

# Schlussbericht

## PANAMERA: Entwicklung eines Predictive Maintenance Baukastens für Automotive Applikationen mittels Fahrzeug-Flottendatenanalyse

<b>Zuwendungsemfänger Vorhaben</b>	Technische Universität München PANAMERA: Entwicklung eines Predictive Maintenance Baukastens für Automotive Applikationen mittels Fahrzeug-Flottendatenanalyse
<b>Förderkennzeichen</b>	19I21016F
<b>Laufzeit des Vorhabens</b>	01.07.2021 — 30.09.2024
<b>Projektleitung</b>	Univ-Prof. Dr. Constantinos Antoniou
<b>Autoren</b>	M.Eng. Cheng Lyu, Dr.-Ing. Qing-Long Lu, Univ-Prof. Dr. Constantinos Antoniou
<b>Institution</b>	Lehrstuhl für Vernetzte Verkehrssysteme, TUM School of Engineering and Design, Technische Universität München



**Finanziert von der  
Europäischen Union**  
NextGenerationEU

Gefördert durch:



Bundesministerium  
für Wirtschaft  
und Klimaschutz

aufgrund eines Beschlusses  
des Deutschen Bundestages

# Inhaltsverzeichnis

<b>I</b>	<b>Kurze Darstellung</b>	<b>4</b>
1	Aufgabenstellung . . . . .	4
2	Voraussetzungen . . . . .	5
3	Planung und Ablauf des Vorhabens . . . . .	5
4	Wissenschaftlichem und technischem Stand . . . . .	6
5	Zusammenarbeit mit anderen Stellen . . . . .	7
<b>II</b>	<b>Eingehende Darstellung</b>	<b>8</b>
1	Verwendung der Zuwendung und erzielte Ergebnisse . . . . .	8
1.1	Stand der Technik und Forschung . . . . .	8
1.1.1	Prozessmodelle . . . . .	8
1.1.2	Predictive Maintenance Modelle . . . . .	10
1.2	Überblick über die Modellentwicklung . . . . .	11
1.3	Use Case: Bremsgeräusche . . . . .	15
1.3.1	Hintergrund . . . . .	15
1.3.2	Problemformulierung . . . . .	15
1.3.3	Automatische Kennzeichnung: Spektrogramm-Faktorisierung . . . . .	18
1.3.4	Bremsgeräuschklassifikation: Traditionelle Machine-Learning- und Deep-Learning-Ansätze . . . . .	23
1.4	Use Case: Sonderereigniserkennung . . . . .	32
1.4.1	Hintergrund . . . . .	32
1.4.2	Problemformulierung . . . . .	35
1.4.3	Datenanalyse & Vorverarbeitung . . . . .	35
1.4.4	Vorläufiges Modell: Autoencoder basierend auf Temporal Convolutional Network . . . . .	39
1.5	Use Case: Spur/Sturz . . . . .	41
1.5.1	Hintergrund . . . . .	41
1.5.2	Problemformulierung . . . . .	41
1.5.3	Datenanalyse und ein lineares Modell . . . . .	43
2	Wichtigste Positionen des zahlenmäßigen Nachweises . . . . .	45
2.1	Personalausgaben (0812) . . . . .	45
2.2	Dienstreisen (0846) . . . . .	45

---

3	Notwendigkeit und Angemessenheit der geleisteten Arbeit . . . . .	46
3.1	Notwendigkeit der einzelnen Arbeitspakete . . . . .	46
3.2	Angemessenheit der Arbeitspaketstruktur . . . . .	47
4	Voraussichtlicher Nutzen . . . . .	47
5	Fortschritte bei anderen Stellen . . . . .	48
6	Veröffentlichungen . . . . .	49
	<b>Abbildungsverzeichnis</b>	<b>50</b>
	<b>Tabellenverzeichnis</b>	<b>51</b>
	<b>Abkürzungsverzeichnis</b>	<b>52</b>
	<b>Literaturverzeichnis</b>	<b>54</b>

# I. Kurze Darstellung

## 1 Aufgabenstellung

Das Hauptziel des PANAMERA-Projekts ist die Entwicklung eines modularen Frameworks für Predictive Maintenance (PM)-Lösungen in Automobilanwendungen unter Nutzung der Flottendatenanalyse. Das Projekt zielt darauf ab, die Entwicklung von PM-Lösungen für Fahrzeugkomponenten zu beschleunigen und kostengünstiger zu gestalten, während gleichzeitig hohe Qualitätsstandards eingehalten werden. In diesem Projekt spielt die Technische Universität München (TUM) eine zentrale Rolle, insbesondere bei der iterativen Entwicklung und Validierung von Machine Learning (ML)-Modellen für Predictive Maintenance. Die Beiträge der TUM konzentrieren sich auf AP 6 (Entwicklung der Verschleißmodelle) und AP 7 (Demonstration und Bewertung), mit zusätzlicher Unterstützung in anderen APs, darunter AP 1 (Unterstützung bei der Charakterisierung von Anforderungen für Daten und Framework), AP 2 (Unterstützung bei der Entwicklung des PANAMERA-Referenzmodells), AP 3 (Unterstützung bei der Vorbereitung der Datenverarbeitungspipeline), AP 4 (Unterstützung bei der Entwicklung der Modellumgebung) und AP 5 (Zusammenarbeit bei der Entwicklung der Datenanalyse- und Berichtsplattform).

Im Speziellen leitete die TUM die Entwicklung von Verschleißmodellen für spezifische Fahrzeugkomponenten, wobei der Fokus auf den Anwendungsfällen der *akustischen Analyse der Bremsgeräusche* und *Verschleißmodellen im Zusammenhang mit Sturz* lag, und unterstützte die frühe Entwicklung des Verschleißmodells für den Anwendungsfall der *Anomalieerkennung von Sonderereignissen*. Diese Modelle wurden mit fortschrittlichen ML-Techniken entwickelt, darunter statistische Analyse und Deep-Learning-basierte Klassifikation, um Komponentenverschleiß und Restlebensdauer zu identifizieren. Die TUM trug auch zur Vorverarbeitung und Bewertung von Modellen bei, um sicherzustellen, dass die Modelle robust und auf verschiedene Eingaben anwendbar sind. Darüber hinaus arbeitete die TUM mit Konsortialmitgliedern zusammen, um die Definition von Framework-Komponenten zu unterstützen und die Wiederverwendbarkeit der entwickelten Module zu gewährleisten. Durch diese Beiträge half die TUM zusammen mit allen Konsortialmitgliedern, ein flexibles modulares Framework für Predictive Maintenance in der Automobilindustrie zu etablieren, mit Fokus auf praktische, datengetriebene Lösungen.

## 2 Voraussetzungen

Der Lehrstuhl für Vernetzte Verkehrssysteme an der TUM unterstützt die erfolgreiche Implementierung des PANAMERA-Projekts mit seiner Expertise in der ML-Algorithmusentwicklung mit Fokus auf verkehrsbezogene Anwendungen. Die Erfahrung in der Anwendung von ML-Techniken auf komplexe Datensätze, insbesondere in Fahrzeugsystemen und Verkehrsanalyse, bietet eine Grundlage für die Anpassung dieser Methoden an Predictive Maintenance in Automobilanwendungen.

Die Erfahrung in der Verarbeitung und Analyse großer Datensätze, einschließlich Fahrzeugsensordaten, kann die Handhabung hochfrequenter und umfangreicher Daten aus Flottenoperationen erleichtern. Dies umfasst die Entwicklung von Methoden zur Datenvorverarbeitung und Feature-Extraktion. Kenntnisse in fortgeschrittenen ML-Techniken wie Regressionsanalyse, Klassifikation, Clustering und Anomalieerkennung können zum Aufbau von Prädiktionsmodellen für Komponentenverschleiß und Ausfallvorhersage beitragen. Darüber hinaus zeigt die vorherige Erfahrung in kollaborativen Forschungsprojekten ein Verständnis für interdisziplinäre und Industrie-Akademie-Partnerschaften. Dies kann eine effektive Zusammenarbeit innerhalb des PANAMERA-Konsortiums unterstützen. Der Fokus auf praktische Anwendungen von ML kann dazu beitragen, dass die entwickelten Modelle sowohl mit theoretischen Grundlagen als auch mit den praktischen Anforderungen der Automobilindustrie übereinstimmen. Diese Voraussetzungen können eine Basis für die Entwicklung innovativer und praktischer Predictive-Maintenance-Lösungen innerhalb des PANAMERA-Projekts durch die Anwendung von ML-Expertise im Transportbereich bieten.

## 3 Planung und Ablauf des Vorhabens

Die Planung und Durchführung der Aufgaben der TUM im PANAMERA-Projekt waren an der Gesamtprojektstruktur ausgerichtet, wie in Abbildung I.1 dargestellt, mit Fokus auf die Entwicklung und Validierung von Predictive-Maintenance-Modellen. In der Anfangsphase unterstützte die TUM hauptsächlich andere Konsortialmitglieder bei der Definition und Charakterisierung der modularen Pipeline für Predictive-Maintenance-Lösungen. Sobald die notwendigen Daten verfügbar waren, verlagerte die TUM ihren Fokus wie geplant auf Modellentwicklung und -bewertung.

Allerdings wurde aufgrund von Herausforderungen verschiedener Art eine unerwartete dreimonatige kostenneutrale Verzögerung eingeführt. Die Herausforderungen für die TUM entstanden hauptsächlich durch einen Wechsel der Managementplattform bei Dr.-Ing. h.c. F. Porsche AG (PAG) und Probleme im Zusammenhang mit Datenzugriffsrechten. Diese Verlängerung ermöglichte es der TUM, diese Störungen zu bewältigen und die erfolgreiche Durchführung ihrer Aufgaben sicherzustellen, während die Ausrichtung an den Gesamtzielen des Projekts beibehalten wurde.

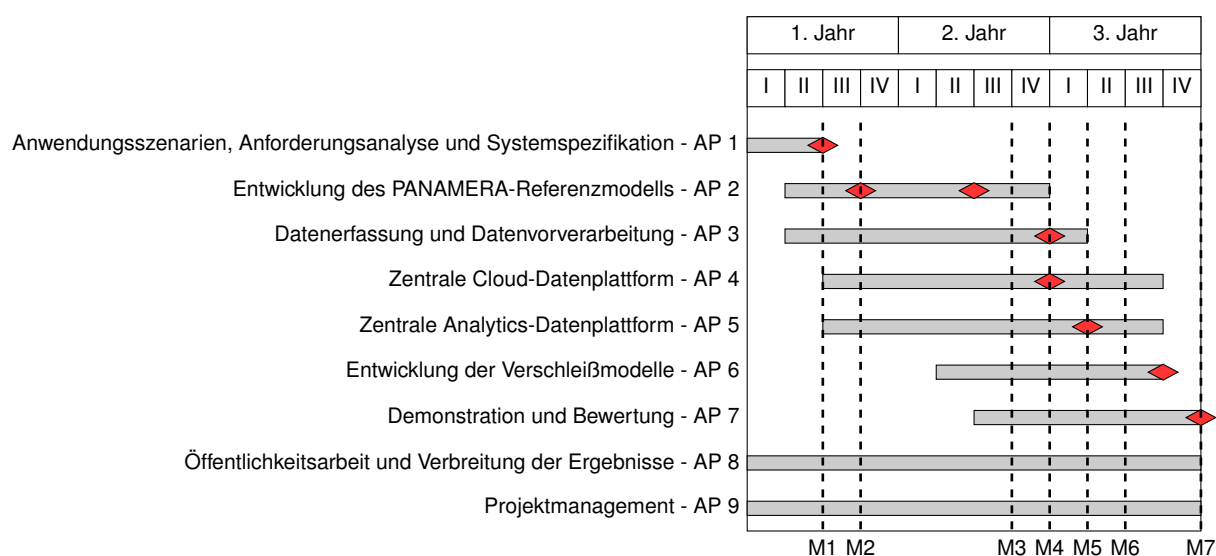


Abbildung I.1: PANAMERA Project Timeline

#### 4 Wissenschaftlichem und technischem Stand

Für Literaturrecherche und Dokumentation wurden mehrere wissenschaftliche Datenbanken genutzt: Web of Science<sup>1</sup>, DBLP<sup>2</sup>, Google Scholar<sup>3</sup>, ScienceDirect<sup>4</sup> und IEEE Xplore<sup>5</sup>. Diese Datenbanken boten umfassenden Zugang zu Peer-Review-Publikationen und aktuellen Preprints in den Bereichen Machine Learning, Automobilingenieurwesen und Predictive Maintenance. Die gefundene Literatur wurde mit Zotero verwaltet, einer Open-Source-Referenzmanagement-Software, die eine systematische Organisation und Zitierung von Forschungsmaterialien erleichtert.

Darüber hinaus wurde die Projektdokumentation und der Wissensaustausch zwischen den Konsortialpartnern über Confluence durchgeführt, eine kollaborative Dokumentationsplattform, die von Porsche bereitgestellt wurde und einen konsistenten und synchronisierten Zugriff auf Projektmaterialien für alle teilnehmenden Organisationen gewährleistete.

Zusammenfassend wurden 29 PM-bezogene Literaturquellen für die Modellentwicklung in diesem Projekt überprüft [1–29]. Außerdem wurden 18 Papiere zu Audio- und Signalverarbeitung für die Algorithmusentwicklung gefiltert, die verschiedene Themen wie Audio-Quellentrennung, automatische latente Feature-Extraktion und Audioklassifikation/-erkennung abdecken [30–47].

Für die Modellentwicklung basieren die Data-Engineering- und Data-Science-Komponenten

<sup>1</sup><https://www.webofscience.com/>

<sup>2</sup><https://dblp.org/>

<sup>3</sup><https://scholar.google.com/>

<sup>4</sup><https://www.sciencedirect.com/>

<sup>5</sup><https://ieeexplore.ieee.org/>

des PM-Toolkits in diesem Projekt hauptsächlich auf Python<sup>6</sup>, einer der beliebtesten Programmiersprachen für Datenverarbeitung und Machine Learning. Die Pipeline wurde hauptsächlich mit Kedro<sup>7</sup> erstellt, das ein standardisiertes Grundgerüst für den Aufbau modularer Workflows bietet, die produktionsreif sind und strukturierte Datenschnittstellen sowie Experiment-Tracking bietet. Datenspeicherung und -verwaltung basieren auf Spark<sup>8</sup> auf der Cloud-Plattform und werden über PySpark<sup>9</sup>-Schnittstellen zugegriffen.

Die methodischen Grundlagen dieses Projekts umfassen verschiedene lineare Faktorisierungsmethoden wie Independent Component Analysis (ICA) [48] und Nicht-negative Matrixfaktorisierung (NMF) [49]. Die Modelle für Anomalieklassifikation wurden auf der Grundlage relevanter Studien im Bereich der Audiotrennung und -erkennung [34, 39] entwickelt, die auf Convolutional Neural Network (CNN) und Transformern basieren.

## 5 Zusammenarbeit mit anderen Stellen

Während des gesamten Projekts pflegte die TUM eine intensive und produktive Zusammenarbeit mit allen Konsortialpartnern, darunter PAG, AMITRONICS Angewandte Mikromechatronik GmbH (AMI), Fraunhofer-Institut für Produktionstechnik und Automatisierung (IPA), areto consulting GmbH (areto) und ExxpertSystems GmbH (ExxpertSystems). Diese Zusammenarbeit umfasste sowohl organisatorische Koordination als auch inhaltliche Beiträge zu verschiedenen Projektthemen.

Die Partnerschaft mit PAG war für das Projekt zentral, da die TUM ihre Modellentwicklung und -bewertung an den Flottendaten und industriellen Anforderungen von PAG ausrichtete. Darüber hinaus arbeitete die TUM intensiv mit IPA an der Entwicklung von Predictive-Maintenance-Algorithmen und der Validierung von Verschleißmodellen, wobei sie von deren umfangreicher Erfahrung in industriellen Anwendungen profitierte. Mit AMI arbeitete die TUM eng an Themen im Zusammenhang mit Signalverarbeitung und akustischer Analyse, wobei sie deren Expertise in Strukturmechanik und Zustandsüberwachung nutzte. Die Zusammenarbeit mit areto konzentrierte sich auf Data Engineering und cloudbasierte Analytik, um die nahtlose Integration von Datenpipelines und Visualisierungstools zu gewährleisten. Die TUM arbeitete auch mit ExxpertSystems bei der Datenerfassung und -vorverarbeitung zusammen.

Es fand keine Zusammenarbeit mit externen Partnern außerhalb des Konsortiums statt. Insgesamt war die Zusammenarbeit durch klare Rollenverteilung, flexible Anpassungsfähigkeit und konstruktive Kommunikation gekennzeichnet, was trotz gelegentlicher Herausforderungen wie Wartezeiten und der Notwendigkeit, Arbeitsabläufe und Standards zu harmonisieren, Fortschritte ermöglichte.

---

<sup>6</sup><https://www.python.org/>

<sup>7</sup><https://kedro.org/>

<sup>8</sup><https://spark.apache.org/>

<sup>9</sup><https://spark.apache.org/docs/latest/api/python/index.html>

## II. Eingehende Darstellung

### 1 Verwendung der Zuwendung und erzielte Ergebnisse

#### 1.1 Stand der Technik und Forschung

In diesem Abschnitt fassen wir den aktuellen Forschungsstand im Bereich der Prozessmodelle und PM zusammen. Dies hilft, ein Verständnis für bestehende methodische Frameworks wie CRISP-DM und ASUM-DM sowie deren Anwendungen im Fahrzeug-PM aufzubauen. Die Übersicht dient mehreren Zwecken innerhalb von AP 1 und AP 2: Sie unterstützt die Charakterisierung von Datenanforderungen, unterstützt die Definition von Qualitätskriterien, identifiziert wesentliche analytische Techniken und formt die Grundlage unseres Referenzmodells. Durch die Untersuchung sowohl von Prozessmodellen als auch von domänenspezifischen Wartungsmethodologien etablieren wir eine umfassende Basis für die Entwicklung unseres maßgeschneiderten Ansatzes für Fahrzeug-PM.

##### 1.1.1 Prozessmodelle

Eine Übersicht über relevante Forschungs- und industrielle State-of-the-Art-Prozessmodelle wurde zusammengefasst, wie unten angegeben. Im Allgemeinen bieten Prozessmodelle systematische Frameworks für die Ausführung von Data-Science- und Machine-Learning-Projekten, die eine konsistente Methodologie, reproduzierbare Ergebnisse und effiziente Ressourcennutzung gewährleisten. Diese Modelle entstanden aus der Notwendigkeit, Datamining- und Analyseansätze über verschiedene Branchen und Anwendungsfälle hinweg zu standardisieren, und haben sich von traditionellen Datamining-Methodologien zu modernen Machine Learning Operations (MLOps)-Praktiken weiterentwickelt.

Die De-facto-Standards für industrielle Anwendungen von Prozessmodellen hängen hauptsächlich von den folgenden grundlegenden Prozessmodellen ab.

**Knowledge Discovery in Databases (KDD):** Der KDD-Prozess, eingeführt von Fayyad, Piatetsky-Shapiro und Smyth [50], stellt einen der frühesten systematischen Ansätze für Datamining dar. Dieses grundlegende Framework etablierte Kernprinzipien, die nachfolgende Methodologien beeinflussten. Die folgende Sequenz von Schritten wird definiert:

1. Auswahl

2. Vorverarbeitung
3. Transformation
4. Data Mining
5. Interpretation/Bewertung

**Cross Industry Standard Process for Data Mining (CRISP-DM):** Das Cross Industry Standard Process for Data Mining (CRISP-DM) [51] stellt eines der frühesten und am weitesten verbreiteten Frameworks dar. Die Stärke von CRISP-DM liegt in seinem domänenagnostischen Ansatz und der umfassenden Abdeckung des gesamten Projektlebenszyklus, mit sechs Schlüsselphasen:

1. Geschäftsverständnis
2. Datenverständnis
3. Datenvorbereitung
4. Modellierung
5. Bewertung
6. Bereitstellung

**SAS Sampling, Exploring, Modifying, Modeling, and Assessing (SEMMA):** Die Sampling, Exploring, Modifying, Modeling, and Assessing (SEMMA)-Methodologie des SAS Institute bietet einen alternativen Prozessablauf, der sich expliziter auf die technischen Aspekte von Datamining-Projekten konzentriert [52]. Während es in vielen Aspekten CRISP-DM ähnelt, legt SEMMA größeren Wert auf die statistischen und analytischen Komponenten des Prozesses.

**IBM Analytics Solutions Unified Method for Data Mining & Predictive Analytics (ASUM-DM):** IBMs Analytics Solutions Unified Method for Data Mining & Predictive Analytics (ASUM-DM) erweitert CRISP-DM durch die Integration moderner agiler Prinzipien und detaillierter Implementierungsanleitungen [53]. Das Framework fügt explizite Projektmanagement- und Deployment-Überlegungen hinzu, die in früheren Modellen fehlen.

