

Gefördert durch:



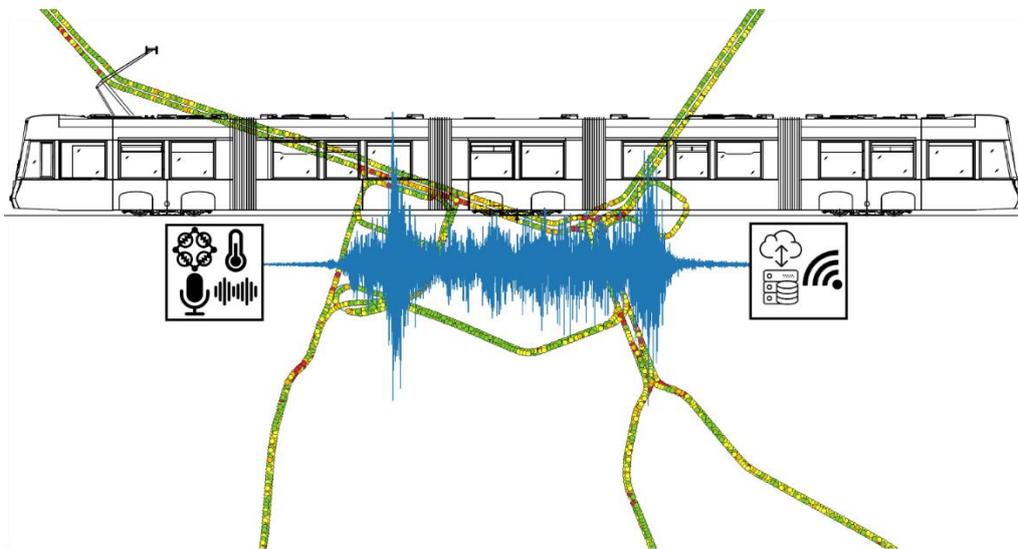
aufgrund eines Beschlusses
des Deutschen Bundestages



Sachbericht / Schlussbericht

OnboardEU

Erkennung von Gleisfehlstellen anhand von Onboard-Daten im Hinblick auf Immissionskarten in europäischen Städten



Projektpartner

Deutsches Zentrum für Luft- und Raumfahrt DLR e. V.
AIT Austrian Institute of Technology GmbH
i4M technologies GmbH

Förderkennzeichen

01F2192A
01F2192B
01F2192C

Version 1.0, 28.08.2025

Autoren
Jörn Groos (DLR)
Judith Heusel (DLR)
Benjamin Baasch (DLR)
Alexander Lähns (DLR)
Michael Roth (DLR)
Karoline Alten (AIT)
Andreas Fuchs (AIT)
Andreas Hula (AIT)
Martin Noll (i4M)
Matthias Schmidt-Kastner (i4M)

Versionshistorie
28.08.2025, Version 1.0 für TIB-Veröffentlichung

Inhaltsverzeichnis

1	Kurze Darstellung	4
1.1	Projektsteckbrief.....	4
1.2	Ziele und Aufgabenstellung	5
1.3	Voraussetzungen und Ausgangslage	5
1.4	Planung und Ablauf.....	6
1.5	Zusammenarbeit mit anderen Stellen	7
2	Eingehende Darstellung	8
2.1	Zuwendung	8
2.2	Projektziele und Forschungsfragen	9
2.3	Forschungsfragen	9
2.4	Stand von Wissenschaft und Technik	10
2.5	Eigene Vorarbeiten.....	11
2.6	Fortschritte im Arbeitsgebiet.....	12
2.7	Projektergebnisse	13
2.7.1	Messsystem und Datenerhebung.....	13
2.7.2	Referenzdaten und Pass-by-Messungen.....	19
2.7.3	Datenmanagement	22
2.7.4	Georeferenzierung	23
2.7.5	Datenkatalog.....	27
2.7.6	Zustandsüberwachung und Lärmkartierung.....	30
2.7.7	Edge-Computing	48
2.8	Verwertung.....	50
2.9	Veröffentlichungen.....	51
3	Abbildungsverzeichnis	52
4	Literaturverzeichnis.....	55

Das Projekt OnboardEU mit einem Projektvolumen von 1.013.178 EUR wurde im Rahmen der Innovationsinitiative mFUND durch das Bundesministerium für Digitales und Verkehr gefördert (Förderquote 74,8%).

