD with AI: Virtual NOx sensor for gasoline engines (2024). In: 2024 SAE On-Board Diagnostics Symposium-Americas

Folgende Veröffentlichungen des Projektergebnisses sind in Planung

[3] Dissertation Alexander Stalp: „Entwicklung einer Alterungsprediktion von Abgasnachbehandlungssystemen mittel künstlicher Intelligenz“

[4] Stalp, Alexander; Weimer, Niko; Beidl, Christian: AI-Driven Virtual NOx Sensor for Gasoline Engines: A Cost-Effective Path to Cleaner Emissions; in 2025 Stuttgart International Symposium

III. Literaturverzeichnis

1. *A rate mapping approach for the efficient implementation of detailed surface chemistry into monolith reactor models.* **Votsmaier, M.** Zürich : s.n., 2008. 7th International Workshop on Catalytic Combustion and Future Concepts in Energy Related Catalysis.

2. *Efficient Implementation of Detailed Surface Chemistry into Technical Reactor Models.* **Votsmaier, M.** Karlsruhe : s.n., 2008. ProcessNet Jahrestagung.

3. *Efficient representation of chemical rate information for reactor design simulations.* **Votsmaier, M.** Würzburg : s.n., 2008. Jahrestreffen Reaktionstechnik.

4. **Kluin, Matthias.** *Durchgängige modellbasierte Methoden zur Entwicklung vernetzter Betriebsstrategien für ottomotorische Hybridantriebe.* s.l. : Shaker Verlag, 2015.

5. *Some Methods for classification and Analysis of Multivariate Observations.* **MacQueen, J. B.** s.l. : University of California Press, 1967. Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability. Bd. 1.

6. *Random Forests.* **Breiman, L.** 2001, Machine Learning, Bd. 45.

7. *A Unified Approach to Interpreting Model Predictions.* **Lundberg, S. und Lee, S.** 2017, Advances in Neural Information Processing Systems, Bd. 30.

8. **https://xgboost.readthedocs.io/en/stable/. [Online]**

9. https://www.asam.net/standards/detail/ods/. [Online]