**Microsoft Team Data Science Process (TDSP):** Der Team Data Science Process (TDSP), entwickelt von Microsoft, bietet eine moderne Interpretation von Prozessmodellen, die speziell auf Data-Science-Teams zugeschnitten ist [54]. Er betont kollaborative Entwicklung, Versionskontrolle und Reproduzierbarkeit – Aspekte, die in der zeitgenössischen Data-Science-Praxis zunehmend wichtiger geworden sind.

Darüber hinaus gibt es viele moderne Erweiterungen von Prozessmodellen. Beispielsweise schlugen Studer u. a. [55] Cross-Industry Standard Process model for Machine Learning with

Quality Assurance (CRISP-ML(Q)) vor, eine Erweiterung von CRISP-DM speziell für Machine-Learning-Anwendungen mit integrierter Qualitätssicherungsmethodologie. Zu den wichtigsten Innovationen gehören gleichzeitige Business- und Data-Understanding-Phasen, verstärkter Fokus auf Modellüberwachung und -wartung, systematische Qualitätssicherung im gesamten Lebenszyklus und explizite Berücksichtigung von ML-spezifischen Herausforderungen. Biecek [56] führten den Model Development Process (MDP) ein, der von der Software-Engineering-Methode Rational Unified Process inspiriert ist. Er betont mehrere Schlüsselaspekte: Er folgt iterativen Entwicklungszyklen, um kontinuierliche Verbesserung zu ermöglichen, verfolgt einen risikogetriebenen Ansatz zur Priorisierung kritischer Herausforderungen, behält architekturzentrierte Entwicklungspraktiken bei und implementiert kontinuierliche Qualitätsverifikation während des gesamten Prozesses, um robuste Ergebnisse sicherzustellen. Costa und Aparicio [57] entwickelten Process Organization and Scheduling electing Tools for Data Science (POST-DS), um Einschränkungen in bestehenden Methodologien durch prozessorientiertes Projektmanagement und Anleitungen zur Toolauswahl zu adressieren.

Einige Studien haben es geschafft, die Prozessmodelle an spezifische Anwendungskontexte anzupassen. Huber u. a. [58] schlugen das Data Mining Methodology for Engineering Applications (DMME) vor, eine Erweiterung von CRISP-DM für Ingenieurkontexte, die spezifische Überlegungen für Datenerfassung in Produktionsumgebungen, Integration mit physischen Systemen und ingenieurspezifische Qualitätssicherungsmaßnahmen hinzufügt. Welte, Estler und Lucke [59] entwickelten eine spezialisierte Methodologie für die Implementierung von Machine-Learning-Lösungen in kleinen und mittleren Unternehmen, die Ressourcenbeschränkungen und praktische Implementierungsherausforderungen adressiert, die spezifisch für kleinere Organisationen sind.

Die Entstehung von MLOps erweitert den konzeptuellen Rahmen, der von Prozessmodellen bereitgestellt wird, hin zur praktischen Implementierung. Kreuzberger, Kühl und Hirschl [60] definierten MLOps als den gesamten Machine-Learning-Lebenszyklus umfassend, einschließlich automatisierter Pipeline-Ausführung, kontinuierlicher Integration/Deployment, Modellüberwachungssystemen und Versionskontrollmechanismen. Eine der repräsentativen Implementierungen ist MLflow, eingeführt von Zaharia u. a. [61] als Plattform zur Optimierung des Machine-Learning-Lebenszyklus, mit einfacherem Experiment-Tracking, Modellmanagement und Ergebnisreproduzierbarkeit.

### **1.1.2 Predictive Maintenance Modelle**

Das Konzept des PM wurde bereits im 20. Jahrhundert für Industriemaschinen eingeführt [3]. Seine Anwendungen im Automobilbereich waren jedoch bis zum letzten Jahrzehnt nicht weit verbreitet, begrenzt sowohl durch die Rechenleistung an Bord als auch durch die Effizienz der drahtlosen Kommunikation. Aufgrund der Komplexität der Fahrzeugmechanik stützt sich der Großteil der Forschung zu Automobil-PM auf datengetriebene Methoden, mit Ausnahme einiger spezifischer Fälle wie der Batteriediagnose, wo physikalische Modelle möglich sind [7].

Basierend auf den Zielsetzungen können bestehende datengetriebene PM-Studien in vier Kategorien eingeteilt werden: Clustering, Ausreißererkenung, Klassifikation und Regression. Eine Sammlung der für das Projekt überprüften Papiere ist in Abbildung II.1 zusammengefasst.

Clustering und Ausreißererkenung sind beides unüberwachte Lernmethoden, die oft ohne klare Grenze dazwischen zusammen auftreten, und umfassen zwei Anwendungsszenarien, nämlich Flottenwarnung und Wartung einzelner Fahrzeuge. Ersteres überwacht die Sensordaten einer Fahrzeugflotte und identifiziert die Teilmenge problematischer Fahrzeuge durch Vergleiche innerhalb der Flotte. Beispielsweise verwendeten Byttner u. a. [17] und Rögnavaldsson u. a. [12] jeweils Histogramme und Gaussian Mixture Models, um Ausreißer aus der gewöhnlichen Datenverteilung zu finden. Im letzteren Fall wird Clustering normalerweise unabhängig davon durchgeführt, von welchem Fahrzeug die Daten stammen. Stattdessen werden Ausreißer auf Sample-Basis identifiziert [6].

Klassifikation ist das am umfassendsten untersuchte Problem im datengetriebenen PM, das die Fragen beantwortet, ob eine Komponente in naher Zukunft ausfallen wird oder in welchem Zustand sich eine Komponente derzeit befindet. Im Gegensatz zu Clustering und Ausreißererkenung entspricht die Klassifikation (halb-)überwachten Methoden, für die mindestens ein Teil der Samples markiert sein muss. Bestehende Studien unterscheiden sich hauptsächlich in Bezug auf Anwendungsfälle, Eingabedaten und Methoden. Die meisten klassifikationsbasierten PM-Systeme nutzen sequentielle Daten, die von Sensoren aufgezeichnet werden; daher folgen ihre methodischen Frameworks dem allgemeinen Arbeitsablauf von Feature-Engineering → Modellauswahl → Modelltraining → Modellevaluation. Einige haben es geschafft, Textdaten einzuführen, z.B. Garantiedaten [8], und visuelle Daten, z.B. Rauschspektrogramme [22].

Regression erweitert klassifikationsbasierte PM-Systeme weiter, indem sie beantwortet, wie lange eine Fahrzeugkomponente voraussichtlich ohne Ausfall weiterarbeiten wird, d.h. Restlebensdauer (RUL). Die Anwendungsfälle der RUL-Vorhersage drehen sich um den Ladezustand von Batterie/Brennstoffzelle [10, 19, 20] sowie die verbleibende Zeit bis zur Planung eines Komponentenaustauschs [2, 23].

## 1.2 Überblick über die Modellentwicklung

In diesem Abschnitt zeigen wir einen Überblick über die Modellentwicklung und -bewertung. Die Modellentwicklung wird auf der Azure-Cloud-Plattform implementiert, wobei das Kedro-Framework für die Erstellung wartbarer und modularer Data-Science-Pipelines genutzt wird. Wir lesen Daten direkt aus dem Speicher, der von Azure Databricks verwaltet wird, was einen skalierbaren und einfachen Zugriff auf große Datensätze ermöglicht.

Die Datenverarbeitungspipeline wird mit Kedro in AP 3 & AP 4 definiert, wobei verschiedene verarbeitete Datensätze einer festgelegten Namenskonvention folgen, d.h. `Layer/Provider_Date_Usecase_VehicleType_TestDes_Resolution`. Insbesondere zeigt der Schlüssel `Layer` an, in welcher Phase sich der Datensatz befindet, einschließlich `Raw`, `Intermediate`,

Abbildung II.1 : Zusammenfassung der Literatur zu Automobil-Predictive-Maintenance-Modellen.

Zielseetzungen	Anwendungsfälle	Komponenten	Methoden	Referenzen
Clustering/Ausreißerererkennung	Flottenwartung Batteriespannungsfehler	Gesamtfahrzeug Batterie	COSMO Clustering/Local Outlier Detection Factor Algorithmus Fuzzy C-Means Algorithmus	[12] [16] [6]
	Funktionsabschwächung Fahrwerkskomponenten	Fahrwerk	Histogramm, lineares Modell	[17]
	Flottenwartung	Gesamtfahrzeug		
Klassifikation	Verstopfungsstatus des Sauerstoffensors Motorabwürgung Bremsgeräusche Kompressorleckage	Motor Motor Bremsen Motor	Allgemeine Machine-Learning-Modelle LSTM, Gauß-Schwellenwert CNN, RNN Allgemeine Machine-Learning-Modelle	[24] [29] [22] [11]
	Motorfehler	Motor	CNN	[28]
	Antriebsstrang/Luftfederungsreparatur	Gesamtfahrzeug	RF	[27]
	CAN-Nachrichtenfehler	Gesamtfahrzeug	HMM	[26]
	Bremsgesundheitsstatus	Bremsen	Hoefding-Baum	[25]
	Zündungs-/Kraftstoff-/Abgas-/Kühlsystemfehler	Gesamtfahrzeug	Allgemeine Machine-Learning-Modelle	[13]
	Verschiedene Fahrzeugfehler	Gesamtfahrzeug	Ensemble Learning	[15]
	Elektronische Drosselklappenfehler	Motor	Inkrementelles Lernen	[5]
	Luftkompressorfehler	Kompressor	RF	[4]
	Verschiedene Fahrzeugfehler Batterieausfall	Gesamtfahrzeug Batterie	Ontologiebasiertes Text-Mining Multiobjektives Info-Fuzzy-Netzwerk	[18] [9]
Regression	Brennstoffzellenausgangsspannung Bremsgeräusche Antriebsstrang RUL Brennstoffzelle RUL Batteriezustandsgesundheit Motorfehler Elektronische Sensoren RUL Zeit bis zum Wechsel des Motors	Brennstoffzelle Bremsen Antriebsstrang Brennstoffzelle Batterie Motor Elektronisches System Motor	Aufmerksamkeitsbasiertes RNN LSTM, GBDT SAE, ANN Physisches Modell, ARMA, ANN Extreme Learning Machine HMM Proportionales Hazard-Modell Lineare Regression	[21] [23] [10] [20] [19] [14] [1] [2]

*Primary, Feature, Model input, Models, Model output* und *Reporting*. Der Schlüssel `Test-Des` beschreibt, zu welcher Testfahrt der Datensatz gehört. Der Schlüssel `Resolution` gibt an, ob der Datensatz zu hochfrequenten oder niederfrequenten Messungen gehört. Die Namenskonvention ist so gestaltet, dass sie den Datenabruf erleichtert und die Konsistenz über verschiedene Anwendungsfälle hinweg gewährleistet.

Die Data-Science-Pipeline ist ebenfalls innerhalb des in AP 6 definierten Kedro-Frameworks standardisiert. Die Pipeline besteht aus mehreren Knoten, von denen jeder eine spezifische Aufgabe darstellt, wie Datenvorverarbeitung, Feature-Engineering, Modelltraining, Leistungsbewertung und Artefaktvisualisierung. Beispiele für Kedro-Pipelines für den Anwendungsfall `Bremsgeräusche` sind in Abbildung II.2 und Abbildung II.3 dargestellt. Der Datenzugriff wird durch Kedros Datenkatalog verwaltet, der eine einheitliche Schnittstelle für das Lesen und Schreiben von Daten über verschiedene Speichersysteme hinweg bietet. Insbesondere nutzen wir die benutzerdefinierten Dataset-Klassen wie `PartitionedDataset`, `NumpyArrayDataset` und `SubsetManagedTableDataset`, um von beliebigen Datenquellen wie CSV, Numpy-Array und ATFX-Dateien zu lesen, mit Hilfe von PySpark, Numpy und Pandas. Das Experiment-Tracking wird durch MLflow verwaltet, wodurch Experimente leicht überwacht und aufgezeichnet werden können.

Zwei primäre Datenquellen wurden genutzt: niederfrequente Flottendaten und hochfrequente Sensordaten von spezialisierten Testfahrzeugen. Diese Kombination ermöglichte es uns, verschiedene Aspekte von PM zu adressieren, von breiter Mustererkennung bis hin zu detaillierter Komponentenanalyse. Unser Modellierungsansatz umfasste drei grundlegende Machine-Learning-Paradigmen: Klassifikation für Zustandsidentifikation, Anomalieerkennung für Ausfallvorhersage und Regression für RUL-Schätzung. Jede Modellentwicklungspipeline folgte einem standardisierten Workflow, einschließlich Datenvorverarbeitung, Feature-Engineering, Modelltraining und -bewertung, mit besonderem Augenmerk auf die spezifischen Anforderungen von Automobilanwendungen, was dem entwickelten Referenzmodell entspricht.

Einige Anwendungsfälle wurden als Beispiele für die PM-Modelle ausgewählt, wobei die TUM an folgenden beteiligt war:

- **Bremsgeräusche** (Verschleißmodell / akustische Klassifikationsaufgabe)
- **Sonderereigniserkennung** (Verschleißmodell / Anomalieerkennungsaufgabe)
- **Spur/Sturz** (RUL-Vorhersage / Regressionsaufgabe)

Diese Anwendungsfälle decken drei verschiedene Arten von PM-Aufgaben ab, darunter Anomalieklassifikation, Anomalieerkennung und RUL-Vorhersage. Darüber hinaus umfassen die Datenquellen sowohl hochfrequente als auch niederfrequente Datenaufösungen, was eine umfassende Bewertung der Modellleistung unter verschiedenen Bedingungen und Szenarien ermöglicht. Die Vielfalt der Daten testet nicht nur die Fähigkeit der Modelle, unter verschiedenen Frequenzen genau vorherzusagen, sondern stellt auch sicher, dass die Datenpipeline



Abbildung II.2: Kedro-Pipeline für automatische Datenkennzeichnung im Anwendungsfall Bremsgeräusche.

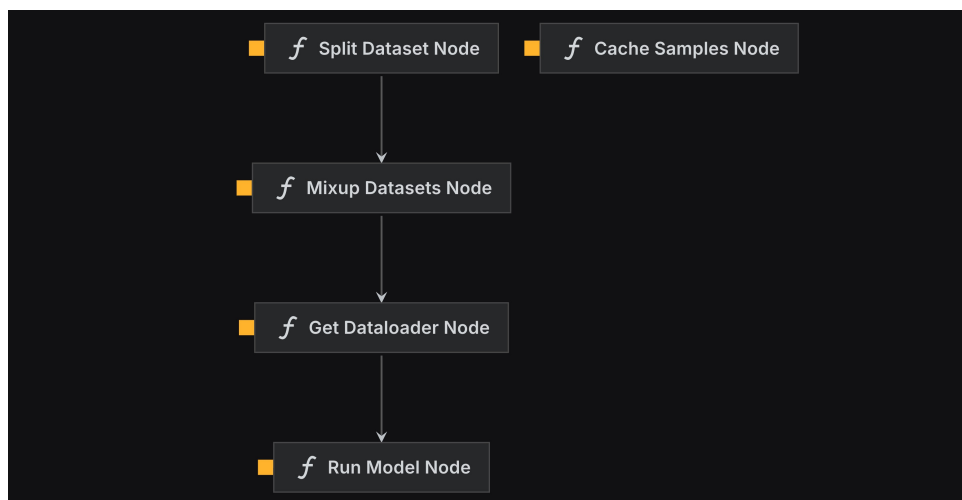


Abbildung II.3: Kedro-Pipeline für Klassifikationsmodell im Anwendungsfall Bremsgeräusche.

vielseitig genug ist, um verschiedene Arten von Eingaben effizient zu verarbeiten und zu verarbeiten.

### 1.3 Use Case: Bremsgeräusche

#### 1.3.1 Hintergrund

Der Anwendungsfall `Bremsgeräusche` konzentriert sich auf die Entwicklung eines automatischen Systems zur Erkennung und Klassifizierung abnormaler Bremsgeräusche unter Verwendung von Daten des Road Condition Sensor (RCS) des Fahrzeugs. Das System zielt darauf ab, eine Grundlinie für normale Bremsgeräusche zu etablieren und abweichende Geräuschemuster zu identifizieren, die auf potenzielle Probleme hinweisen könnten, die eine Inspektion erfordern. Der RCS erfasst akustische Daten, die dann verarbeitet und im Event Frequency Processor (EFP)-Speicher des Fahrzeugs für spätere Analysen gespeichert werden. Dieser PM-Ansatz dient zwei Hauptzwecken: Verbesserung der Fahrsicherheit durch frühzeitige Erkennung von Anomalien im Bremssystem und Optimierung der Wartungskosten durch gezielte Inspektionen basierend auf dem tatsächlichen Systemzustand anstelle von festen Serviceintervallen. Die Entwicklung steht jedoch vor erheblichen technischen Herausforderungen. Die begrenzte Dauer der verfügbaren Testfahrten mit dem ungesunden Bremssystem beschränkt die Menge an Daten, die für die Entwicklung starker Klassifikationsmodelle gesammelt werden können. Darüber hinaus weisen die RCS-Sensordaten ein niedriges Signal-Rausch-Verhältnis auf, was es schwierig macht, bremspezifische Geräusche zuverlässig von anderen Umgebungs- und Fahrzeuggeräuschen zu unterscheiden. Diese Herausforderungen müssen bewältigt werden, um eine zuverlässige und praktische Lösung zur Überwachung von Bremsgeräuschen zu schaffen.

#### 1.3.2 Problemformulierung

In diesem Abschnitt bieten wir eine formalisierte Formulierung der untersuchten Probleme in diesem Anwendungsfall. Die Erkennung und Klassifikation von Bremsgeräuschen kann in zwei verschiedene, aber miteinander verbundene Probleme strukturiert werden:

##### **Problem 1. Unüberwachte Signalkennzeichnung**

Gegeben ist eine Menge von multivariaten Sensor-Zeitreihen  $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^N$ , wobei das Sample  $\mathbf{x}_i \in \mathbb{R}^{w_i \times d}$  das  $i$ -te Snippet von  $d$ -dimensionalen Sensormessungen der Länge  $w_i$  darstellt. In diesem Anwendungsfall sind diese Messungen die Mikrofonaufnahmen des Bremssystems. Wir möchten die punktweisen Labels  $\mathbf{y}_i = (y_{i,1}, y_{i,2}, \dots, y_{i,w_i})$  bestimmen, wobei jedes  $y_{i,t} \in \{1, 2, \dots, K\}$  dem Klassenlabel zum Zeitpunkt  $t$  für das  $i$ -te Snippet entspricht, und  $w_i$  ist die Länge der Label-Sequenz. Hier repräsentiert  $K$  die Gesamtzahl der möglichen Klassen, wie verschiedene Zustände oder Bedingungen des Bremssystems (z.B. normal, Muhen, Quietschen & Knarren). Das Ziel ist es, eine Abbildung  $f : \mathbb{R}^{w_i \times d} \rightarrow \mathcal{Y}_i$  zu erlernen, wobei

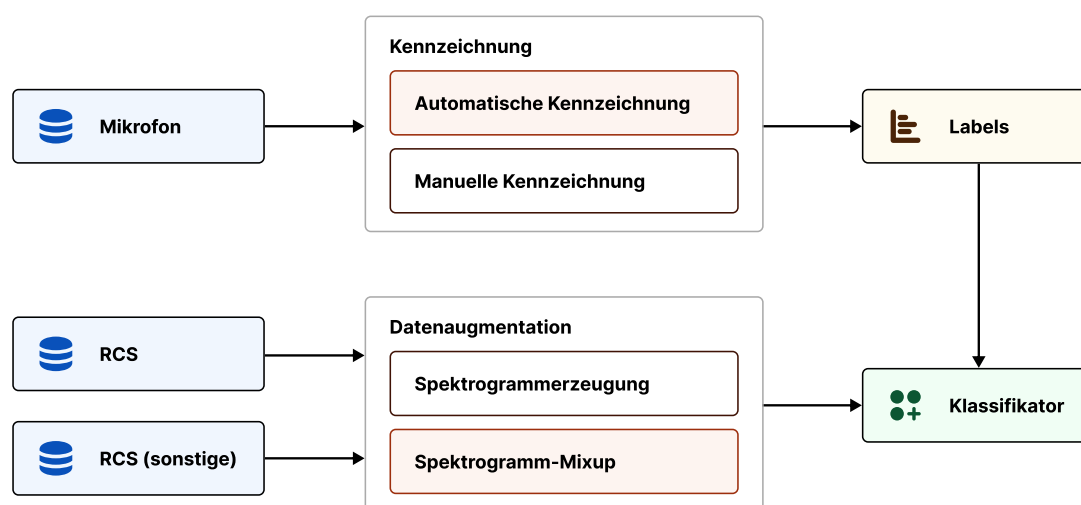


Abbildung II.4: Überblick über das Framework.