Über das Förderprogramm mFUND des BMDV

Im Rahmen des Förderprogramms mFUND unterstützt das BMDV seit 2016 Forschungs- und Entwicklungsprojekte rund um datenbasierte digitale Innovationen für die Mobilität 4.0. Die Projektförderung wird ergänzt durch eine aktive fachliche Vernetzung zwischen Akteuren aus Politik, Wirtschaft, Verwaltung und Forschung und die Bereitstellung von offenen Daten auf der Mobilithek. Weitere Informationen finden Sie unter www.mfund.de.

1 Kurze Darstellung

Straßenbahnen sind stark frequentierte öffentliche Verkehrsmittel, die auch durch eng bewohnte Stadtbezirke fahren. Bei Schäden an Gleisen und Schienen entstehen störende Erschütterungen und Lärm sowie ein erhöhter Verschleiß an den Fahrzeugen. Eine Folge sind Konflikte mit betroffenen Anwohnern und Fahrgästen. Das erforderliche Beschwerdemanagement sowie die reaktive, kurzfristige Beseitigung von fortgeschrittenen Schäden an Gleisen und Fahrzeugen verursachen hohe Kosten. Mit etablierten Inspektionsverfahren (z. B. handgeführten Messgeräten) ist eine kurzfristige Aufdeckung neuer Gleisschäden wirtschaftlich und betrieblich nicht umsetzbar. Die schnelle, kostengünstige und frühzeitige Erkennung von entstehenden Gleisschäden stellt die Verkehrsbetriebe vor große Herausforderungen. Eine kontinuierliche Zustandsüberwachung mit eingebetteten Messsystemen zur Erfassung der Fahrzeug-Fahrweg-Interaktion auf regulär verkehrenden Fahrzeugen soll zukünftig eine zustandsbasierte und kosteneffiziente Instandhaltung der Gleisinfrastruktur ermöglichen.

1.1 Projektsteckbrief

Zielstellung

Ziel des Projekts [OnboardEU](#) ([1]) war die kontinuierliche Überwachung der Gleisnetze mit Messsystemen auf den verkehrenden Straßenbahnen. Dazu sollten Straßenbahnen in mindestens drei europäischen Städten für mehrere Wochen mit Onboard-Systemen zur Erfassung von Vibrationen und Schall im Bereich des Rad-Schiene-Kontakts ausgestattet werden. Anhand der gesammelten Daten sollten KI-Verfahren für die Zustandsüberwachung und Lärmkartierung entwickelt werden.

Ergebnisse und Wirkungen

In OnboardEU wurden mittels Multi-Sensor-Systemen mit hohem Technologie-Reifegrad auf sieben Straßenbahnen in Basel, Graz, Hannover und Wien im laufenden Betrieb Messdaten erhoben. Innerhalb von 21 Monaten konnten über 150.000 Fahrten mit einer Laufleistung von über 92.000 km gleisgenau georeferenziert werden. Anhand dieses umfassenden Datensatzes konnten KI-Verfahren für die Erkennung relevanter Schadensbilder wie Riffel und Schienenbrüche erfolgreich demonstriert werden, um eine zielgerichtete Instandhaltung zu ermöglichen. Ebenso konnte die Möglichkeit einer Vorhersage der Lärmentwicklung anhand des tatsächlichen Schienenzustandes gezeigt werden. Zusammen mit einem entwickelten Edge-Computing-Ansatz soll das Messsystem zur Produktreife weiterentwickelt werden. Mehrere der Messsysteme bleiben über das Projektende hinaus in Betrieb und bilden mit den bereits erhobenen Daten die Grundlage für die nachfolgende Erhöhung des Technologiereifegrades der KI-Verfahren. Die Algorithmen für die Georeferenzierung sowie ein Trainingsdatensatz werden über die Mobiltheke zur Verfügung gestellt.