$\mathcal{Y}_i = \{1, 2, \dots, K\}^{w_i}$  der Raum aller möglichen Label-Sequenzen der Länge  $w_i$  für das  $i$ -te Snippet ist.

## Problem 2. Bremsgeräuschklassifikation

Gegeben ist eine Menge von gelabelten RCS-Snippets  $\mathcal{X} = \{(\mathbf{x}_i, y_i)\}_{i=1}^N$ , wobei  $\mathbf{x}_i \in \mathbb{R}^{w_i \times d}$  das  $i$ -te Snippet von  $d$ -dimensionalen Sensormessungen mit Länge  $w_i$  darstellt, und  $y_i \in (p_{i,1}, p_{i,2}, \dots, p_{i,K})$  ist das entsprechende Bremsgeräusch-Label. Hier ist  $p_{i,j}$  die Wahrscheinlichkeit, dass das  $i$ -te Snippet zur Klasse  $j$  gehört, die durch den Anteil der Zeitschritte des Snippets bestimmt wird, die in der Kennzeichnungsphase als Klasse  $j$  gekennzeichnet wurden. Das Ziel ist es, einen Klassifikator  $g : \mathbb{R}^{w \times d} \rightarrow \{1, 2, \dots, K\}$  zu erlernen, der RCS-Messungen genau auf ihre jeweiligen Bremsgeräuschkategorien abbildet.

Wie durch die beiden Problemformulierungen angezeigt, nähern wir uns diesem Anwendungsfall durch ein zweistufiges Framework (Abbildung II.4). Die erste Stufe konzentriert sich auf die Signalkennzeichnung, bei der wir entweder automatisch oder manuell die Bremsgeräuschsignale basierend auf den Mikrofonaufnahmen kennzeichnen wollen. Die zweite Stufe umfasst die überwachte Klassifikation der gekennzeichneten Bremsgeräuschsignale, um Anomalien zu erkennen oder sie basierend auf ihren Eigenschaften in vordefinierte Klassen zu kategorisieren.

Ein detaillierterer Überblick über das gesamte Framework ist in Abbildung II.5 dargestellt. Dieser Überblick bietet eine intuitive Möglichkeit, die Eingaben, Ausgaben, Module und ihre Beziehungen zu untersuchen, was es einfach macht, ihre Wiederverwendbarkeit in der Evaluationsphase in AP 7 zu bewerten. Die Details des Frameworks werden in den folgenden Abschnitten erläutert.

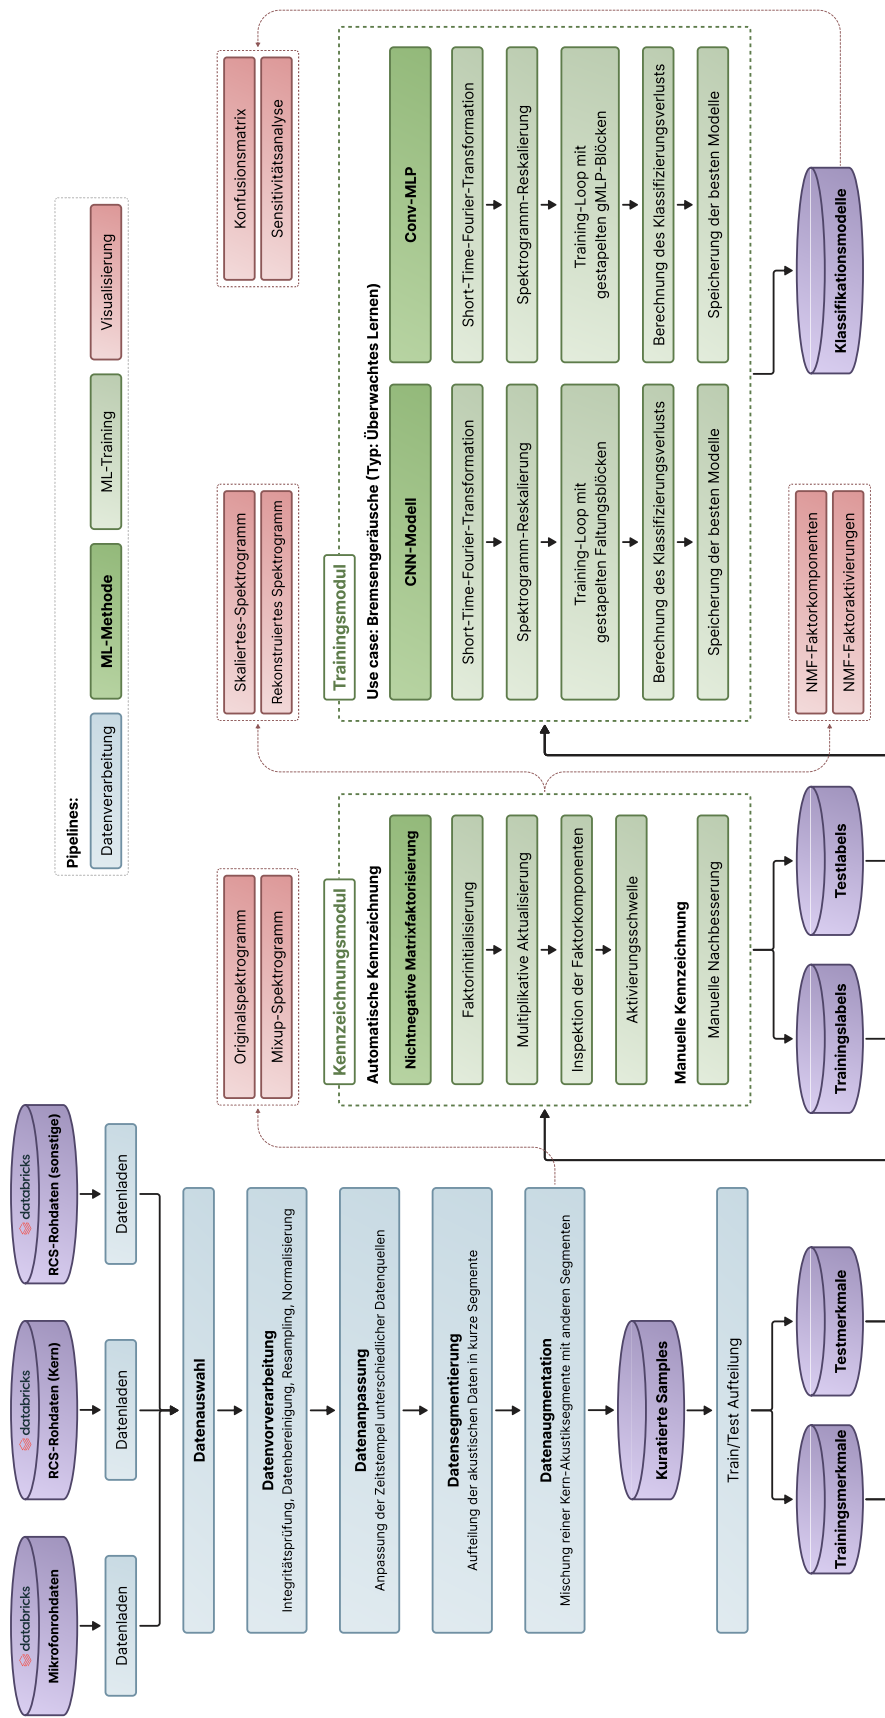


Abbildung II.5: Überblick über den gesamten Workflow mit Demonstration und Bewertung der Modelleistung

### 1.3.3 Automatische Kennzeichnung: Spektrogramm-Faktorisierung

In dieser Phase liegt der Fokus auf der Verarbeitung der akustischen Daten, die vom Mikrofonsystem des Fahrzeugs gesammelt wurden, um bremspezifische Geräuschsignale aus einer Mischung von Umgebungs- und Betriebsgeräuschen zu isolieren. Dies beinhaltet:

- Segmentierung der Daten in kontinuierliche und handhabbare Segmente, um die Analyse zu erleichtern.
- Umwandlung dieser Segmente in ihre Zeit-Frequenz-Darstellungen (d.h. Spektrogramme), um die inhärenten Muster der Geräuschsignale besser zu erfassen.
- Anwendung unüberwachter Faktorisierungstechniken, um bremspezifische Geräusche von überlappenden Quellen zu entwirren.

#### Adaptive Spektrogrammskala

Short-Time Fourier Transform (STFT) ist ein nützliches Werkzeug in der Signalverarbeitung für die Analyse der Zeit-Frequenz-Muster von Signalen. Im Gegensatz zur traditionellen Fourier-Transformation, die Frequenzinformationen für das gesamte Signal liefert, teilt STFT das Signal in kurze, überlappende Zeitsegmente und wendet die Fourier-Transformation auf jedes Segment an. Eine solche Segmentierung ermöglicht es uns, zu beobachten, wie sich die Frequenzmuster des Signals im Laufe der Zeit entwickeln, was es besonders nützlich für die Analyse von Signalen mit gemischten Komponenten macht, wie Bremsgeräuschaufnahmen. Das Ergebnis von STFT ist eine Matrix, die die Magnitude und Phase der Frequenzkomponenten in jedem Zeitrahmen darstellt. Durch das Nehmen der Magnitude dieser Matrix können wir ein Spektrogramm erstellen, das eine visuelle Darstellung des Frequenzmusters des Signals über die Zeit ist.

Ein Spektrogramm ist ein zweidimensionales Diagramm, bei dem die  $x$ -Achse die Zeit, die  $y$ -Achse die Frequenz darstellt, und die Werte die Magnitude oder Leistung der Frequenzkomponenten an jedem Zeitpunkt angeben. Spektrogramme werden in der Audioanalyse häufig verwendet, weil sie eine intuitive Visualisierung davon bieten, wie verschiedene Frequenzen zu dem Signal zu beliebigen Zeitpunkten beitragen. Die Auflösung eines Spektrogramms hängt von den in der STFT verwendeten Parametern ab, wie der Fenstergröße und der Überlappung, die den Kompromiss zwischen Zeit- und Frequenzauflösung bestimmen.

Bei der Interpretation von Spektrogrammen kann die  $y$ -Achse in verschiedenen Skalen gestreckt werden, wie der linearen Skala und der Mel-Skala. Eine lineare Frequenzskala stellt Frequenzen einheitlich dar:

$$\text{Linear}(f) = f. \quad (\text{II.1})$$

Allerdings sind die meisten Bremsgeräuschsignale, an denen wir interessiert sind, im unteren Frequenzbereich konzentriert, und die lineare Skala kann die Details in diesem Bereich nicht vollständig erfassen. Die Mel-Skala hingegen ist eine logarithmische Transformation der Fre-

quenzskala, die besser mit der menschlichen Hörwahrnehmung übereinstimmt:

$$\text{Mel}(f) = \begin{cases} \frac{3f}{200} & \text{if } 0 \leq f < 1000, \\ 15 + 27 \log_{6.4} \left( \frac{f}{1000} \right) & \text{if } f \geq 1000. \end{cases} \quad (\text{II.2})$$

Es ist erwähnenswert, dass es mehrere verschiedene Möglichkeiten gibt, die Mel-Skala zu berechnen, und die obige Formel stammt aus Slaneys Implementierung [62], die eine stückweise Funktion verwendet, wie in [63] vorgeschlagen. Durch die Umwandlung des Spektrogramms in die Mel-Skala können wir ein Mel-Spektrogramm erstellen, das niedrigere Frequenzen betont und höhere Frequenzen komprimiert, was es besonders nützlich für unseren Anwendungsfall macht. Um besser auf die Bremsgeräuschsignale einzugehen, verwenden wir eine adaptive (Symlog) Spektrogrammskala, die die Frequenzskala automatisch basierend auf den Eigenschaften des Eingabesignals anpasst. Diese adaptive Skala erweitert die stückweise Mel-Skala, indem sie die Parameter anpasst, um die relevanten Frequenzkomponenten der Bremsgeräuschsignale effektiver zu erfassen und die Qualität der Spektrogrammdarstellung zu verbessern.

$$\text{Symlog}(f) = \begin{cases} \frac{f}{p} & \text{if } 0 \leq f < t, \\ \frac{t}{p} + q \log_b \left( \frac{f}{t} \right) & \text{if } f \geq t. \end{cases} \quad (\text{II.3})$$


Ein Vergleich der linearen, Mel- und Symlog-Skalen ist in Abbildung II.6 dargestellt. Die Symlog-Skala bietet eine ausgewogenere Darstellung der Frequenzkomponenten und erfasst die Frequenzdetails des Signals effektiv. Durch die Verwendung der Symlog-Skala können wir Spektrogramme erstellen, die die Bremsgeräuschsignale besser hervorheben und die nachfolgenden Analyse- und Klassifikationsaufgaben erleichtern.

### **Regularisierte Nicht-negative Matrixfaktorisierung für Spektrogrammzerlegung**


Faktorisierungsmethoden werden verwendet, um verschiedene Geräuschkomponenten aus dem Spektrogramm zu trennen. Mögliche Lösungen umfassen NMF, Principal Component Analysis (PCA) und ICA. Wir bieten einen kurzen Vergleich dieser Methoden unten in Tabelle II.1. Aufgrund der Vorteile in Bezug auf Sparsität und Interpretierbarkeit wird Regularisierte Nicht-negative Matrixfaktorisierung (RNMF) für die Aufgabe der Bremsgeräuschsignaltrennung ausgewählt.

Insbesondere ist NMF eine beliebte Technik zur Zerlegung einer Matrix in zwei nicht-negative Matrizen, die als Basiskomponenten und deren Koeffizienten interpretiert werden können. Im Kontext der Bremsgeräuschsignaltrennung kann NMF verwendet werden, um die einzigartigen Klangquellen zu extrahieren, die zum beobachteten Spektrogramm beitragen. Durch die Anwendung von NMF auf das Spektrogramm können wir die Bremsgeräuschkomponente im Frequenzbereich effektiv isolieren, was weitere Analyse- und Klassifikationsaufgaben erleichtert.


Stellen Sie sich ein Szenario vor, in dem wir eine Musikaufnahme haben, die eine Mischung von Klängen verschiedener Instrumente enthält. Das Ziel ist es, diese Aufnahme in ihre ein-



(a) Linear Spektrogramm.



(b) Mel-Spektrogramm.



(c) Symlog-Spektrogramm.

Abbildung II.6: Vergleich der Spektrogrammskalen: Linear, Mel und Symlog.

Tabelle II.1: Vergleich von PCA, ICA und NMF für die Spektrogrammzerlegung.

	PCA	ICA	NMF
Zielsetzung	Maximiert Varianz, um orthogonale Komponenten zu finden	Findet statistisch unabhängige Komponenten	Findet nicht-negative, additive Komponenten
Basis Interpretierbarkeit	Orthogonale Basis Komponenten sind möglicherweise nicht leicht interpretierbar	Unabhängige Basis Komponenten sind statistisch unabhängig, können aber an Interpretierbarkeit mangeln	Nicht-negative Basis Hochgradig interpretierbar aufgrund der Nicht-Negativität
Sparsität	Nicht inhärent spärlich	Kann Sparsität fördern, abhängig vom Algorithmus	Führt oft zu spärlichen Darstellungen mit zusätzlicher Regularisierung
Nicht-Negativität	Keine Nicht-Negativitätsbeschränkungen	Keine Nicht-Negativitätsbeschränkungen	Mit Nicht-Negativitätsbeschränkungen

zelenen Komponenten zu zerlegen und den Klang jedes Instruments zu isolieren. Obwohl die Klänge gemischt sind, hat jedes Instrument seine eigene charakteristische akustische Signatur, die als wichtiger Hinweis für die Trennung dienen kann. NMF adressiert dies, indem es die ursprüngliche Datenmatrix in zwei Matrizen zerlegt: eine, die die Basiskomponenten erfasst (die die einzigartigen Klangeigenschaften jedes Instruments darstellen), und eine andere, die die Aktivierungskoeffizienten dieser Komponenten in der gemischten Aufnahme kodiert. In unserem Anwendungsfall wird NMF ähnlich wie bei der Instrumententrennung angewendet. Indem die akustische Signatur verschiedener Geräusche in den Basiskomponenten eingebettet wird, kann NMF sie effektiv voneinander trennen.

Mathematisch gesehen stellt NMF das Eingabespektrogramm als lineare Kombination nicht-negativer Basiskomponenten und ihrer entsprechenden Aktivierungskoeffizienten dar. Gegeben die Eingabematrix  $\mathbf{X} \in \mathbb{R}^{t \times m}$ , wobei  $m$  die halbe Größe der Stichprobe und  $t$  die Länge des Signalsegments ist, sucht NMF die folgende Transformation:

$$\mathbf{X} \approx \mathbf{W}\mathbf{H}, \quad (\text{II.4})$$

wobei:

- $\mathbf{W} \in \mathbb{R}^{t \times r}$  die Komponentenmatrix ist und  $r$  die Anzahl der latenten Komponenten, auch bekannt als Matrix-Rang.
- $\mathbf{H} \in \mathbb{R}^{r \times m}$  die Aktivierungsmatrix ist, die die Stärke jeder Komponente über die Zeit angibt.

Um die Lösung für NMF zu finden, sollte das folgende eingeschränkte Optimierungsproblem gelöst werden:

$$\arg \min_{\mathbf{W}, \mathbf{H} \geq \mathbf{0}} \frac{1}{2} \|\mathbf{X} - \mathbf{W}\mathbf{H}\|_F^2. \quad (\text{II.5})$$

Im Vergleich zur NMF führt RNMF zusätzliche Regularisierung ein, um spärliche Lösungen zu fördern:

$$\arg \min_{\mathbf{W}, \mathbf{H} \geq 0} \frac{1}{2} \|\mathbf{X} - \mathbf{W}\mathbf{H}\|_F^2 + \alpha_H \|\text{vec}(\mathbf{H})\|_1 + \frac{\beta_H}{2} \|\mathbf{H}\|_F^2 + \alpha_W \|\text{vec}(\mathbf{W})\|_1 + \frac{\beta_W}{2} \|\mathbf{W}\|_F^2, \quad (\text{II.6})$$

wobei  $\|\cdot\|_F$  die Frobenius-Norm,  $\|\cdot\|_1$  die  $L^1$ -Norm, und  $\alpha$  ein Ausgleichskoeffizient ist. Die Zielfunktion von RNMF besteht aus drei Komponenten:

- Der Rekonstruktionsfehler der Matrixfaktorisierung.
- Die Sparsitätsregularisierung durch die  $L^1$ -Norm.
- Die Skalenregularisierung, berechnet durch die Frobenius-Norm.

Angenommen, es gibt  $K$  latente Komponenten, sind die detaillierten Schritte zur Lösung des RNMF-Optimierungsproblems wie folgt:

1. Initialisiere die faktorisierten Matrizen.

2. Wiederhole bis zur Konvergenz:

(a) Aktualisiere  $\mathbf{W}$  mit:

$$\mathbf{W} \leftarrow \mathbf{W} \odot \frac{\mathbf{X}\mathbf{H}^\top}{\mathbf{W}\mathbf{H}\mathbf{H}^\top + \alpha_W \mathbf{I} + \beta_W \mathbf{W}}. \quad (\text{II.7})$$

(b) Aktualisiere  $\mathbf{H}$  mit:

$$\mathbf{H} \leftarrow \mathbf{H} \odot \frac{\mathbf{W}^\top \mathbf{X}}{\mathbf{W}^\top \mathbf{W}\mathbf{H} + \alpha_H \mathbf{I} + \beta_H \mathbf{H}}. \quad (\text{II.8})$$

(c) Überprüfe die Konvergenz.

Sobald das Modell angepasst ist, bietet es eine Zerlegung der beobachteten Signale in additive Komponenten. Die automatische Kennzeichnung kann durch folgendes Verfahren erreicht werden:

1. Kennzeichne die Komponenten in der Komponentenmatrix unter Rückgriff auf einen Fahrzeugtechniker.
2. Finde die entsprechenden Aktivierungskoeffizienten in der Aktivierungsmatrix.
3. Lege einen Schwellenwert fest, um die Labels für das Spektrogramm zu bestimmen.

## Experimentergebnisse

Hier zeigen wir die Zerlegungsergebnisse auf dem Spektrogramm, das aus den Daten einer Testfahrt abgeleitet wurde. Ein Vergleich zwischen dem originalen und dem rekonstruierten

Spektrogramm ist in Abbildung II.7 dargestellt. Es kann beobachtet werden, dass die Rekonstruktion erfolgreich die wesentliche Struktur des Originalspektrogramms beibehält, während zufällige Geräusche ignoriert werden. Durch die Anwendung von RNMF auf das Spektrogramm können wir die Bremsgeräuschsignale effektiv voneinander trennen und separate Darstellungen der bremspezifischen Komponenten bieten. Wir zeigen die komponentenweise Rekonstruktion in Abbildung II.8. Die Sparsitätsregularisierung in RNMF ist auch erfolgreich bei der Isolierung der Bremsgeräuschsignale vom Hintergrundgeräusch, wobei jede Komponente ein visuell spärliches Muster aufweist.

Die extrahierten Frequenzkomponenten werden in Abbildung II.9 deutlicher visualisiert, wobei die einzigartigen Frequenzmuster der Bremsgeräuschsignale gezeigt werden. Schließlich werden die Aktivierungskoeffizienten der extrahierten Komponenten in Abbildung II.10 visualisiert, die die Stärke jeder Komponente über die Zeit anzeigen. Wir normalisieren die Aktivierungskoeffizienten und setzen einen Schwellenwert von 0,5, um die Labels für das Spektrogramm zu bestimmen, wobei die Zeitpunkte mit Koeffizienten größer als 0,5 als positive Proben gekennzeichnet werden.

### **1.3.4 Bremsgeräuschklassifikation: Traditionelle Machine-Learning- und Deep-Learning-Ansätze**

#### **Workflows für Bremsgeräuschklassifikation**

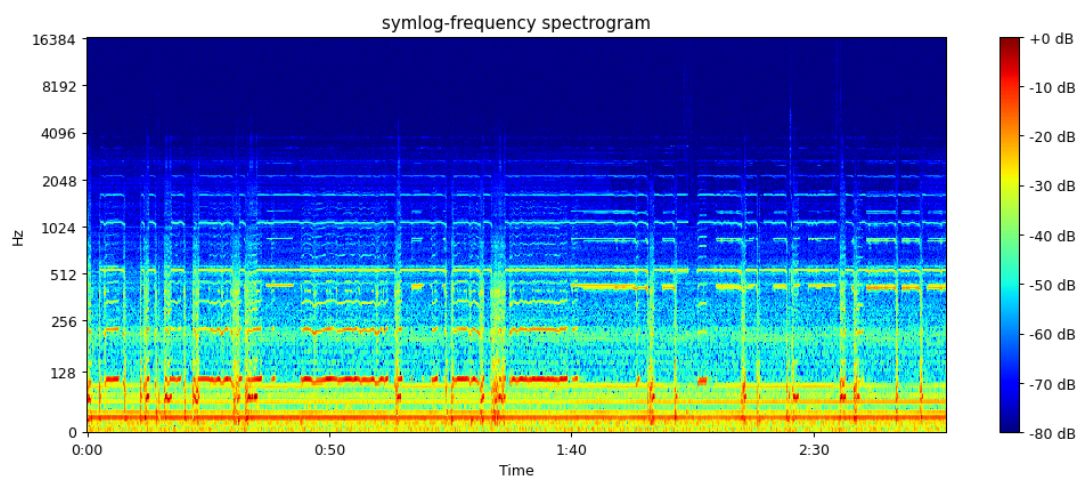
Die Klassifikation von Bremsgeräuschsignalen ist ein entscheidender Schritt im Anwendungsfall *Bremsgeräusche*, da sie die automatische Erkennung abnormaler Bremsgeräusche aus den RCS-Daten ermöglicht, die als alternative Datenquelle für PM dienen. Um dies zu erreichen, entwickeln wir zwei übergeordnete Klassifikations-Workflows (Abbildung II.11), die jeweils traditionelle ML- und Neural Network (NN)-Ansätze nutzen.

Der traditionelle ML-Workflow besteht aus den folgenden Schritten:

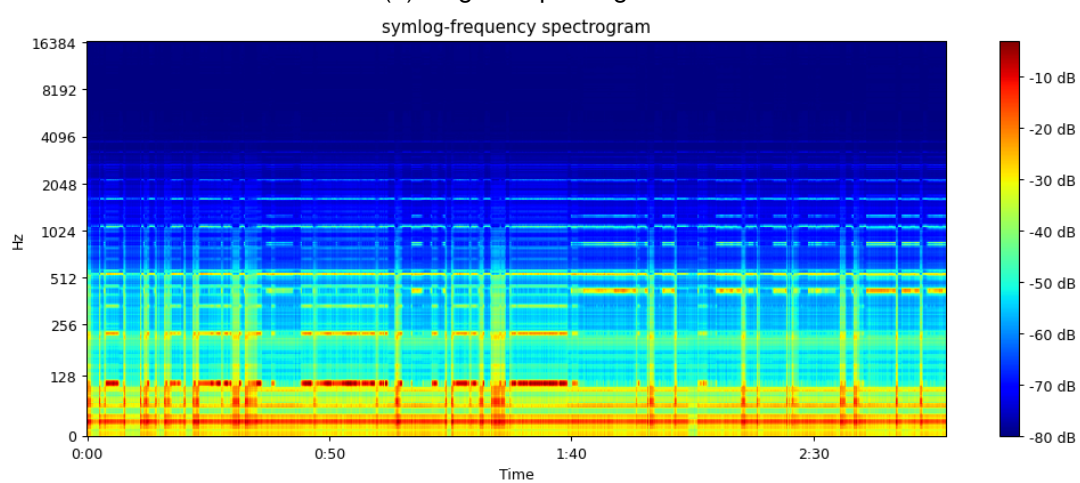
1. Extrahiere statistische Merkmale aus der originalen RCS-Wellenform, einschließlich Zeit- und Frequenzbereichsmerkmalen.
2. Pivottiere die extrahierten Merkmale in ein tabellarisches Format, das für ML-Modelle geeignet ist.
3. Trainiere ein Klassifikationsmodell auf den tabellarischen Daten mit traditionellen ML-Algorithmen — in unserem Fall ein Gradient Boosting Decision Tree (GBDT) [64].
4. Das trainierte Modell wird dann verwendet, um die Bremsgeräusch-Labels für neue RCS-Daten vorherzusagen.

Der NN-Workflow umfasst die folgenden Schritte:

1. Konvertiere die originale RCS-Wellenform in eine Spektrogrammdarstellung mit STFT und transformiere diese dann in eine adaptive Spektrogrammskala.



(a) Original Spektrogramm.



(b) Rekonstruiertes Spektrogramm.

Abbildung II.7: Spektrogrammzerlegungsergebnisse mit RNMF.

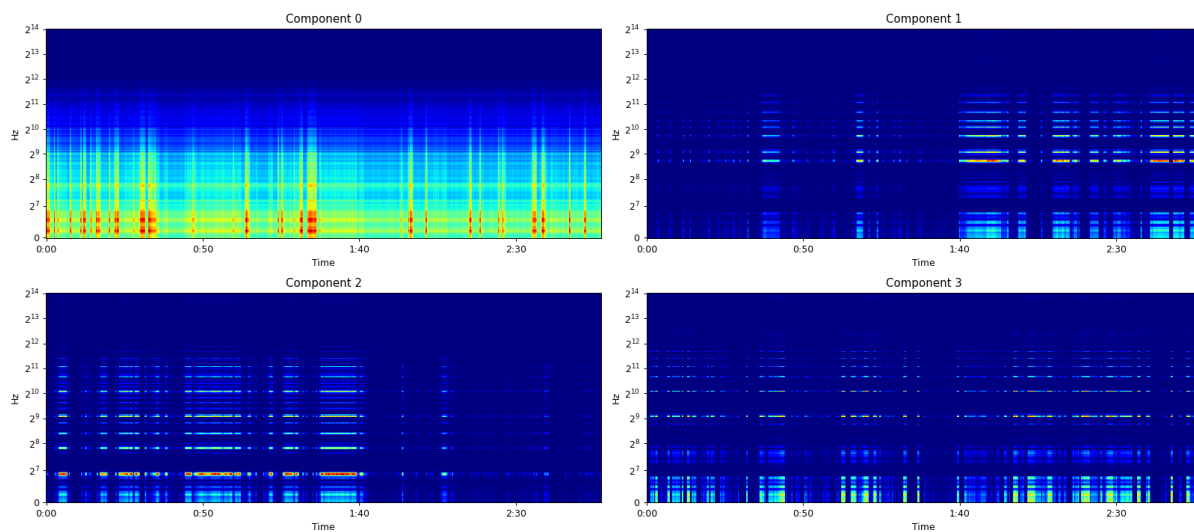


Abbildung II.8: Komponentenweise Rekonstruktion mit RNMF.




Abbildung II.9: Extrahierte Frequenzkomponenten mit RNMF.

2. Wende lineare Projektion auf das extrahierte Spektrogramm als Eingabeeinbettungen an.
3. Trainiere ein NN-Modell auf den Einbettungen mit einer geeigneten Architektur.
4. Das trainierte Modell wird dann verwendet, um die Bremsgeräusch-Labels für neue RCS-Daten vorherzusagen.

## Netzwerkarchitekturen

Im Vergleich zum traditionellen ML-Workflow, bei dem Merkmale manuell von Ingenieuren extrahiert werden, verlässt sich der NN-Workflow auf das Architekturdesign, um implizit Merkmale aus den Daten zu extrahieren.

Um dieses Ziel zu erreichen, wurden drei Kandidaten-NN-Architekturen für den NN-Workflow zum Vergleich entworfen, wie in Abbildung II.12 dargestellt.

- **Die CNN-Architektur** ist ein bewährter Ansatz, bestehend aus gestapelten Faltungsblöcken. Faltungsschichten sind darauf ausgelegt, lokale Muster und Merkmale innerhalb des Eingabespektrogramms zu erkennen. Sie verwenden Filter, um räumliche oder zeitliche Informationen zu extrahieren. Batch-Normalisierung, oft in diese Blöcke integriert, hilft, die Aktivierungen jeder Schicht zu normalisieren, wodurch die interne Kovariatenverschiebung reduziert und ein schnelleres und stabileres Training ermöglicht wird. Die sequentielle Struktur dieser Faltungsblöcke ermöglicht es dem Modell, zunehmend komplexe und hierarchische Muster zu erfassen. Anschließend wird globales Pooling eingesetzt, um die extrahierten Merkmale zusammenzufassen, die Dimensionalität zu reduzieren und gleichzeitig die wichtigsten Informationen zu bewahren.
- **Die Patch-Multi-Layer Perceptron (MLP)-Architektur** bietet einen prinzipiellen Ansatz zur Spektrogrammverarbeitung. Sie beginnt damit, das Spektrogramm in Patches zu unterteilen, was dem Modell ermöglicht, lokale Regionen der Eingabe ähnlich wie das menschliche visuelle System zu verarbeiten. Sequentielle gated-MLP (gMLP)-Blöcke werden dann eingesetzt. MLP-Schichten bieten die Flexibilität, nichtlineare und komplexe Beziehungen zwischen Eingabemerkmalen zu erlernen. Der Gating-Mechanismus innerhalb dieser Blöcke ermöglicht adaptive Filterung und Verarbeitung der Informationen. Globales Pooling wird auch hier verwendet, um die gelernten Merkmale aus den Patches zusammenzufassen und eine kompakte und repräsentative Zusammenfassung zu erstellen.
- **Die Conv-MLP-Architektur** kombiniert das Beste aus beiden Welten, indem sie sequentielle Blöcke von Faltungsmodulen und gMLPs kombiniert. Diese Kombination ermöglicht es dem Modell, sowohl lokale Muster über die Faltungsmodule als auch komplexe nichtlineare Beziehungen durch die gMLPs zu erfassen. Feed-Forward-Blöcke innerhalb dieser Architektur sorgen für einen reibungslosen Informationsfluss und unterstützen effektives Lernen. Wie bei den anderen Architekturen wird globales Pooling verwendet, um die


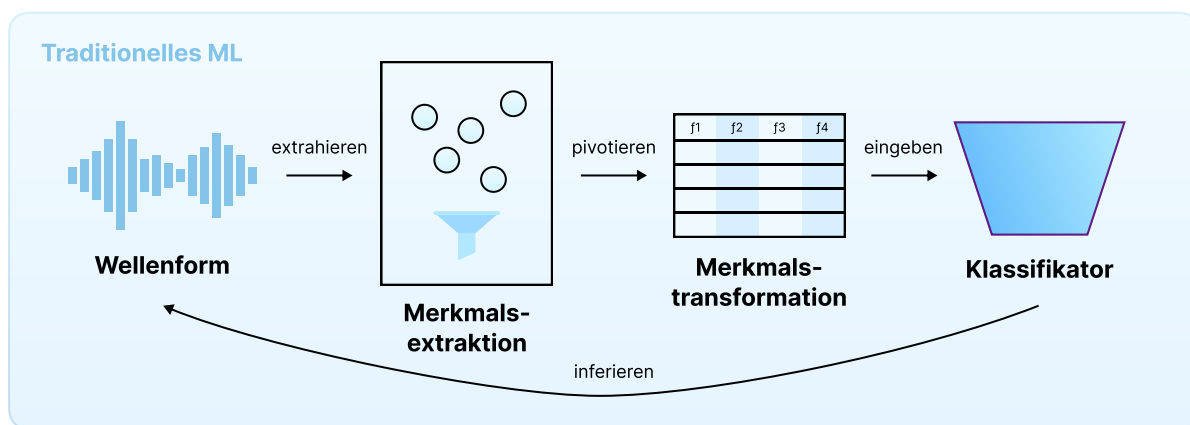
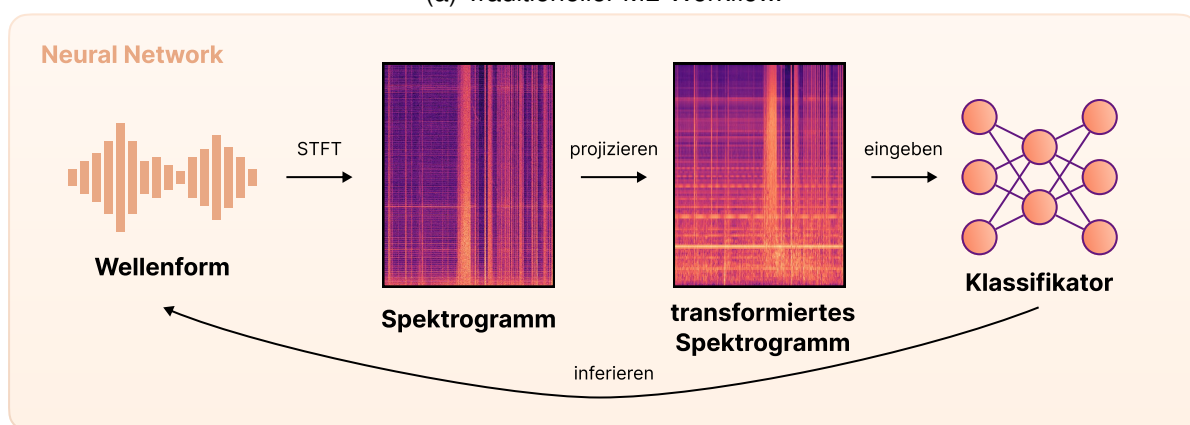


Abbildung II.10: Aktivierungskoeffizienten der extrahierten Komponenten.



(a) Traditioneller ML-Workflow.



(b) Neural-Network-Workflow.

Abbildung II.11: Gegenüberstellung der Verarbeitungsworkflows.

verschiedenen in den Schichten extrahierten Merkmale zu konsolidieren und eine umfassende und genaue Darstellung für die Klassifikation zu bieten.

### Spektrogramm-Mixup für Datenerweiterung

Eine Datenerweiterungsstrategie wurde entwickelt, um das Problem der begrenzten Trainingsproben zu lösen und die Modellgeneralisierungsfähigkeit zu verbessern. Anstelle von sprachorientierten Erweiterungsstrategien wie [65] ist unsere Strategie von der Grundstrategie in [66] inspiriert, da die Zeit-Frequenz-Maskierungsoperationen in [65] möglicherweise nicht für die Bremsgeräuschsignale geeignet sind, bei denen das Frequenzmuster von Interesse vorübergehend sein oder einen kleinen Frequenzbereich abdecken könnte. Wie in Abbildung II.13 dargestellt, kombiniert die Spektrogramm-Mixup-Technik ein Paar von Spektrogrammen aus dem Anwendungsfall `Bremsgeräusche` und anderen Anwendungsfällen ohne abnormale Bremsgeräusche, um neue Samples zu erstellen. Bezeichne das ursprüngliche Spektrogrammpaar als  $\mathbf{X}_1$  und  $\mathbf{X}_2$  und die entsprechenden Labels als  $y_1$  und  $y_2$ . Die Spektrogramm-Mixup-Operation ist definiert als:

$$\tilde{\mathbf{X}} = \lambda \mathbf{X}_1 + (1 - \lambda) \mathbf{X}_2, \quad (\text{II.9})$$

$$\tilde{y} = y_1. \quad (\text{II.10})$$

Die durch das überlagerte Signal eingeführten nicht verwandten externen Geräusche können dem Modell helfen, besser zu generalisieren und das Risiko des Overfittings zu reduzieren.

### Experiment-Setup und Ergebnisse

Die Klassifikationsleistung der Modelle wird mit Genauigkeit, AUC und F1-Score-Metriken bewertet. Die Genauigkeit misst den Anteil der korrekt klassifizierten Samples:

$$\text{Genauigkeit} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}, \quad (\text{II.11})$$

wobei:

- TP: True Positive, die Anzahl der korrekt klassifizierten positiven Samples.
- TN: True Negative, die Anzahl der korrekt klassifizierten negativen Samples.
- FP: False Positive, die Anzahl der negativen Samples, die fälschlicherweise als positiv klassifiziert wurden.
- FN: False Negative, die Anzahl der positiven Samples, die fälschlicherweise als negativ klassifiziert wurden.

Der F1-Score ist das harmonische Mittel aus Präzision und Recall und bietet eine ausgewoge-

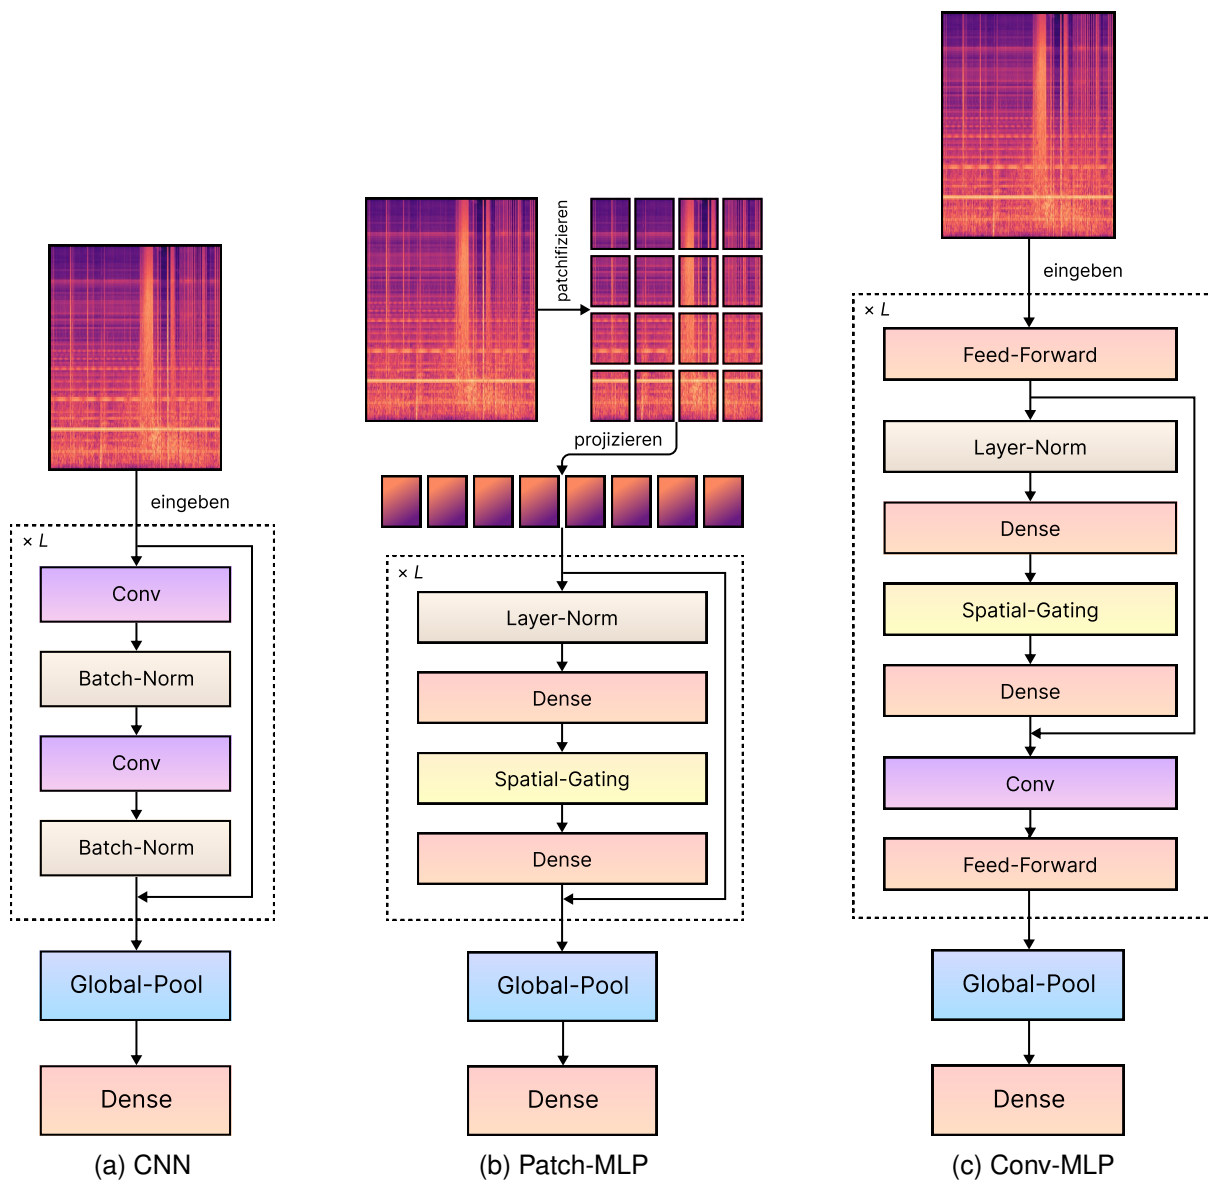


Abbildung II.12: Gegenüberstellung der Kandidaten-Netzwerkarchitekturen.

ne Bewertung der Modelleistung.