1.2 Ziele und Aufgabenstellung

Übergeordnetes Ziel des Projektes OnboardEU war die Weiterentwicklung, Erprobung und Demonstration einer kontinuierlichen und automatisierten Zustandsüberwachung sowie Lärmkartierung der innerstädtischen Gleisnetze mit Messsystemen auf regulär verkehrenden Straßenbahnen. Im Fokus stand dabei die Erforschung geeigneter Verfahren der künstlichen Intelligenz (KI) für die Detektion von Schäden an den Schienen und dem Gleisoberbau sowie die Lärmkartierung anhand eines umfassenden Messdatensatzes aus operativer Umgebung.

Im Rahmen des Projektes wurden drei leitende Ziele für die inhaltlichen Arbeiten formuliert:

- 1) Verbesserung des Asset Managements bei städtischen Schieneninfrastruktur-Betreibern in Europa
- 2) Erstellung eines Datenmuster-Katalogs für spezifische Schienenschäden und typische Fahrzeugreaktionen
- 3) Verbesserung der Ortungsgenauigkeit der Onboard-Sensorsysteme

Ein maßgebliches technisches Ziel war die Erhebung der erforderlichen Messdaten in mindestens drei europäischen Städten mit mehreren Straßenbahnfahrzeugen mit dem im Projekt aufzubauenden Sensorsystem (siehe Abschnitt 2.7.1). Es sollten mit jedem Fahrzeug mindestens vier Wochen und in Summe über alle Fahrzeuge mindestens zehn Monate Messdaten im regulären Betrieb erfasst werden. Teil des Projektes war darüber hinaus das partnerübergreifende Datenmanagement der erhobenen Messdaten sowie deren gleisgenaue Georeferenzierung mittels eines kartengestützten Multi-Sensor-Ansatzes (siehe Abschnitt 2.7.4). Darauf aufbauend waren standen die Erforschung und Weiterentwicklung geeigneter KI-Verfahren für die automatische Datenanalyse im Vordergrund (siehe Abschnitt 2.7.6). Die leitenden konkreten Forschungsfragen für die Erforschung der KI-Verfahren sind in Abschnitt 2.2 detailliert dargestellt. Abschließend soll die Bereitstellung eines aufbereiteten Trainingsdatenkatalogs über die Mobilthek die Verwertung der Projektergebnisse über das Projekt hinaus unterstützen (siehe Abschnitt 2.7.5).

1.3 Voraussetzungen und Ausgangslage

In den vergangenen Jahren ist ein spürbares Wiederaufleben von vielen Straßenbahnnetzen Europas, die häufig nach dem zweiten Weltkrieg eingestellt wurden, zu beobachten. In diesem Zusammenhang ist die Förderung von Maßnahmen zur Effizienz- und Qualitätssteigerung von sogenannten „light railway“ Netzwerken nicht nur in Deutschland sondern in ganz Europa von besonderer Bedeutung. Bereits heute haben 23 von 27 EU-Staaten Städte mit aktuell betriebenen Straßenbahnen. [Insgesamt sind Straßenbahnen in 199 Städten in der Europäischen Union \(EU\) in Betrieb, 8 neue sind bereits in Bau bzw. Planung.](#) Eine regelmäßige und möglichst automatisierte Gleisinspektion kann zukünftig ein maßgeblicher Eckpfeiler bei der Aufrechterhaltung und Erweiterung des innerstädtischen Mobilitätsangebots sowie der Reduktion potentieller Lärm- und Erschütterungsemissionen in allen europäischen Ballungsräumen sein. Während sich für die Vollbahn bereits Systeme zum Onboard-Monitoring - insbesondere der Gleisgeometrie - auf dem Markt bzw. bei einigen Netzbetreibern in Verwendung etabliert haben, werden Straßenbahnnetze aufgrund der anderen Anforderungen (niedrigere Geschwindigkeiten und Tonnagen pro Jahr, straßeneingebettete Oberbauformen, Einsatz von Niederflurfahrzeugen, häufige Zwischenhalte, u.a.) und der oft viel kleineren Netze mit niedrigerer Priorität hinsichtlich automatischer Zustandserkennung behandelt. Die Durchdringung der Flotten mit entsprechenden Systemen ist sehr gering und geht bislang nicht über einzelne Erprobungs- und Demonstrationsprojekte hinaus. Der gegenwärtige Stand der Technik und der sich daraus ableitende Forschungsbedarf ist in Abschnitt 2.4 detaillierter dargestellt. Dieser besteht im Schwerpunkt bei der Entwicklung robuster und zuverlässiger KI-Verfahren für die Gewinnung relevanter