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}, \quad (\text{II.12})$$

$$\text{Präzision} = \frac{TP}{TP + FP}, \text{ Recall} = \frac{TP}{TP + FN}. \quad (\text{II.13})$$

Die AUC misst die Fähigkeit des Modells, zwischen positiven und negativen Samples zu unterscheiden, wobei eine höhere AUC eine bessere Leistung anzeigt.

Die Leistung der Modelle ist in Tabelle II.2 zusammengefasst. Hier betrachten wir sowohl ein traditionelles ML-Modell basierend auf GBDT als auch fünf NN-Modelle, darunter Conv-MLP, Conformer [39], Patch-MLP mit gMLP [67], Patch-MLP mit MLP-Mixer [68] und CNN mit ResNet-Architekturen [69]. Laut der Tabelle schneidet der traditionelle ML-Ansatz deutlich schlechter ab als die NN-Ansätze. Der F1-Score von 0 zeigt an, dass das Modell in diesem Anwendungsfall keine sinnvollen Ausgaben liefert; während alle NN-Modelle F1-Scores über 0,7 haben. Das Conv-MLP-Modell erzielt die beste Leistung in Bezug auf Genauigkeit, AUC und F1-Score. Das Conv-MLP-Modell kombiniert die Vorteile sowohl von Faltungs- als auch von MLP-Architekturen, erfasst effektiv lokale Muster und komplexe Beziehungen in den Spektrogrammdateien. Das Patch-MLP-Modell zeigt ebenfalls eine wettbewerbsfähige Leistung, was die Effektivität des patch-basierten Verarbeitungsansatzes hervorhebt. Das CNN-Modell, das immer noch eine gute Leistung erzielt, liegt leicht hinter den Conv-MLP- und Patch-MLP-Modellen, was auf die Vorteile der vorgeschlagenen Architekturen für die Bremsgeräuschklassifikation hinweist. Bemerkenswert ist, dass unser Modell auch das state-of-the-art Akustikerkenntnismodell, Conformer, in diesem Anwendungsfall übertrifft, was die Effektivität der vorgeschlagenen Architekturen für die Bremsgeräuschklassifikation demonstriert.

Neben dem Vergleich zwischen verschiedenen Modellen haben wir auch mit verschiedenen Hyperparametern und Konfigurationen experimentiert, um ihre Auswirkungen auf die Klassifikationsleistung zu untersuchen. Zunächst untersuchten wir den Einfluss der Verlustfunktion auf die Modelleistung. Die Standardverlustfunktion für Klassifikation ist der Kreuzentropie-Verlust:

$$\mathcal{L}_{ce} = - \sum_{i=1}^N y_i \log(p_i), \quad (\text{II.14})$$

wobei  $y_i$  das wahre Label und  $p_i$  die vorhergesagte Wahrscheinlichkeit ist. Wir experimentierten auch mit dem Focal Loss [70], der die gut klassifizierten Samples heruntergewichtet, um sich auf die schwierigen Samples zu konzentrieren:

$$\mathcal{L}_{focal} = - \sum_{i=1}^N (1 - p_i)^\gamma y_i \log(p_i), \quad (\text{II.15})$$

wobei  $\gamma$  ein Hyperparameter ist, der den Heruntergewichtungsfaktor steuert. Die Ergebnisse sind in Tabelle II.3 zusammengefasst, wobei der Focal Loss mit  $\gamma = 5$  die beste Leistung in Bezug auf Genauigkeit, AUC und F1-Score erzielt. Dies zeigt, dass der Focal Loss effektiv bei

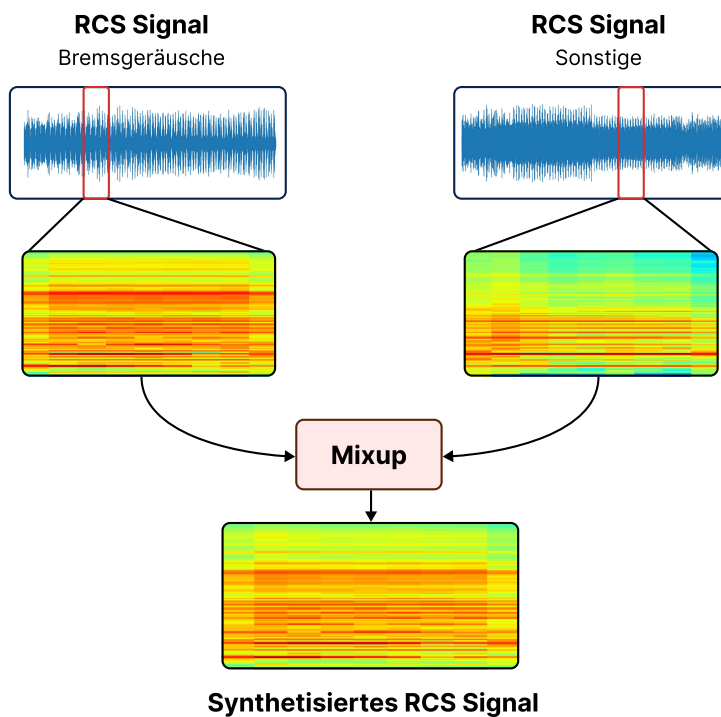


Abbildung II.13: Spektrogramm-Mixup zur Datenaugmentation.

Tabelle II.2: Klassifikationsleistung verschiedener Modelle.

Modell	Genauigkeit	AUC	F1
Conv-MLP	88,2%	91,5%	75,0%
Conformer	86,9%	90,7%	73,8%
Patch-MLP (gMLP)	86,7%	87,5%	71,6%
Patch-MLP (MLP-Mixer)	85,9%	87,0%	68,6%
CNN (ResNet)	85,8%	86,7%	70,5%
Traditionelles ML (GBDT)	74,4%	61,0%	0,00%

der Bewältigung der unausgewogenen Datenverteilung in der Bremsgeräuschklassifikationsaufgabe ist.

Die Ablationsstudie wurde durchgeführt, um den Einfluss der einzelnen Komponenten des Netzwerks auf die Modelleleistung zu untersuchen, wie in Tabelle II.4 zusammengefasst. Die Ergebnisse zeigen, dass das Conv-MLP-Modell die beste Leistung erzielt, was die Bedeutung der kombinierten Faltungs- und MLP-Architekturen für die Bremsgeräuschklassifikation verdeutlicht. Das Entfernen der Residualverbindungen, der gMLP-Blöcke, der Feed-Forward-Netzwerke, der tiefenweisen Faltungsschichten und der Aktivierungsfunktionen führt jeweils zu einer Leistungsabnahme, was die Bedeutung dieser Komponenten in der Modellarchitektur hervorhebt.

Zusätzlich vergleichen wir die Rechenkomplexität des Conv-MLP-Modells mit anderen Modellen in Tabelle II.5. Das Conv-MLP-Modell hat eine höhere Anzahl an Parametern und Rechenoperationen im Vergleich zu den Patch-MLP- und CNN-Modellen. Dies ist auf die Kombination von Faltungs- und MLP-Architekturen zurückzuführen, die die Modellkomplexität erhöht. Angesichts der Tatsache, dass das Conv-MLP-Modell die beste Leistung unter den Modellen erzielt und der Rechenaufwand akzeptabel ist, wird es dennoch als optimale Modellwahl für diesen Anwendungsfall betrachtet.

Schließlich untersuchten wir die Robustheit des Conv-MLP-Modells gegenüber verschiedenen Geräuschen, die durch die Datenerweiterung eingeführt wurden. Die Ergebnisse sind in Abbildung II.14 dargestellt, wo die Modelleleistung über verschiedene Mixup-Koeffizienten hinweg stabil bleibt, was die Robustheit des Modells gegenüber den eingeführten Geräuschen zeigt. Dies demonstriert die Effektivität der Spektrogramm-Mixup-Technik bei der Verbesserung der Modellgeneralisierung und -leistung. Unter allen Sätzen von Mixup-Koeffizienten hat nur der erste — der die meisten Geräusche in das Spektrogramm einführt — signifikante negative Auswirkungen auf die Klassifikation, mit einer Reduktion von etwa 10% in der Genauigkeit. Dies könnte darauf hindeuten, dass die hinzugefügten Geräusche zu stark sind und mit Frequenzmustern interferieren, die für das Modell notwendig sind, um die Bremsgeräuschklasse zu erkennen.

## **1.4 Use Case: Sonderereigniserkennung**

### **1.4.1 Hintergrund**

Fahrzeugfahrwerke, insbesondere Federbeinlager, sind kritische Komponenten, die sowohl Fahrkomfort als auch Fahrzeugsicherheit gewährleisten. Diese Komponenten sind darauf ausgelegt, normalen Betriebsbelastungen standzuhalten, aber wiederholtes Fahren über Schwellen und Senken mit unangemessenen Geschwindigkeiten kann zu schweren Auswirkungen auf den Zustand der Komponenten führen und vorzeitigen Verschleiß und potenzielles Versagen verursachen. Dieser Schaden ist jedoch oft für den Fahrer nicht erkennbar und wird möglicherweise erst bei einer Werkstattinspektion identifiziert. Das Ziel dieses Anwendungs-

Tabelle II.3: Einfluss der Verlustfunktion und  $\gamma$  auf die Leistung.


Verlustfunktion	$\gamma$	Genauigkeit	AUC	F1
Focal	0,5	87,2%	90,5%	73,8%
Focal	1	87,2%	90,5%	73,8%
Focal	2	85,6%	90,6%	73,8%
Focal	5	88,2%	91,5%	75,0%
Focal	10	87,6%	91,0%	74,7%
BCE	N/A	87,2%	90,1%	74,2%

Tabelle II.4: Ablationsstudie des Conv-MLP-Modells.


Modellvarianten	Genauigkeit	AUC	F1
Conv-gMLP	88,2%	91,5%	75,0%
– adaspec + melspec	86,8%	90,2%	72,7%
– Residual	74,4%	50,0%	0,00%
– gMLP	87,3%	91,3%	73,3%
– FFN	87,5%	90,8%	74,3%
– dw-conv	87,3%	91,1%	73,6%
– GELU + ReLU	87,2%	91,1%	73,7%
– GELU + Swish	87,1%	91,2%	73,5%

Tabelle II.5: Rechenkomplexität verschiedener Modelle.

Modell	# Parameter	MAdds	FLOPs
Conv-MLP	3,4M	28,8M	352,9M
Patch-MLP (gMLP)	0,6M	6,2M	142,5M
CNN (ResNet)	0,2M	20,4M	40,4M



(a) Änderungen des SNR.



(b) Änderungen der Genauigkeit.

Abbildung II.14: Einfluss des Mixup-Koeffizienten auf SNR und Klassifikationsgenauigkeit.

falls, Sonderereigniserkennung, ist die Entwicklung eines Anomalieerkennungsmodells unter Verwendung von Sensordaten, um proaktiv Instanzen dieses Missbrauchs zu identifizieren und eine frühzeitige Intervention und potenzielle Schadensverhütung zu ermöglichen. Dies hat das Potenzial, Garantieansprüche zu reduzieren und die Kundenzufriedenheit zu verbessern, indem unerwartete und kostspielige Reparaturen verhindert werden.

Für diesen Anwendungsfall war die TUM in der frühen Phase der Datenanalyse und Entwicklung eines vorläufigen Modells beteiligt.

### 1.4.2 Problemformulierung

In diesem Abschnitt bieten wir eine formalisierte Formulierung des untersuchten Problems.

#### Problem 3. Flotten-Anomalieerkennung

Gegeben ist eine Menge unmarkierter multivariater Sensor-Zeitreihen  $X = \{x_i\}_{i=1}^N$ , wobei das Sample  $x_i \in \mathbb{R}^{w \times d}$  das  $i$ -te Snippet von  $d$ -dimensionalen Sensormessungen fester Länge  $w$  darstellt. Diese Messungen umfassen Beschleunigung, Geschwindigkeit und andere relevante Sensordaten vom Fahrwerk. Das Ziel ist es, anomale Ereignisse zu identifizieren, die auf potenzielle schädigende Auswirkungen auf die Federbeinlager hinweisen könnten. Formal streben wir an, eine Funktion  $f: \mathbb{R}^{w \times d} \rightarrow [0, 1]$  zu erlernen, die ein Fenster von Sensormessungen auf einen Anomalieindikator abbildet.

Die Hauptherausforderungen dieses Problems sind das Fehlen markierter Trainingsdaten und die zeitlichen Abhängigkeiten in den Datenproben. Darüber hinaus enthält der Datensatz selbst eine große Anzahl fehlender Werte, die vor dem Modelltraining behandelt werden müssen.

### 1.4.3 Datenanalyse & Vorverarbeitung

Die in diesem Anwendungsfall verwendeten Flottendaten bestehen aus neun Signalkanälen, darunter Fahrzeuggeschwindigkeit, Körperbeschleunigung und Fahrzeughöhe, gemessen an den vier Rädern, wie in Abbildung II.15 dargestellt. Diese Signale werden durch neun Felder in den Datentabellen angezeigt als:

- ESP\_v\_Signal
- FA\_BodyAcceleration\_HL
- FA\_BodyAcceleration\_HR
- FA\_BodyAcceleration\_VL
- FA\_BodyAcceleration\_VR
- FA\_Hohenwert\_HL\_00




Abbildung II.15: Signalen von Use Case Sonderereigniserkennung.

- FA\_Hohenwert\_HR\_00
- FA\_Hohenwert\_VL\_00
- FA\_Hohenwert\_VL\_00

Die Daten werden mit einer Frequenz von 50Hz aufgezeichnet, was einen detaillierten Blick auf die Fahrzeugdynamik während des Betriebs ermöglicht. Statistische Analyse und Datenvisualisierung werden durchgeführt, um die Datencharakteristiken und die Datenqualität zu verstehen, wie in Abbildung II.16 und Abbildung II.17 dargestellt.

- Es kann beobachtet werden, dass die Fahrzeuggeschwindigkeit (`ESP_v_Signal`) den höchsten Wertebereich zeigt, hauptsächlich im positiven Bereich zwischen 0–90 konzentriert. Die Verteilung erscheint im Allgemeinen relativ dicht und konsistent. Die Datenpunkte, die in den Bereich zwischen 70 und 90 fallen, sind relativ spärlich, aber mit einigen Clustern um 70–85.
- Vier Beschleunigungssignale (`FA_BodyAcceleration_*`) zeigen ähnliche Muster zueinander, mit Werten, die in einem schmalen Band um 0 konzentriert sind, mit einem Bereich von etwa -5 bis +5. Die Verteilung erscheint symmetrisch um Null, was auf ausgewogene Beschleunigungsmessungen hindeutet.

- Vier Fahrzeughöhenmerkmale ( $FA\_Hohenwert\_*$ ) zeigen deutliche Muster mit viel größerem Bereich als die Beschleunigungssignale. Die Werte verteilen sich zwischen etwa -60 bis +40. Das regelmäßige, gestreifte Muster in der Verteilung deutet auf eine relativ niedrige Wertauflösung in den Daten hin, was auf die Messbeschränkungen zurückzuführen sein könnte. Ähnliches Gesamtmuster über alle vier Höhenmessungen hinweg, ohne klar beobachtbare Konzentration von Punkten in einem bestimmten Bereich.

Die Empirische Verarbeitungsfunktionen (ECDFs), die in Abbildung II.17 gezeigt werden, bieten einige Einblicke in die Abtastcharakteristiken des Messsystems. Bei einer erwarteten Abtastrate von 50Hz, die 20ms-Intervallen zwischen aufeinanderfolgenden Messungen entspricht, zeigen die Diagramme sowohl das reguläre Abtastverhalten als auch Abweichungen davon. Das logarithmische Skalendiagramm (Abbildung II.17a) zeigt, dass die große Mehrheit der aufeinanderfolgenden Messungen (etwa mehr als 99%) tatsächlich dem erwarteten 20ms-Intervall folgt, was durch den scharfen vertikalen Anstieg an diesem Zeitpunkt belegt wird. Dieses Muster ist über alle neun Signale hinweg konsistent, was auf einen stabilen primären Abtastmechanismus hinweist. Das vergrößerte lineare Skalendiagramm (Abbildung II.17b) konzentriert sich auf die weniger häufigen, aber bemerkenswerten größeren Zeitdifferenzen und zeigt, dass die meisten Intervalle innerhalb der ersten 250 Sekunden auftreten, es aber gelegentliche Lücken gibt, die sich bis zu 1500 Sekunden erstrecken. Etwa 60-70% aller Intervalle fallen in den ersten 250-Sekunden-Bereich, danach zeigen die Kurven einen allmählichen Anstieg, was auf sporadisches Auftreten größerer Lücken hindeutet. Die Verteilung nähert sich 100% bei 1500 Sekunden, was darauf hindeutet, dass sehr wenige Lücken diese Dauer überschreiten.

Obwohl jedoch die meisten Zeitdifferenzen wünschenswert sind, müssen die verbleibenden fehlenden Werte, wie in Abbildung II.18 dargestellt, sorgfältig behandelt werden, bevor mit dem Modelltraining begonnen wird. Typische Ansätze für die Imputation fehlender Werte umfassen:

- Forward filling: Verbreitung des letzten beobachteten Wertes in die Zukunft.
- Backward filling: Verbreitung des nächsten beobachteten Wertes in die Vergangenheit.
- Lineare Interpolation: Auffüllen der fehlenden Werte mit linear interpolierten Werten.
- Matrix-Vervollständigung: Auffüllen der fehlenden Werte mit Low-Rank-Matrix-Vervollständigungstechniken.

Ein Vergleich zwischen verschiedenen Imputationsmethoden ist in Abbildung II.19 dargestellt, wobei die lineare Interpolation und Matrix-Vervollständigungsmethoden die anderen Methoden in Bezug auf Imputationsqualität übertreffen, und Matrix-Vervollständigungsmethoden einen leichten Vorteil gegenüber linearer Interpolation haben. Allerdings ist die Matrix-Vervollständigungsmethoden rechnerisch aufwendiger als die lineare Interpolation, was ein Problem sein könnte, das ihre Anwendung in großen Datensätzen einschränkt.

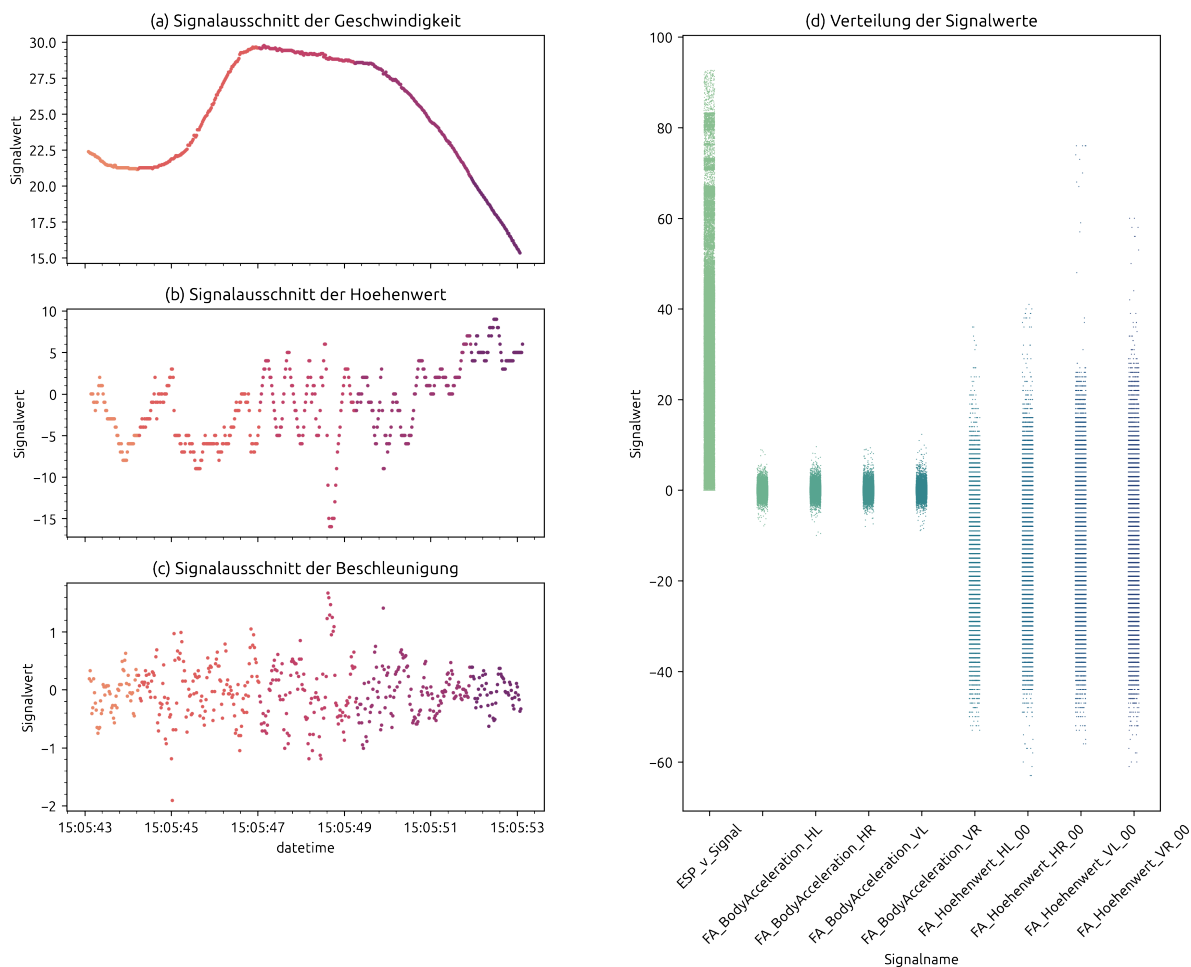
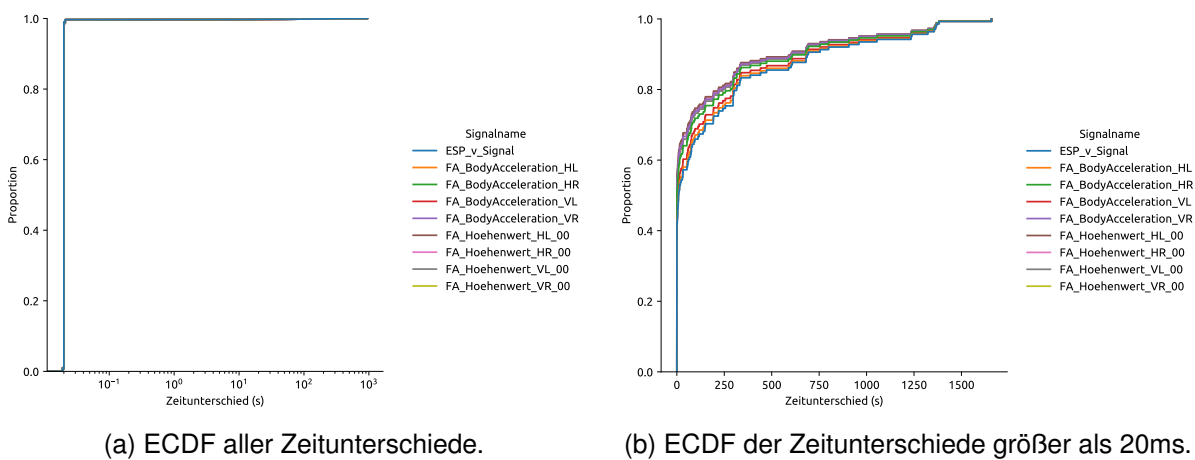


Abbildung II.16: Verteilung und Ausschnitte von Signalen.



(a) ECDF aller Zeitunterschiede.

(b) ECDF der Zeitunterschiede größer als 20ms.

Abbildung II.17: ECDF der Zeitunterschiede zwischen den Signalen.




Abbildung II.18: Diskontinuitäten in den Signalen.

#### 1.4.4 Vorläufiges Modell: Autoencoder basierend auf Temporal Convolutional Network

Um Anomalieerkennung zu realisieren, wurde ein vorläufiges Modell basierend auf Autoencoder (AE) und Temporal Convolutional Network (TCN) entworfen, wobei die Anomalien durch Vergleich zwischen dem Originalsignal und dem rekonstruierten Signal identifiziert werden können. Größere Diskrepanzen zwischen den Original- und rekonstruierten Signalen deuten auf eine höhere Wahrscheinlichkeit von Anomalien hin.

Die AEs sind neuronale Netzwerke, die für unüberwachtes Lernen konzipiert sind, bestehend aus einem Encoder und einem Decoder. Der Encoder komprimiert Eingabedaten in eine niedrigdimensionale latente Darstellung, während der Decoder die ursprüngliche Eingabe aus dieser Darstellung rekonstruiert. Durch die Minimierung des Rekonstruktionsfehlers lernen AEs, die zugrunde liegende Struktur der Daten zu erfassen. Eine Schlüsselanwendung von AEs ist die Anomalieerkennung. Da sie trainiert werden, normale Datenmuster zu rekonstruieren, führen Anomalien — die von diesen Mustern abweichen — zu hohen Rekonstruktionsfehlern. Dies macht AEs effektiv bei der Identifizierung von Ausreißern oder ungewöhnlichen Datenpunkten in Bereichen wie Betrugserkennung, Netzwerksicherheit und industrieller Überwachung. Ihre Fähigkeit, Datenrepräsentationen ohne markierte Beispiele zu lernen, macht sie besonders wertvoll für die Erkennung von Anomalien in unüberwachten Einstellungen.

Bei der Anwendung auf Zeitreihendaten in diesem Anwendungsfall kann AE durch die Nutzung von TCNs als ihre Kernarchitektur verbessert werden. TCNs verwenden dilatierte kausale Faltungen, um zeitliche Abhängigkeiten in den Daten zu erfassen, was sie gut für die Modellierung von Sequenzen geeignet macht. In einem TCN-basierten AE verwendet der Encoder gestapelte zeitliche Faltungsschichten, um hierarchische Merkmale zu extrahieren und die Eingabesequenz in eine latente Darstellung zu komprimieren. Der Decoder verwendet dann ähnliche zeitliche Faltungen, um die Sequenz aus dieser Darstellung zu rekonstruieren. Diese Architektur zeichnet sich durch das Lernen zeitlicher Muster aus, was präzise Rekonstruktion normaler Sequenzen und hohe Rekonstruktionsfehler für anomale ermöglicht.

Als vorläufige Exploration haben wir das TCN-basierte AE-Modell auf dem vorverarbeiteten




Abbildung II.19: Vergleich der Imputationsmethoden.

Datensatz trainiert. Das Modell lernt, normales Fahrverhalten durch Training zu kodieren und zu dekodieren, da Anomalien selten sind und in den Daten nicht gut repräsentiert sind. Nach dem Training wird der Rekonstruktionsfehler verwendet, um Anomalien zu erkennen: Hohe Fehler deuten auf Abweichungen von normalen Mustern hin und kennzeichnen potenzielle Sonderereignisse. Beispiele für Rekonstruktionen sind in Abbildung II.20 dargestellt. Ein Schwellenwert kann später basierend auf der Fehlerverteilung gesetzt werden, um Anomalien zu klassifizieren, was dem System ermöglicht, ungewöhnliche Fahrereignisse ohne Notwendigkeit markierter Anomaliedaten zu identifizieren.

## 1.5 Use Case: Spur/Sturz

### 1.5.1 Hintergrund


Radeinstellungsmerkmale beeinflussen signifikant die Fahrzeugdynamik und die Lebensdauer der Reifen. Der Anwendungsfall *Spur/Sturz* konzentriert sich auf die Entwicklung eines prädiktiven Ansatzes zur Schätzung des Reifenverschleißfortschritts durch die Analyse des Lenkungssystemverhaltens. Während die traditionelle Reifenverschleißbewertung typischerweise auf periodischen manuellen Inspektionen basiert, zielt dieser Ansatz darauf ab, eine datengestützte Methodik für kontinuierliche Verschleißüberwachung unter Verwendung leicht verfügbarer Fahrzeugsensordaten zu etablieren. Der Anwendungsfall nutzt Lenkradwinkelmessungen in Korrelation mit akkumulierter Fahrleistung, um Verschleißprogressionsmuster zu modellieren, die Einblicke in die Reifenabnutzung über die Zeit liefern, was als Ersatz für die Aufgabe der RUL-Vorhersage dient. Die vereinfachte Methodik wurde aufgrund ihrer robusten Datenverfügbarkeit und direkten Beziehung zu Fahrzeugbetriebsbedingungen gewählt. Der Ansatz baut auf etablierten Fahrzeugdynamikprinzipien auf, wobei das Lenkverhalten als Ersatzindikator für den Gesamtzustand des Radsystems dient. Durch die Entwicklung dieses Beziehungsmodells kann der Anwendungsfall die Machbarkeit der Implementierung von PM-Strategien unter Verwendung bestehender Fahrzeugsensorinfrastruktur demonstrieren. Die aus dieser Analyse gewonnenen Erkenntnisse legen den Grundstein für umfassendere RUL-Vorhersagemodelle, die potenziell zusätzliche Fahrzeugparameter in zukünftigen Entwicklungen einbeziehen könnten.

### 1.5.2 Problemformulierung


Die formalisierte Formulierung des untersuchten Problems in diesem Anwendungsfall ist wie folgt:

#### **Problem 4. Fahrzeugverschleißvorhersage**

Gegeben ist eine Menge von Lenkradwinkelmessungen  $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^N$  und entsprechender Kilometerstand  $\mathbf{M} = \{m_i\}_{i=1}^N$ , wobei  $\mathbf{x}_i \in \mathbb{R}^{w_i}$  ein Fenster von Lenkradwinkelmessungen und  $m_i \in \mathbb{R}$  die durchschnittliche Kilometerstand zum Zeitpunkt  $i$  darstellt. Das Ziel ist es, eine



(a) Normales Signal und rekonstruiertes Signal.



(b) Anormales Signal und rekonstruiertes Signal.

Abbildung II.20: Vergleich der Rekonstruktionsleistung zwischen normalen und anomalen Signalen mittels Autoencoder-Modell.

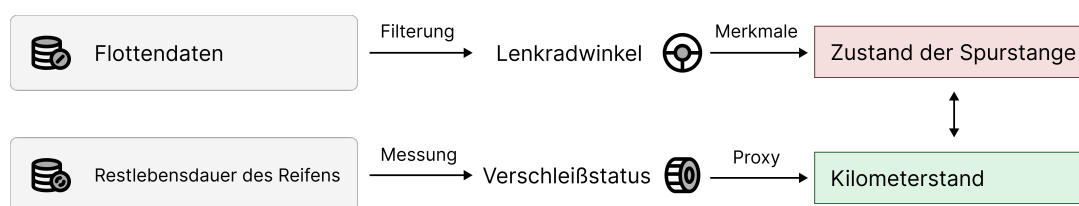


Abbildung II.21: Überblick über die Modellierungspipeline.

Funktion  $h : \mathbb{R}^d \rightarrow \mathbb{R}$  zu erlernen, die einen  $d$ -dimensionalen Merkmalsvektor, der aus den Lenkradwinkelmessungen extrahiert wurde, auf die entsprechende Kilometerstand als Ersatzschätzung der Restlebensdauer des Reifens abbildet.

### 1.5.3 Datenanalyse und ein lineares Modell

Eine datengetriebene Pipeline für die Restlebensdauervorhersage wurde mit drei Hauptkomponenten entwickelt: Datenvorverarbeitung, Merkmalsextraktion und Modelltraining. Die Pipeline korreliert Merkmale, die aus Lenkraddaten extrahiert wurden, mit Labels, die aus Kilometerstandsdaten abgeleitet wurden, was als Proxy für die Schätzung des Reifenverschleißes im Zusammenhang mit abnormalem Status der Spurstange dient. Dieser kilometerstandbasierte Ansatz kann durch die tatsächliche Restlebensdauer ersetzt werden, wenn solche Daten verfügbar werden.

Die Datenanalyse und Vorverarbeitungsschritte können in drei Schritte zusammengefasst werden:

1. Die Lenkradwinkelndaten jedes Fahrzeugs werden zunächst in Segmente mit fester Bins der Bins der Kilometerstand aufgeteilt.
2. Merkmale werden aus jedem Segment extrahiert, um das Fahrverhalten darzustellen.
3. Visualisierung wird eingesetzt, um die Beziehungen zwischen Messverteilungen zu verstehen. Wie in Abbildung II.22 dargestellt, scheint es eine allmähliche Verschiebung der Verteilung mit zunehmender Kilometerstand zu geben, was darauf hindeutet, dass der Fahrzeugverschleiß potenziell durch die Dynamik der Lenkradwinkelndmessungen erfasst werden kann.
4. Die Merkmale und Labels werden verwendet, um ein Regressionsmodell zu trainieren, das die Kilometerstand basierend auf den Lenkradwinkelnddaten schätzt.

Relevante Merkmale wurden aus Sensordaten extrahiert und durch rekursive randomisierte Merkmalseliminierung ausgewählt. Die resultierende Merkmalsliste umfasst:

- `median`: der Median der Messungen.
- `bowley_skew`: die Bowley-Schiefe der Messungen.

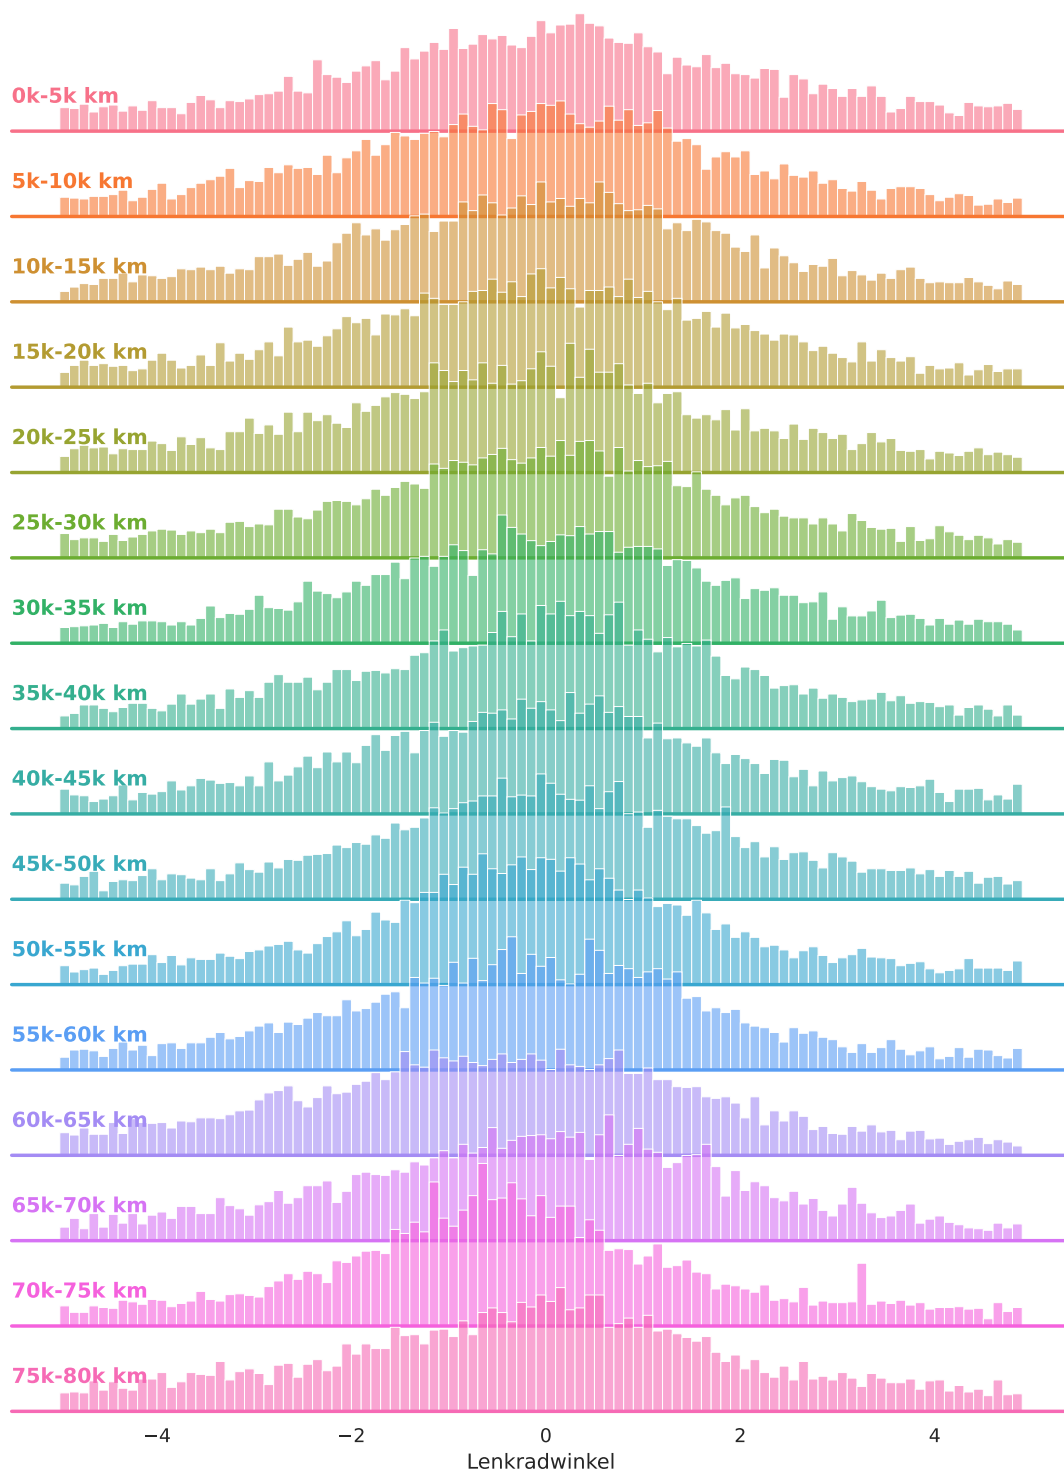


Abbildung II.22: Gestapeltes Histogramm der Lenkradwinkel in Bezug auf die Bins der Kilometerstand.

Tabelle II.6: Regressionsergebnisse

Variable	Koeffizient	Std. Fehler	P-Wert
median	+1,49	0,93	0,127
bowley_skew	-34,07	1,05	0,005
median_abs_dev	+1,17	0,31	0,001
R <sup>2</sup>			0,806
Adj-R <sup>2</sup>			0,774
BIC			499,7

- `median_abs_dev`: der Median der absoluten Abweichung jeder Messung.

Die Trainingslabels wurden mit Daten-Binning-Techniken verarbeitet, um die Schätzungsrobustheit zu verbessern. Ein lineares Regressionsmodell wird für diese Aufgabe gewählt und erscheint effektiv, wie in Tabelle II.6 dargestellt, was einen adjusted-R<sup>2</sup> Score von 0,774 zeigt.

## 2 Wichtigste Positionen des zahlenmäßigen Nachweises

Zwei Posten sind für die TUM im zahlenmäßigen Nachweis relevant: Personalausgaben (0812) und Dienstreisen (0846).

### 2.1 Personalausgaben (0812)

Die Personalkosten haben weitgehend der ursprünglichen Budgetplanung entsprochen. Das Forschungsteam hat kontinuierlich Arbeitsstunden für die Entwicklung und Implementierung von Machine-Learning-Modellen für Predictive Maintenance aufgewendet.

### 2.2 Dienstreisen (0846)

Es gab eine Reduzierung der Reisekosten im Vergleich zum ursprünglichen Budget. Diese Reduzierung kann auf zwei Hauptfaktoren zurückgeführt werden:

- Die Reisekosten wurden durch pandemiebedingte Reisebeschränkungen beeinflusst, insbesondere während der frühen Projektphasen. Die reduzierten Reisekosten hatten keine negativen Auswirkungen auf die Projektergebnisse, da das Konsortium erfolgreich auf digitale Kollaborationstools und Online-Meeting-Formate umgestellt hat.
- Außerdem hat die Pandemie eine Verschiebung hin zu verstärkter Remote-Zusammenarbeit und virtuellen Meetings mit Projektpartnern bewirkt. In Anbetracht der Tatsache, dass

sich die meisten Aufgaben im Zusammenhang mit der TUM um Datenanalyse und Modellentwicklung drehen, konnte das Projektteam die Produktivität und Zusammenarbeit ohne die Notwendigkeit von Aktivitäten wie Vor-Ort-Messungen aufrechterhalten.

Insgesamt zeigt das Finanzmanagement die Einhaltung des geplanten Budgetrahmens bei gleichzeitiger Anpassung an veränderte Umstände.