Zustandsinformationen. Dies wiederum erfordert geeignete Datensätze aus operativer Umgebung für Training, Test und Validierung entsprechender Ansätze. Bislang sind nur wenige offene Datensätze mit Messdaten zur Fahrzeug-Fahrweg-Interaktion verfügbar. Diese betreffen zudem den Güterverkehr (z. B. mCLOUD [QUISS](#), Fokus auf starke Wagenstöße im Betrieb) bzw. stellen lediglich Messungen am Drehgestell bereit (z. B. [DR-Train dataset](#), Light Rail Pittsburgh).

Die Projektpartner verfügen über umfassende Erfahrungen in der Erfassung und Auswertung von dynamischen Fahrzeug-Fahrweg-Wechselwirkungen für die Zustandsüberwachung aus vorangegangenen nationalen und internationalen Forschungsprojekten mit Praxispartnern bzw. dem kommerziellen Betrieb entsprechender Systeme (siehe Abschnitt 2.5 Eigene Vorarbeiten). Das Projekt OnboardEU schloss unmittelbar an vorausgegangene Forschungsarbeiten sowie bestehende Messsysteme der Projektpartner an und adressierte gezielt Bereiche mit besonders großem weiteren Forschungsbedarf.

1.4 Planung und Ablauf

Das Projekt wurde entlang der Wirkkette von der fahrzeug- und streckenseitigen Messdatenerhebung (Arbeitspaket (AP) 2) über die Datenaufbereitung und Georeferenzierung (AP 3) bis hin zur KI-basierten Datenanalyse (AP 5) strukturiert. Der vibroakustische Datenkatalog wurde in AP 4 erstellt. Erste Projektergebnisse wurden bereits projektbegleitend in geeigneten Medien publiziert (siehe Abschnitt 2.9) und mit Betreibern von urbanen Gleisnetzen im Rahmen von Fachworkshops diskutiert (AP 6). Eine Übersicht über die Arbeitspakete mit Unterarbeitspaketen, Verantwortlichkeiten und Abhängigkeiten ist in Abbildung 1 gegeben.

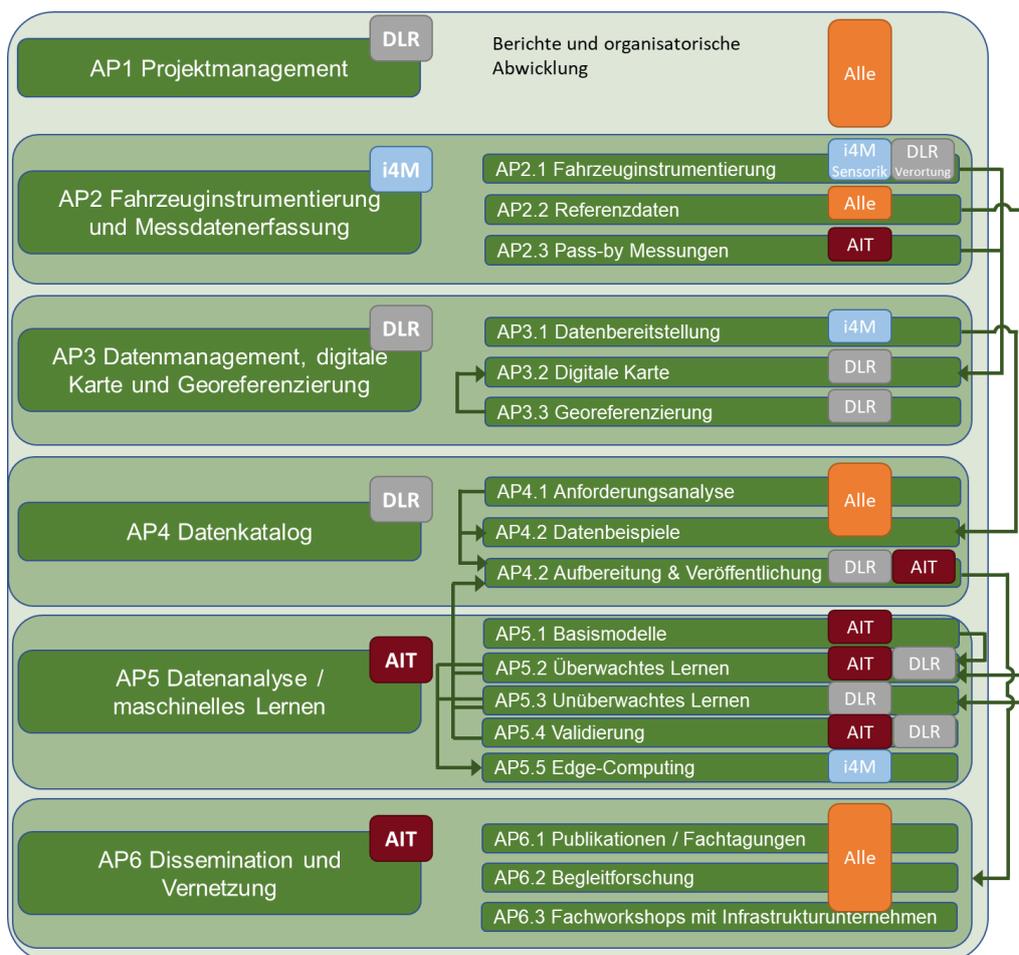


Abbildung 1. Arbeitspaketstruktur des Projekts.

1.5 Zusammenarbeit mit anderen Stellen

Mehrere europäische Infrastrukturbetreiber und Verkehrsbetriebe (Basler Verkehrs-Betriebe BVB, Holding Graz – Kommunale Dienstleistungen GmbH, ÜSTRA Hannoversche Verkehrsbetriebe AG, WIENER LINIEN GmbH, Hafenbetriebsgesellschaft Braunschweig mbH) waren im Rahmen assoziierten Projektpartnerschaften am Projekt OnboardEU maßgeblich beteiligt. Wesentlich war die Bereitstellung von Fahrzeugen zur Erhebung von Messdaten im operativen Betrieb, vorhandener Geo- und Inspektionsdaten für die Erstellung von Trainingsdaten und der Evaluation der Ergebnisse, die Möglichkeit zur Durchführung von Streckenbegehungen sowie der kontinuierliche fachliche Austausch zu den Projektinhalten und -ergebnissen. Neben der engen Zusammenarbeit mit den assoziierten Projektpartnern bestand ein enger fachlicher Austausch mit weiteren mFUND-Projekten, insbesondere [IDX4RAIL](#) ([2]) und [LRVTwin](#). Gemeinsam mit den Partnern des Projektes LRVTwin wurden zwei Fachkonferenzen unter dem Titel „Digitale Stadtbahnflotten“ durchgeführt. Im Rahmen dieser Fachkonferenzen konnten die Ergebnisse beider Projekte gemeinsam präsentiert und mit der Fachöffentlichkeit diskutiert werden.

2 Eingehende Darstellung

In den folgenden Abschnitten werden zuerst die grundlegenden wissenschaftlichen Fragestellungen sowie Ziele des Projekts eingehender vorgestellt. Der für das Projekt relevante Stand von Wissenschaft und Technik sowie die Vorarbeiten der Projektpartner werden zusammenfassend dargestellt. Anschließend erfolgt die eingehende Darstellung der erreichten Ergebnisse.

2.1 Zuwendung

Das Projekt OnboardEU mit einem bewilligten Projektvolumen von 1.013.178 Euro wurde im Rahmen der Innovationsinitiative mFUND mit einer Förderquote von 74,8% durch das Bundesministerium für Digitales und Verkehr gefördert.