### 3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die im PANAMERA-Projekt durchgeführte Arbeit zeigt eine klare Notwendigkeit und angemessene Strukturierung über seine Arbeitspakete hinweg:

#### 3.1 Notwendigkeit der einzelnen Arbeitspakete

- *Anwendungsszenarien, Anforderungsanalyse und Systemspezifikation (AP 1)*: Es liefert wesentliche Grundlagenarbeit, die Anwendungsfälle und Systemanforderungen definiert, was entscheidend für die Etablierung der Gesamtarchitektur und die Schaffung von Abstimmung zwischen Konsortialpartnern ist.
- *Entwicklung des PANAMERA-Referenzmodells (AP 2)*: Es ist ein Kern-Arbeitspaket, das das Hauptprojektziel eines modularen Toolkits liefert, was entscheidend für die Standardisierung von Predictive-Maintenance-Entwicklungsansätzen und die Etablierung von Metriken zur Bewertung der Modularwiederverwendbarkeit ist.
- *Datenerfassung und Datenvorverarbeitung (AP 3)*: Es ist grundlegend für die Bereitstellung von Qualitätseingabedaten für die Modellentwicklung, notwendige Integration von Fahrzeugsensoren und externen Messsystemen und wesentliche Vorverarbeitungs-Workflows für die Handhabung von Flottendaten und hochfrequenten Sensordaten.
- *Zentrale Cloud-Datenplattform (AP 4)*: Es bietet kritische Infrastruktur, die Datenspeicherung und -verarbeitung im Flottenmaßstab ermöglicht, standardisierte Datenverarbeitungs Pipelines implementiert und sichere und effiziente Datenverwaltung über alle Projektkomponenten hinweg gewährleistet.
- *Zentrale Analytics-Datenplattform (AP 5)*: Es dient als Schlüsselfaktor für Datenvisualisierung und -analyse, bietet notwendige Tools für die interaktive Erkundung von Sensordaten und kritische Funktionen für die Überwachung der Modelleistung und Datenqualität.
- *Entwicklung der Verschleißmodelle (AP 6)*: Es stellt die wissenschaftliche Kernarbeit der Entwicklung von Predictive-Maintenance-Modellen dar, die wesentlich für die Validierung des modularen Ansatzes und die Demonstration der praktischen Anwendbarkeit in realen Szenarien ist.

- *Demonstration und Bewertung (AP 7)*: Es bietet kritische Validierung der Projektergebnisse, Bewertung der industriellen Anwendbarkeit und wesentliche Dokumentation der erreichten Vorteile und Erkenntnisse aus der Implementierung.

### 3.2 Angemessenheit der Arbeitspaketstruktur

Die Arbeitspaketstruktur zeigt angemessene Abfolge und Abhängigkeiten. In Bezug auf den logischen Fluss sind die Arbeitspakete so strukturiert, dass sie aufeinander aufbauen, mit angemessener paralleler Entwicklung komplementärer Komponenten. AP 1 legt die Grundlagen für die nachfolgende Arbeit, während AP 2-AP 6 angemessene parallele Entwicklung komplementärer Komponenten zeigen. AP 7 schließt angemessen mit Evaluation und Demonstration ab.

Die Verteilung der Arbeit unter den Konsortialpartnern zeigt sorgfältige Berücksichtigung von Expertise und Fähigkeiten. Industrielle und akademische Partner sind in einer Weise ausbalanciert, die ihre jeweiligen Stärken nutzt, wobei Industriepartner (PAG, areto, AMI, ExpertSystems) praktische Anwendungen und Daten bereitstellen, während akademische Partner (IPA, TUM) methodisches Fachwissen und Forschungsstrenge beitragen. Die Koordination zwischen Datenerfassungs-, Verarbeitungs- und Analyseaufgaben ist so strukturiert, dass ein effizienter Arbeitsablauf und maximaler Wissenstransfer zwischen Partnern gewährleistet ist.

Die Notwendigkeit und Angemessenheit dieser Arbeitsstruktur wird durch mehrere Schlüsselergebnisse validiert. Das Projekt hat konsequent seine definierten Meilensteine erreicht und sich erfolgreich an technische Herausforderungen angepasst, wie die Migration von Amazon Web Services (AWS) zur Azure-Cloud-Plattform. Es gab eine klare Progression in Richtung der Projektziele, belegt durch die erfolgreiche Entwicklung von Predictive-Maintenance-Modellen und unterstützender Infrastruktur.

## 4 Voraussichtlicher Nutzen

Das PANAMERA-Projekt bietet der TUM signifikantes Potenzial zur Förderung wissenschaftlicher Forschung und Lehre im Bereich datengetriebener Mobilitätssysteme. Die entwickelten Methoden und Erkenntnisse werden auf mehreren Ebenen genutzt werden.

Die im Projekt entwickelten Referenzmodelle und Predictive-Maintenance-Techniken leisten einen wichtigen Beitrag zur Weiterentwicklung der Fahrzeugtechnik. Die systematische Integration von Flottenanalytik und Predictive-Maintenance-Strategien ermöglicht nicht nur eine verbesserte Nutzererfahrung durch vorausschauende Wartung, sondern trägt auch zu höherer Fahrsicherheit bei. Darüber hinaus unterstützt der entwickelte Ansatz eine nachhaltige Nutzung von Fahrzeugkomponenten durch optimierte Wartungszyklen.

Die in AP 6 entwickelte Methodologie für die Verschleißmodellierung bietet wertvolle Transfermöglichkeiten zu anderen Forschungsfeldern. Insbesondere können die entwickelten Ma-

trixfaktorisierungstechniken in der Verkehrsdynamikforschung für die Analyse spärlicher Datenstrukturen angewendet werden. Die implementierten Deep-Learning-Architekturen bieten neue Erkenntnisse für die räumlich-zeitliche Modellierung komplexer Systeme und erweitern damit das methodische Repertoire der Verkehrssystemanalyse.

Die im Projekt realisierte Integration von Cloud-Entwicklungsplattform und modularem Framework schafft eine wichtige Grundlage für zukünftige Forschungsaktivitäten. Der standardisierte Workflow ermöglicht eine bessere Reproduzierbarkeit von Forschungsergebnissen und beschleunigt den Transfer zu industriellen Anwendungen. Diese Erfahrungen fließen direkt in die Lehre ein und bieten Studierenden praktische Einblicke in moderne Entwicklungsprozesse. Das gewonnene Wissen kann auch in den entsprechenden Masterstudiengang und die Doktorandenseminare an der TUM integriert werden und bildet die Grundlage für weitere Forschungsprojekte im Bereich intelligenter Mobilitätssysteme.

## 5 Fortschritte bei anderen Stellen

Während die Forschung zum datengetriebenen Predictive Maintenance, einschließlich Verschleißmodellierung und Restlebensdauervorhersage, in der allgemeinen Industriebranche erheblich an Popularität gewonnen hat [71–73], sind entsprechende Fortschritte im Automobilsektor relativ selten. Die begrenzten Fortschritte im Automobilbereich drehen sich meist um Predictive-Maintenance-Modelle für Elektrofahrzeug (EV), insbesondere die EV-Batterie [74–76].

Aus der Perspektive der Machine-Learning-Methodologie im Zusammenhang mit Audioverarbeitung gab es während des Projekts einen signifikanten Fortschritt im Bereich der Spracherkennung, die eine ähnliche methodische Grundlage mit der Automobilaudiodatenanalyse teilt. Der Forschungstrend kann wie folgt zusammengefasst werden:

- Skalierung der Modellgröße zur Verbesserung der Erkennungsgenauigkeit [44, 77]: Die erhöhte Rechenleistung und Datenverfügbarkeit haben das Training größerer Modelle ermöglicht, die überlegene Leistung in verschiedenen Audioverarbeitungsaufgaben gezeigt haben. Wenn es jedoch um Automobilanwendungen geht, muss die Modellgröße aufgrund der Einschränkungen der Rechenressourcen an Bord, hoher Kosten für drahtlose Kommunikation und Echtzeitverarbeitungsanforderungen sorgfältig begrenzt werden.
- Few-Shot-Learning für schnelle Anpassung an Out-of-Distribution-Aufgaben und ressourcenarme Szenarien [46, 78]: Die Fähigkeit, sich schnell mit begrenzten Daten an neue Aufgaben anzupassen, ist entscheidend für die Audioverarbeitung im Automobilbereich, wo die Audioumgebung über verschiedene Fahrzeugmodelle und Fahrbedingungen hinweg erheblich variieren kann. Es ermöglicht auch den schnellen Transfer von vortrainierten Modellen zu neuen Sensoren und neuen Anomalien ohne die Notwendigkeit umfangreicher Testfahrten.

## 6 Veröffentlichungen

Aus den im PANAMERA-Projekt entwickelten Techniken und Methodologien abgeleitete akademische Arbeiten wurden in mehreren wissenschaftlichen Foren veröffentlicht. Die Veröffentlichungen decken ein breites Spektrum an Themen ab, darunter das standardisierte Predictive-Maintenance-Framework in *CIRP Conference on Intelligent Computation in Manufacturing Engineering* [79], die tensorbasierten Ansätze zur Wiederherstellung spärlicher Verkehrsdaten in *IEEE International Conference on Intelligent Transportation Systems* [80] und *Transportation Research Part C: Emerging Technologies* [81]. Es gibt auch geplante Veröffentlichungen bezüglich der in AP 6 entwickelten Verschleißmodelle, die bei relevanten Fachzeitschriften im Bereich der Verkehrssysteme und Fahrzeugtechnik eingereicht werden sollen.

## Abbildungsverzeichnis

I.1	PANAMERA Project Timeline . . . . .	6
II.1	Zusammenfassung der Literatur zu Automobil-Predictive-Maintenance-Modellen. . . . .	12
II.2	Kedro-Pipeline für automatische Datenkennzeichnung im Anwendungsfall Bremsgeräusche. . . . .	14
II.3	Kedro-Pipeline für Klassifikationsmodell im Anwendungsfall Bremsgeräusche. . . . .	14
II.4	Überblick über das Framework. . . . .	16
II.5	Überblick über den gesamten Workflow mit Demonstration und Bewertung der Modelleistung . . . . .	17
II.6	Vergleich der Spektrogrammskalen: Linear, Mel und Symlog. . . . .	20
II.7	Spektrogrammzerlegungsergebnisse mit RNMF. . . . .	24
II.8	Komponentenweise Rekonstruktion mit RNMF. . . . .	25
II.9	Extrahierte Frequenzkomponenten mit RNMF. . . . .	25
II.10	Aktivierungskoeffizienten der extrahierten Komponenten. . . . .	27
II.11	Gegenüberstellung der Verarbeitungsworkflows. . . . .	27
II.12	Gegenüberstellung der Kandidaten-Netzwerkarchitekturen. . . . .	29
II.13	Spektrogramm-Mixup zur Datenaugmentation. . . . .	31
II.14	Einfluss des Mixup-Koeffizienten auf SNR und Klassifikationsgenauigkeit. . . . .	34
II.15	Signalen von Use Case Sonderereigniserkennung. . . . .	36
II.16	Verteilung und Ausschnitte von Signalen. . . . .	38
II.17	ECDF der Zeitunterschiede zwischen den Signalen. . . . .	38
II.18	Diskontinuitäten in den Signalen. . . . .	39
II.19	Vergleich der Imputationsmethoden. . . . .	40
II.20	Vergleich der Rekonstruktionsleistung zwischen normalen und anomalen Signalen mittels Autoencoder-Modell. . . . .	42
II.21	Überblick über die Modellierungspipeline. . . . .	43
II.22	Gestapeltes Histogramm der Lenkradwinkel in Bezug auf die Bins der Kilometerstand. . . . .	44

## Tabellenverzeichnis

II.1	Vergleich von PCA, ICA und NMF für die Spektrogrammzerlegung. . . . .	21
II.2	Klassifikationsleistung verschiedener Modelle. . . . .	31
II.3	Einfluss der Verlustfunktion und $\gamma$ auf die Leistung. . . . .	33
II.4	Ablationsstudie des Conv-MLP-Modells. . . . .	33
II.5	Rechenkomplexität verschiedener Modelle. . . . .	33
II.6	Regressionsergebnisse . . . . .	45

## Abkürzungsverzeichnis

<b>AE</b> Autoencoder .....	2, 39
<b>AMI</b> AMITRONICS Angewandte Mikromechatronik GmbH .....	7, 47
<b>ANN</b> Artificial Neural Network .....	12
<b>areto</b> areto consulting GmbH .....	7, 47
<b>ARMA</b> Autoregressive Moving Average .....	12
<b>ASUM-DM</b> Analytics Solutions Unified Method for Data Mining & Predictive Analytics .....	9
<b>AWS</b> Amazon Web Services .....	47
<b>CNN</b> Convolutional Neural Network .....	7, 12, 26, 29–33
<b>CRISP-DM</b> Cross Industry Standard Process for Data Mining .....	9, 10
<b>CRISP-ML(Q)</b> Cross-Industry Standard Process model for Machine Learning with Quality Assurance .....	9
<b>DMME</b> Data Mining Methodology for Engineering Applications .....	10
<b>ECDF</b> Empirische Verarbeitungsfunktion .....	37, 38, 50
<b>EFP</b> Event Frequency Processor .....	15
<b>EV</b> Elektrofahrzeug .....	48
<b>ExxpertSystems</b> ExxpertSystems GmbH .....	7, 47
<b>GBDT</b> Gradient Boosting Decision Tree .....	12, 23, 30, 31
<b>gMLP</b> gated-MLP .....	26, 30, 32
<b>HMM</b> Hidden Markov Model .....	12
<b>ICA</b> Independent Component Analysis .....	7, 19, 21, 51

---

<b>IPA</b> Fraunhofer-Institut für Produktionstechnik und Automatisierung .....	7, 47
<b>KDD</b> Knowledge Discovery in Databases .....	8
<b>LSTM</b> Long-Short Term Memory .....	12
<b>MDP</b> Model Development Process .....	10
<b>ML</b> Machine Learning .....	4, 5, 10, 23, 26, 27, 30
<b>MLOps</b> Machine Learning Operations .....	8, 10
<b>MLP</b> Multi-Layer Perceptron .....	26, 29, 30, 32
<b>NMF</b> Nicht-negative Matrixfaktorisierung .....	7, 19, 21, 22, 51
<b>NN</b> Neural Network .....	23, 26, 30
<b>PAG</b> Dr.-Ing. h.c. F. Porsche AG .....	5, 7, 47
<b>PCA</b> Principal Component Analysis .....	19, 21, 51
<b>PM</b> Predictive Maintenance .....	4, 8, 10, 11, 13, 15, 23, 41
<b>POST-DS</b> Process Organization and Scheduling electing Tools for Data Science .....	10
<b>RCS</b> Road Condition Sensor .....	15, 16, 23, 26
<b>RF</b> Random Forest .....	12
<b>RNMF</b> Regularisierte Nicht-negative Matrixfaktorisierung .....	19, 22–25, 50
<b>RNN</b> Recurrent Neural Network .....	12
<b>RUL</b> Restlebensdauer .....	11–13, 41
<b>SAE</b> Stacked Autoencoder .....	12
<b>SEMMA</b> Sampling, Exploring, Modifying, Modeling, and Assessing .....	9
<b>STFT</b> Short-Time Fourier Transform .....	18, 23
<b>TCN</b> Temporal Convolutional Network .....	2, 39
<b>TDSP</b> Team Data Science Process .....	9
<b>TUM</b> Technische Universität München .....	4, 5, 7, 35, 45–48

## Literaturverzeichnis

- [1] Haitao Liao und Jay Lee. „Predictive Monitoring and Failure Prevention of Vehicle Electronic Components and Sensor Systems“. In: *SAE Transactions* 115.7 (2006), S. 240–246. DOI: 10.4271/2006-01-0373.
- [2] Hong-Bae Jun u. a. „Predictive Algorithm to Determine the Suitable Time to Change Automotive Engine Oil“. In: *Computers & Industrial Engineering* 51.4 (2006), S. 671–683. DOI: 10.1016/j.cie.2006.06.017.
- [3] John T. Renwick und Paul E. Babson. „Vibration Analysis: A Proven Technique as a Predictive Maintenance Tool“. In: *IEEE Transactions on Industry Applications* IA-21.2 (1985), S. 324–332. DOI: 10.1109/TIA.1985.349652.
- [4] Rune Prytz u. a. „Predicting the Need for Vehicle Compressor Repairs Using Maintenance Records and Logged Vehicle Data“. In: *Engineering Applications of Artificial Intelligence* 41 (2015), S. 139–150. DOI: 10.1016/j.engappai.2015.02.009.
- [5] Chaitanya Sankavaram u. a. „Incremental Classifiers for Data-Driven Fault Diagnosis Applied to Automotive Systems“. In: *IEEE Access* 3 (2015), S. 407–419. DOI: 10.1109/ACCESS.2015.2422833.
- [6] Shen Yin und Zenghui Huang. „Performance Monitoring for Vehicle Suspension System via Fuzzy Positivistic C-means Clustering Based on Accelerometer Measurements“. In: *IEEE/ASME Transactions on Mechatronics* 20.5 (2015), S. 2613–2620. DOI: 10.1109/TMECH.2014.2358674.
- [7] Kong Soon Ng u. a. „Enhanced Coulomb Counting Method for Estimating State-of-Charge and State-of-Health of Lithium-Ion Batteries“. In: *Applied Energy* 86.9 (2009), S. 1506–1511. DOI: 10.1016/j.apenergy.2008.11.021.
- [8] Jirachai Buddhakulsomsiri und Armen Zakarian. „Sequential Pattern Mining Algorithm for Automotive Warranty Data“. In: *Computers & Industrial Engineering* 57.1 (2009), S. 137–147. DOI: 10.1016/j.cie.2008.11.006.
- [9] Mark Last, Alla Sinaiski und Halasya Siva Subramania. „Predictive Maintenance with Multi-Target Classification Models“. In: *Intelligent Information and Database Systems*. Bd. 5991. Berlin, Heidelberg: Springer, 2010, S. 368–377. DOI: 10.1007/978-3-642-12101-2\_38.

- [10] Vandan Revanur u. a. „Embeddings Based Parallel Stacked Autoencoder Approach for Dimensionality Reduction and Predictive Maintenance of Vehicles“. In: *IoT Streams for Data-Driven Predictive Maintenance and IoT, Edge, and Mobile for Embedded Machine Learning*. Bd. 1325. Cham: Springer, 2020, S. 127–141. DOI: 10.1007/978-3-030-66770-2\_10.
- [11] Iron Tessaro, Viviana Cocco Mariani und Leandro dos Santos Coelho. „Machine Learning Models Applied to Predictive Maintenance in Automotive Engine Components“. In: *Proceedings of 1st International Electronic Conference on Actuator Technology: Materials, Devices and Applications*. Sciforum.net: MDPI, 2020, S. 8508. DOI: 10.3390/IeCAT2020-08508.
- [12] Thorsteinn Rögnvaldsson u. a. „Self-Monitoring for Maintenance of Vehicle Fleets“. In: *Data Mining and Knowledge Discovery 32.2* (2018), S. 344–384. DOI: 10.1007/s10618-017-0538-6.
- [13] Uferah Shafi u. a. „Vehicle Remote Health Monitoring and Prognostic Maintenance System“. In: *Journal of Advanced Transportation 2018* (2018), S. 1–10. DOI: 10.1155/2018/8061514.
- [14] António Simões u. a. „The State of the Art of Hidden Markov Models for Predictive Maintenance of Diesel Engines: HMM for Predictive Maintenance of Diesel Engines“. In: *Quality and Reliability Engineering International 33.8* (2017), S. 2765–2779. DOI: 10.1002/qre.2130.
- [15] Andreas Theissler. „Detecting Known and Unknown Faults in Automotive Systems Using Ensemble-Based Anomaly Detection“. In: *Knowledge-Based Systems 123* (2017), S. 163–173. DOI: 10.1016/j.knosys.2017.02.023.
- [16] Yang Zhao u. a. „Fault and Defect Diagnosis of Battery for Electric Vehicles Based on Big Data Analysis Methods“. In: *Applied Energy 207* (2017), S. 354–362. DOI: 10.1016/j.apenergy.2017.05.139.
- [17] Stefan Byttner u. a. „A Field Test with Self-Organized Modeling for Knowledge Discovery in a Fleet of City Buses“. In: *2013 IEEE International Conference on Mechatronics and Automation*. Takamatsu, Kagawa, Japan: IEEE, 2013, S. 896–901. DOI: 10.1109/ICMA.2013.6618034.
- [18] Dnyanesh G. Rajpathak. „An Ontology Based Text Mining System for Knowledge Discovery from the Diagnosis Data in the Automotive Domain“. In: *Computers in Industry 64.5* (2013), S. 565–580. DOI: 10.1016/j.compind.2013.03.001.
- [19] Haihong Pan u. a. „Novel Battery State-of-Health Online Estimation Method Using Multiple Health Indicators and an Extreme Learning Machine“. In: *Energy 160* (2018), S. 466–477. DOI: 10.1016/j.energy.2018.06.220.
- [20] Daming Zhou u. a. „Online Remaining Useful Lifetime Prediction of Proton Exchange Membrane Fuel Cells Using a Novel Robust Methodology“. In: *Journal of Power Sources 399* (2018), S. 314–328. DOI: 10.1016/j.jpowsour.2018.06.098.