Die Notwendigkeit der Förderung ergab sich durch den stark experimentell-forschenden Charakter des Projektes sowie der hohen wirtschaftlichen Risiken bei der Umsetzung von Messkampagnen im operativen Betrieb. Die Entwicklung von Regelzugmesssystemen für den Einsatz zur Zustandsüberwachung in Schienennetzen stellt insbesondere für kleine, innovative Unternehmen noch immer ein großes wirtschaftliches Risiko dar: die Entwicklungskosten (insbesondere für KI-basierte Algorithmen) sind hoch und der Markt noch nicht umfassend entwickelt. Es gibt noch keine im Dauerbetrieb erprobten Onboard-Sensorsystemen in Verbindung mit neuartigen KI-Verfahren. Insbesondere fehlen bei Infrastrukturbetreibern mehrheitlich daher noch die erforderlichen Erfahrungen und geeignete unternehmerischen Prozesse zur Einbindung entsprechender Ansätze und Systeme in das etablierte Instandhaltungsmanagement. Während der Einführungsphase dieser Systeme ist zudem mit einem hohen iterativen Weiterentwicklungsbedarf zu rechnen, um die Robustheit und Zuverlässigkeit der Systeme entsprechend der konkreten Anwendungsumgebungen zu erhöhen. Die mit diesem Projekt verbundene Förderung war daher notwendig, um mit Hilfe der involvierten Betreiber städtischer Schieneninfrastrukturen Pilot-Implementierungen aufzubauen, die als „Leuchtturm-Projekte“ der Kooperation von Forschung und Wirtschaft die technische und wirtschaftliche Machbarkeit solcher innovativen, datenbasierten Ansätze der Infrastrukturzustandsüberwachung unter Beweis stellen. Die Umsetzung solcher Leuchtturmprojekte ist ohne Förderung nur für sehr große Unternehmen möglich und würde kleinere, innovative Unternehmen sowie Forschungseinrichtungen von der Entwicklung marktfähiger Lösungen ausschließen. Für den erfolgreichen Transfer wissenschaftlicher Ergebnisse in die Praxis sind Forschungseinrichtungen wie AIT und DLR maßgeblich auf den Rahmen öffentlich geförderter Verbundprojekte mit Praxispartnern angewiesen.

2.2 Projektziele und Forschungsfragen

Aus den bereits dargestellten übergeordneten Projektzielen wurden die in der folgenden Tabelle dargestellten konkreten fachlichen/technischen Ziele für das Projekt abgeleitet.

Ziel	Verbesserung des Asset Managements bei städtischen Schieneninfrastruktur-Betreibern in Europa	Erstellung eines Datenmuster-Katalogs für spezifische Schienenschäden und typische Fahrzeugreaktionen	Verbesserung der Ortungsgenauigkeit des Onboard-Sensorsystems
	Identifikation von Fehlstellen in Schienennetzen mit KI-Verfahren anhand von Onboard-Daten der Fahrzeug-Fahrweg-Interaktion. Erfassung dynamischer Fahrzeugreaktionen in Abhängigkeit von Streckenzustand / Fahrprofil und Witterung bei verschiedenen europäischen Schieneninfrastruktur-Betreibern	Definition einer einheitlichen Datenstruktur für die Erfassung von dynamischen Fahrzeugreaktionen und Gleis-Zustandsdaten. Extraktion von Beispiel-Datensätzen aus den Messdaten (anonymisierter Trainingsdatensatz) zur Vergleichbarkeit auf Basis von Datenqualitätskriterien. Bereitstellung von Datensätzen über die Mobilithek.	Verknüpfung von Sensor- und Kartendaten für die präzisere, gleisgenaue Lokalisierung von Gleisfehlstellen. Lärmkartierung auf der Basis von georeferenzierten Onboard-Sensordaten und streckenseitig gemessenen Daten.

2.3 Forschungsfragen

Das Auffinden bestimmter Fehlzustände im Schienennetz durch sehr spezifische Auswertungen von dynamischen Fahrzeugreaktionen können heutzutage bereits als Stand der Technik betrachtet werden (siehe auch Abschnitte 2.4 und 2.5). In den meisten Fällen beruht diese Detektion auf sehr einfachen Schwellenwertverfahren die - bedingt durch unzureichende Informationen über externe Parameter - einer relativ hohen Fehlerquote unterliegen und keine Detailauskünfte über die Art der Fehlstelle liefern. Um an dieser Stelle im Rahmen der beschriebenen Zielstellungen des Projektes einen substantziellen Beitrag zu leisten, wurden die im Folgenden dargestellten forschungsleitenden Fragen formuliert.

Forschungsfrage: Welche **KI-Ansätze** (überwacht und unüberwacht) eignen sich, um ein möglichst breites Spektrum an **Schienenfehlern richtig und frühzeitig zu identifizieren und zu klassifizieren**?

Auf Basis von Messungen über einen längeren Zeitraum und bei verschiedenen Betriebsbedingungen in verschiedenen städtischen Netzen sollen externe Einwirkungen wie Fahrprofil und Witterung in die Detektion-Algorithmen mit einfließen. Durch die Verschneidung dieser Datensätze sollen die erzeugten **Fahrzeugpegelkarten** bestmöglich anhand von Modellen erklärt werden, die alle relevanten Einflussgrößen berücksichtigen. Gleichzeitig soll eine automatische Erkennung und Gruppierung auffälliger Fahrzeugreaktionen zur Identifikation von plötzlich auftretenden und/oder atypischen, seltenen Fehlzuständen stattfinden, die auch zur Aufdeckung erhöhter Belastungen der Fahrzeuge dient.

Forschungsfrage: Können geeignete Transferspektren zwischen Fahrzeugpegeln und Vorbeifahrtspegeln (Immissionen) gebildet werden, die eine netzweite Lärmkartierung auf Basis von Fahrzeugpegeln ermöglichen?

Es gilt hierbei zu untersuchen, wie sich das Umfeld (Bebauungsdichte: Freifeld vs. enge Straßen, Vegetation, Fahrzeugeigenschaften, ...) auf die Übertragungsfunktion auswirkt und welche Umgebungsparameter bekannt sein müssen, um innerstädtische, flächendeckende Lärmkarten allgemeingültig und hinreichend genau anhand der Fahrzeugpegel zu ermitteln.

Diese übergeordneten Fragestellungen wurden wiederum für die Projektdurchführung weiter konkretisiert/untergliedert:

1. Welche KI-Ansätze (überwacht und unüberwacht) eignen sich, um ein möglichst breites Spektrum an Schienenfehlern richtig und frühzeitig zu identifizieren und klassifizieren?
2. Welche KI-Ansätze eignen sich zur zuverlässigen Erkennung atypischer, ggfs. bislang unbekannter, dynamischer Fahrzeugreaktionen die auf Schäden an Strecke oder Fahrzeug hindeuten können?
3. Welche Umgebungsbedingungen sind für die Erklärung und Modellierung der erfassten Fahrzeugpegel relevant?
4. Können geeignete Transferspektren zwischen Fahrzeugpegeln und Vorbeifahrtspegeln gebildet werden, die eine netzweite Lärmkartierung auf Basis von Fahrzeugpegeln ermöglichen?

Um den beschriebenen Herausforderungen zu begegnen, wurden die Vorteile moderner KI-Verfahren (überwachtes und unüberwachtes maschinelles Lernen) im Zuge einer intelligenten Analyse der auf den Fahrzeugen erhobenen Sensordaten unter Hinzunahme weiterer ergänzender Sensordaten, Bestandsinformationen und Umgebungsinformationen genutzt. Hierfür wurden in AP 5 die aus vorangegangenen Projekten bereits vorhandenen Ansätze hinsichtlich der spezifischen Anforderungen für Straßenbahnen angepasst und weiterentwickelt. Die Ansätze kombinieren bereits heute etablierte Techniken der klassischen Signalanalyse mit überwachten und unüberwachten Lernverfahren. Mit im Projekt erstellten annotierten Datensätzen (z. B. durch Inspektionen bekannte und quantifizierte Fehlzustände) wurden überwachte Lernverfahren eingesetzt (siehe Abschnitt 2.7.6.3). Ergänzend wurden unüberwachte Lernverfahren (z. B. Autoencoder) für die vollautomatische Erkennung ungewöhnlicher Fahrzeugreaktionen (Anomaliedetektion) genutzt (siehe Abschnitt 2.7.6.2). Durch das unüberwachte Lernen können auch Fehlzustände erkannt werden, für welche noch keine annotierten Trainingsdaten oder Beobachtungen aus der Vergangenheit vorliegen.

Voraussetzung für weitere Fortschritte bei der Entwicklung dieser KI-basierten Analyseansätze ist die Verfügbarkeit geeigneter Trainings-, Test- und Benchmarkdatensätze. In diesem Sinne erfolgten Veröffentlichungen offener Datensätze über die Mobilthek (siehe Abschnitt 2.7.5).