- [21] Jian Zuo u. a. „Deep Learning Based Prognostic Framework towards Proton Exchange Membrane Fuel Cell for Automotive Application“. In: *Applied Energy* 281 (2021), S. 115937. DOI: 10.1016/j.apenergy.2020.115937.
- [22] Merten Stender u. a. „Deep Learning for Brake Squeal: Brake Noise Detection, Characterization and Prediction“. In: *Mechanical Systems and Signal Processing* 149 (2021), S. 107181. DOI: 10.1016/j.ymsp.2020.107181.
- [23] Shuwen Wang u. a. „Prediction of Frictional Braking Noise Based on Brake Dynamometer Test and Artificial Intelligent Algorithms“. In: *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* (2021), S. 095440702110622. DOI: 10.1177/09544070211062276.
- [24] Danilo Giordano u. a. „Data-Driven Strategies for Predictive Maintenance: Lesson Learned from an Automotive Use Case“. In: *Computers in Industry* 134 (2022), S. 103554. DOI: 10.1016/j.compind.2021.103554.
- [25] T. M. Alamelu Manghai und R. Jegadeeshwaran. „Vibration Based Brake Health Monitoring Using Wavelet Features: A Machine Learning Approach“. In: *Journal of Vibration and Control* 25.18 (2019), S. 2534–2550. DOI: 10.1177/1077546319859704.
- [26] Lorenzo Perini. „Predictive Maintenance for Off-Road Vehicles Based on Hidden Markov Models and Autoencoders for Trend Anomaly Detection“. Magisterarb. Turin, Italy: Politecnico di Torino, 2019.
- [27] Parivash Pirasteh u. a. „Interactive Feature Extraction for Diagnostic Trouble Codes in Predictive Maintenance: A Case Study from Automotive Domain“. In: *Proceedings of the Workshop on Interactive Data Mining*. Melbourne, Australia: ACM Press, 2019, S. 1–10. DOI: 10.1145/3304079.3310288.
- [28] Dengyu Xiao u. a. „Domain Adaptive Motor Fault Diagnosis Using Deep Transfer Learning“. In: *IEEE Access* 7 (2019), S. 80937–80949. DOI: 10.1109/ACCESS.2019.2921480.
- [29] Wenbo Yu, Xuejiao Li und Yong Sun. *Towards Making Predictive Maintenance System Adaptive and Interpretable*. Preprint. 2021. DOI: 10.20944/preprints202107.0040.v1.
- [30] John R. Hershey u. a. „Deep Clustering: Discriminative Embeddings for Segmentation and Separation“. In: *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Shanghai, China: IEEE, 2016, S. 31–35. DOI: 10.1109/ICASSP.2016.7471631.
- [31] Yi Luo und Nima Mesgarani. „TaSNet: Time-Domain Audio Separation Network for Real-Time, Single-Channel Speech Separation“. In: *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Calgary, AB, USA: IEEE, 2018, S. 696–700. DOI: 10.1109/ICASSP.2018.8462116.

- [32] Ilya Kavalero v u. a. „Universal Sound Separation“. In: *2019 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA)*. New Paltz, NY, USA: IEEE, 2019, S. 175–179. DOI: 10.1109/WASPAA.2019.8937253.
- [33] Steffen Schneider u. a. „Wav2vec: Unsupervised Pre-Training for Speech Recognition“. In: *Interspeech 2019*. Graz, Austria: ISCA, 2019, S. 3465–3469. DOI: 10.21437/Interspeech.2019-1873.
- [34] Yi Luo und Nima Mesgarani. „Conv-TasNet: Surpassing Ideal Time–Frequency Magnitude Masking for Speech Separation“. In: *IEEE/ACM Transactions on Audio, Speech, and Language Processing* 27.8 (2019), S. 1256–1266. DOI: 10.1109/TASLP.2019.2915167.
- [35] Valentin Leplat, Andersen M.S. Ang und Nicolas Gillis. „Minimum-Volume Rank-deficient Nonnegative Matrix Factorizations“. In: *2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Brighton, United Kingdom: IEEE, 2019, S. 3402–3406. DOI: 10.1109/ICASSP.2019.8682280.
- [36] Valentin Leplat, Nicolas Gillis und Andersen M.S. Ang. „Blind Audio Source Separation With Minimum-Volume Beta-Divergence NMF“. In: *IEEE Transactions on Signal Processing* 68 (2020), S. 3400–3410. DOI: 10.1109/TSP.2020.2991801.
- [37] Qiuqiang Kong u. a. „PANNs: Large-Scale Pretrained Audio Neural Networks for Audio Pattern Recognition“. In: *IEEE/ACM Transactions on Audio, Speech, and Language Processing* 28 (2020), S. 2880–2894. DOI: 10.1109/TASLP.2020.3030497.
- [38] Scott Wisdom u. a. „Unsupervised Sound Separation Using Mixture Invariant Training“. In: *Advances in Neural Information Processing Systems 33*. Virtual Event: Curran Associates, 2020.
- [39] Anmol Gulati u. a. „Conformer: Convolution-augmented Transformer for Speech Recognition“. In: *Interspeech 2020*. ISCA, 2020, S. 5036–5040. DOI: 10.21437/Interspeech.2020-3015.
- [40] Giorgia Cantisani, Slim Essid und Gael Richard. „Neuro-Steered Music Source Separation With EEG-Based Auditory Attention Decoding And Contrastive-NMF“. In: *2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Toronto, Canada: IEEE, 2021, S. 36–40. DOI: 10.1109/ICASSP39728.2021.9413841.
- [41] Julian Neri, Philippe Depalle und Roland Badeau. „Unsupervised Blind Source Separation with Variational Auto-Encoders“. In: *Proceeding of the 29th European Signal Processing Conference*. Dublin, Ireland, 2021, S. 311–315.
- [42] Yuan Gong, Yu-An Chung und James Glass. „AST: Audio Spectrogram Transformer“. In: *Interspeech 2021*. Brno, Czech Republic: ISCA, 2021, S. 571–575. DOI: 10.21437/Interspeech.2021-698.
- [43] Alexei Baevski u. a. „Unsupervised Speech Recognition“. In: *Advances in Neural Information Processing Systems 34*. Bd. 34. Virtual Event: Curran Associates, 2021, S. 27826–27839.

- [44] Yu Zhang u. a. *Google USM: Scaling Automatic Speech Recognition Beyond 100 Languages*. 2023.
- [45] Yuang Li, Xianrui Zheng und Philip C. Woodland. „Self-Supervised Learning-Based Source Separation for Meeting Data“. In: *2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Rhodes Island, Greece: IEEE, 2023, S. 1–5. DOI: 10.1109/ICASSP49357.2023.10094606.
- [46] Yuzhuo Liu u. a. „Audio Prompt Tuning for Universal Sound Separation“. In: *2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Seoul, Korea: IEEE, 2024, S. 1446–1450. DOI: 10.1109/ICASSP48485.2024.10447061.
- [47] Zengwei Yao u. a. „Zipformer: A Faster and Better Encoder for Automatic Speech Recognition“. In: *The Twelfth International Conference on Learning Representations*. Vienna, Austria: ICLR, 2024.
- [48] Pierre Comon. „Independent Component Analysis, A New Concept?“ In: *Signal Processing* 36.3 (1994), S. 287–314. DOI: 10.1016/0165-1684(94)90029-9.
- [49] Lei Tong u. a. „Nonnegative-Matrix-Factorization-Based Hyperspectral Unmixing with Partially Known Endmembers“. In: *IEEE Transactions on Geoscience and Remote Sensing* 54.11 (2016), S. 6531–6544. DOI: 10.1109/TGRS.2016.2586110.
- [50] Usama Fayyad, Gregory Piatetsky-Shapiro und Padhraic Smyth. „From Data Mining to Knowledge Discovery in Databases“. In: *AI Magazine* 17.3 (1996), S. 37–37. DOI: 10.1609/aimag.v17i3.1230.
- [51] Rüdiger Wirth und Jochen Hipp. „CRISP-DM: Towards a Standard Process Model for Data Mining“. In: *Proceedings of the 4th International Conference on the Practical Application of Knowledge Discovery and Data Mining*. Manchester, UK: Springer, 2000, S. 29–39.
- [52] SAS. *Introduction to SEMMA*. URL: <https://documentation.sas.com/doc/en/emref/15.2/n061bzurmej4j3n1jnj8bbjjmla2.htm>.
- [53] IBM. *Analytics Solutions Unified Method: Implementations with Agile Principles*.
- [54] Microsoft. *What Is the Team Data Science Process?* URL: <https://learn.microsoft.com/en-us/azure/architecture/data-science-process/overview>.
- [55] Stefan Studer u. a. „Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology“. In: *Machine Learning and Knowledge Extraction* 3.2 (2021), S. 392–413. DOI: 10.3390/make3020020.
- [56] Przemyslaw Biecek. *Model Development Process*. 2019. DOI: 10.48550/arXiv.1907.04461.
- [57] Carlos J. Costa und Joao Tiago Aparicio. „POST-DS: A Methodology to Boost Data Science“. In: *2020 15th Iberian Conference on Information Systems and Technologies (CISTI)*. Sevilla, Spain: IEEE, 2020, S. 1–6. DOI: 10.23919/CISTI49556.2020.9140932.

- [58] Steffen Huber u. a. „DMME: Data Mining Methodology for Engineering Applications – a Holistic Extension to the CRISP-DM Model“. In: *Procedia CIRP* 79 (2019), S. 403–408. DOI: 10.1016/j.procir.2019.02.106.
- [59] Rebecca Welte, Manfred Estler und Dominik Lucke. „A Method for Implementation of Machine Learning Solutions for Predictive Maintenance in Small and Medium Sized Enterprises“. In: *Procedia CIRP* 93 (2020), S. 909–914. DOI: 10.1016/j.procir.2020.04.052.
- [60] Dominik Kreuzberger, Niklas Kühl und Sebastian Hirschl. „Machine Learning Operations (MLOps): Overview, Definition, and Architecture“. In: *IEEE Access* 11 (2023), S. 31866–31879. DOI: 10.1109/ACCESS.2023.3262138.
- [61] M. Zaharia u. a. „Accelerating the Machine Learning Lifecycle with MLflow“. In: *IEEE Data Engineering Bulletin* (2018).
- [62] Malcolm Slaney. *Auditory Toolbox: A MATLAB Toolbox for Auditory Modeling Work*. en. Technical Report 1998-010. Interval Research Corporation, 1998.
- [63] S. Umesh, L. Cohen und D. Nelson. „Fitting the Mel Scale“. en. In: *Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing*. Bd. 1. Phoenix, AZ, USA: IEEE, 1999, S. 217–220. DOI: 10.1109/ICASSP.1999.758101.
- [64] Guolin Ke u. a. „LightGBM: A Highly Efficient Gradient Boosting Decision Tree“. In: *Advances in Neural Information Processing Systems 30*. Long Beach, CA, USA: Curran Associates, 2017, S. 3146–3154.
- [65] Daniel S. Park u. a. „SpecAugment: A Simple Data Augmentation Method for Automatic Speech Recognition“. In: *20th Annual Conference of the International Speech Communication Association*. Graz, Austria: ISCA, 2019, S. 2613–2617. DOI: 10.21437/Interspeech.2019-2680.
- [66] Hongyi Zhang u. a. „Mixup: Beyond Empirical Risk Minimization“. In: *The Sixth International Conference on Learning Representations*. Vancouver, Canada: OpenReview, 2018, S. 1–13.
- [67] Hanxiao Liu u. a. „Pay Attention to MLPs“. In: *Advances in Neural Information Processing Systems 34*. Hrsg. von Marc’Aurelio Ranzato u. a. Virtual Event: Curran Associates, 2021, S. 9204–9215.
- [68] Ilya O Tolstikhin u. a. „MLP-Mixer: An All-MLP Architecture for Vision“. In: *Advances in Neural Information Processing Systems 34*. Hrsg. von M. Ranzato u. a. Bd. 34. Virtual Event: Curran Associates, 2021, S. 24261–24272.
- [69] Kaiming He u. a. „Deep Residual Learning for Image Recognition“. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, NV, USA: IEEE, 2016, S. 770–778. DOI: 10.1109/CVPR.2016.90.

- [70] Tsung-Yi Lin u. a. „Focal Loss for Dense Object Detection“. In: *IEEE International Conference on Computer Vision*. Venice, Italy: IEEE, 2017, S. 2999–3007. DOI: 10.1109/ICCV.2017.324.
- [71] Jian Duan, Xi Zhang und Tielin Shi. „A Hybrid Attention-Based Paralleled Deep Learning Model for Tool Wear Prediction“. In: *Expert Systems with Applications* 211 (2023), S. 118548. DOI: 10.1016/j.eswa.2022.118548.
- [72] Jiusi Zhang u. a. „An Integrated Multi-Head Dual Sparse Self-Attention Network for Remaining Useful Life Prediction“. In: *Reliability Engineering & System Safety* 233 (2023), S. 109096. DOI: 10.1016/j.ress.2023.109096.
- [73] Zhiqian Zhao u. a. „Task-Generalization-Based Graph Convolutional Network for Fault Diagnosis of Rod-Fastened Rotor System“. In: *IEEE Transactions on Industrial Informatics* 20.3 (2024), S. 4616–4626. DOI: 10.1109/TII.2023.3326507.
- [74] Jichao Hong, Huanqin Zhang und Xiaoming Xu. „Thermal Fault Prognosis of Lithium-Ion Batteries in Real-World Electric Vehicles Using Self-Attention Mechanism Networks“. In: *Applied Thermal Engineering* 226 (2023), S. 120304. DOI: 10.1016/j.applthermaleng.2023.120304.
- [75] Juan Fernández u. a. „Training of Physics-Informed Bayesian Neural Networks with ABC-SS for Prognostic of Li-ion Batteries“. In: *Computers in Industry* 155 (2024), S. 104058. DOI: 10.1016/j.compind.2023.104058.
- [76] Peihang Xu u. a. „State-of-Charge Estimation and Health Prognosis for Lithium-Ion Batteries Based on Temperature-Compensated Bi-LSTM Network and Integrated Attention Mechanism“. In: *IEEE Transactions on Industrial Electronics* 71.6 (2024), S. 5586–5596. DOI: 10.1109/TIE.2023.3292865.
- [77] Alec Radford u. a. „Robust Speech Recognition via Large-Scale Weak Supervision“. In: *Proceedings of the 40th International Conference on Machine Learning*. Bd. 202. Honolulu, Hawaii, USA: PMLR, 2023, S. 28492–28518.
- [78] Jordi Pons u. a. „GASS: Generalizing Audio Source Separation with Large-Scale Data“. In: *2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Seoul, Korea: IEEE, 2024, S. 546–550. DOI: 10.1109/ICASSP48485.2024.10446601.
- [79] Yannic Wolf, Lennard Sielaff und Dominik Lucke. „A Standardized Description Model for Predictive Maintenance Use Cases“. In: *Procedia CIRP* 118 (2023), S. 122–127. DOI: 10.1016/j.procir.2023.06.022.
- [80] Cheng Lyu u. a. „Robust Two-Stage Transport Data Imputation with Change-point Detection and Tucker Decomposition“. In: *IEEE 26th International Conference on Intelligent Transportation Systems (ITSC)*. Bilbao, Spain: IEEE, 2023, S. 494–499. DOI: 10.1109/ITSC57777.2023.10422346.

- [81] Cheng Lyu u. a. „Tucker Factorization-Based Tensor Completion for Robust Traffic Data Imputation“. In: *Transportation Research Part C: Emerging Technologies* 160 (2024), S. 104502. DOI: 10.1016/j.trc.2024.104502.

## Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel PANAMERA: Entwicklung eines Predictive Maintenance Baukastens für Automotive Applikationen mittels Fahrzeug-Flottendatenanalyse	
4. Autor(en) [Name(n), Vorname(n)] M.Eng. Cheng Lyu Dr.-Ing. Qing-Long Lu Univ.-Prof. Dr. Constantinos Antoniou	5. Abschlussdatum des Vorhabens Sept 2024
	6. Veröffentlichungsdatum März 2025
	7. Form der Publikation Bericht
8. Durchführende Institution(en) (Name, Adresse) Lehrstuhl für Vernetzte Verkehrssysteme, TUM School of Engineering and Design Technische Universität München Arcisstraße 21, 80333 München	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 19I21016F
	11. Seitenzahl 61
12. Fördernde Institution (Name, Adresse)  Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. Literaturangaben 81
	14. Tabellen 6
	15. Abbildungen 22
16. Zusätzliche Angaben	
17. Vorgelegt bei (Titel, Ort, Datum) Technische Informationsbibliothek (TIB) Hannover, März 2025	
18. Kurzfassung Das PANAMERA-Projekt adressiert den Bedarf an intelligenten, datengetriebenen Wartungsstrategien in der Automobilindustrie durch die Entwicklung eines standardisierten, modularen Frameworks für Predictive Maintenance. Während bestehende Predictive-Maintenance-Lösungen erfolgreich fortschrittliche datengetriebene Modelle zur Verbesserung der Wartungseffizienz nutzen, fehlt ihnen oft eine systematische Abstraktion der gesamten Pipeline, wodurch eine vollständige Neuentwicklung für neue Komponenten und Anwendungsszenarien erforderlich wird. Dieses Projekt präsentiert ein umfassendes Framework, das den gesamten Prozess von der Datenerfassung bis zur Bereitstellung standardisiert und cloudbasierte Plattformen mit spezialisierten Analyse-Pipelines sowohl für hoch- als auch für niederfrequente Sensordaten integriert. Die TUM arbeitete während der gesamten Entwicklung eng mit dem Konsortium zusammen, mit besonderem Fokus auf die Konzeption von Machine-Learning-Algorithmen innerhalb des Frameworks. Drei Use Cases validieren die Vielseitigkeit des Frameworks: Bremsgeräuschklassifikation basierend auf akustischer Analyse, Sonderereigniserkennung basierend auf Anomalieerkennung und Reifenverschleißvorhersage mittels Lenkverhaltenanalyse. Empirische Ergebnisse bestätigen die Wirksamkeit der entwickelten Modelle und die Machbarkeit des Frameworks. Das vorgeschlagene Framework bildet eine Grundlage für zukünftige Predictive-Maintenance-Anwendungen in der Automobilindustrie, mit Potenzial zur Erweiterung auf andere industrielle Systeme und Anwendungen, die eine Zustandsüberwachung von Komponenten und Predictive Maintenance erfordern.	
19. Schlagwörter Predictive Maintenance, Verschleißmodell, Akustische Analyse, Anomalieerkennung, Maschinelles Lernen	
20. Verlag	21. Preis

## Document Control Sheet

1. ISBN or ISSN	2. type of document (e.g. report, publication) Final report
3. title PANAMERA: Development of a Predictive Maintenance Framework for Automotive Application with Fleet Data Analysis	
4. author(s) (family name, first name(s)) Constantinos Antoniou Cheng Lyu	5. end of project Sept 2024
	6. publication date Mar 2025
	7. form of publication Report
8. performing organization(s) (name, address) Chair of Transportation Systems Engineering, TUM School of Engineering and Design, Technical University of Munich Arcisstraße 21, 80333 München	9. originator's report no.
	10. reference no. 19I21016F
	11. no. of pages 61
12. sponsoring agency (name, address)  Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. no. of references 81
	14. no. of tables 6
	15. no. of figures 22
16. supplementary notes	
17. presented at (title, place, date) Technische Informationsbibliothek (TIB) Hannover, März 2025	
18. abstract The PANAMERA project addresses the need for smart data-driven maintenance strategies in the automotive industry by developing a standardized, modular framework for predictive maintenance. While existing predictive maintenance solutions successfully utilize advanced data-driven models to improve maintenance efficacy, they often lack systematic abstraction of the whole pipeline, thereby requiring complete redevelopment for new components and application scenarios. This project presents a comprehensive framework that standardizes the entire process from data acquisition to deployment, integrating cloud-based platforms with specialized analytics pipelines for both high and low-frequency sensor data. TUM worked closely with the consortium throughout development, with particular focus on the design of machine learning algorithms within the framework. Three use cases validate the framework's versatility: brake noise classification based on acoustic analysis, special event detection based on anomaly detection, and tire wear prediction via steering behavior analysis. Empirical results confirm the effectiveness of the designed models and the feasibility of the framework. The proposed framework establishes a foundation for future predictive maintenance applications in the automotive industry, with potential for extension to other industrial systems and applications requiring component health monitoring and predictive maintenance.	
19. keywords Predictive maintenance, wear model, acoustic analysis, anomaly detection, machine learning	
20. publisher	21. price