2.4 Stand von Wissenschaft und Technik

Der Ansatz zur Gleiszustands- sowie Emissionsüberwachung basierend auf Messungen der dynamischen Fahrzeugreaktionen (z. B. Beschleunigungen am Achslager) regulär verkehrender Schienenfahrzeuge wurde bereits vor Jahrzehnten beschrieben (z. B. [3, 4]) und die grundsätzliche Eignung in Feldversuchen demonstriert. Eine geringe Zahl an Patenten wurde angemeldet, wobei die erfolgsrelevanten Datenanalyseverfahren in der Regel nicht patentierbar sind. In Bezug auf die Sensorausstattung der Fahrzeuge besteht kein grundsätzlicher Forschungsbedarf, einige Systeme von Fahrzeugherstellern und Systemanbietern sind am Markt verfügbar (z. B. Siemens, ZF Friedrichshafen AG, Tyréns AB). Bisher vorhandene Systeme und Ansätze fokussieren sich überwiegend auf den Einsatz auf Vollbahnen (Geschwindigkeiten > 60 km/h) für die Überwachung einzelner Parameter der Gleisgeometrie. Die Rahmenbedingungen (z. B. Fahrzeugeigenschaften, Streckeneigenschaften, Betriebsmodus, Geschwindigkeitsprofile, Häufigkeit der Halte, ...) für die eingebettete Zustandsüberwachung für Straßenbahnen unterscheiden sich jedoch stark von den Anforderungen

für die Vollbahn (z. B. Personenzüge auf Hochgeschwindigkeitstrecken). Für Stadt- bzw. Straßenbahnen sind wenige Systeme etabliert und keines eignet sich bislang für ein vollumfassendes Instandhaltungsmanagement. Untersuchungen die gezielt auf Straßenbahnnetze abzielten fanden beispielsweise in Budapest ([5]) und Melbourne ([6]) statt. Im Rahmen diverser Entwicklungsaufträge wurde für den Kunden Rheinbahn AG von i4M seit 2016 ein System zur Identifikation von periodischen Gleisfehlstellen (Riffeln, Wellen) sowie von stoßartigen Anregungen entwickelt. Hierbei stand die Belastung bestimmter Antriebskomponenten an den Schienenfahrzeugen im Fokus. Der Stand des Systems wurde von i4M im Rahmen von Veröffentlichungen auf Fachkonferenzen beschrieben (z. B. [7]).

Konkrete Schwachstellen bestehender Systeme für Straßenbahnen liegen beispielsweise in der Anwohnerlärmdetektion, der hochgenauen Ortung der Fehlstellen sowie der eindeutigen Identifikation der Fehlstellen (Abgleich zwischen Sensordaten und tatsächlichem Schadensbild vor Ort). Hinzu kommt, dass Weichen und Kreuzungen aktuell nicht zuverlässig identifiziert und überwacht werden können. Daher werden entsprechende Systeme bislang noch kaum von Infrastrukturbetreibern eingesetzt. Bezüglich der Zustandsüberwachung von Weichen erfolgten bereits Forschungsvorhaben (z. B. „Predictive Railway Monitoring (PRM) 4.0“ geleitet von voestalpine Signaling sowie STRAWE). Kernherausforderung ist bis heute die anspruchsvolle, zuverlässige Gewinnung der relevanten Information (Art und Ausmaß sowie Position des Fehlzustands) aus den sehr großen Mengen an erhobenen Messdaten. Stand der Technik bei der Datenauswertung ist der Einsatz von etablierten, klassischen Methoden der Signalanalyse (Filterung, Integration, Zeit-Frequenz-Analysen, etc.). Erst mit der Verfügbarkeit zunehmend leistungsfähigerer mobiler Rechnersysteme (edge computing) sowie leistungsfähigerer maschineller Lernverfahren (z. B. tiefe neuronale Netze) werden relevante Verbesserungen bei der Datenanalyse ([8, 9]) für die Überwindung der bestehenden Hemmnisse praktisch umsetzbar. Ein sehr relevantes Beispiel aus jüngster Zeit ist die Arbeit im EU-Projekt [QUIET-TRACK](#). Aus diesem Vorhaben ging unter anderem eine Dissertation zum Thema Squat-Detektion mittels „supervised learning“ (überwachtes Lernen) anhand von Vibro-Akustiksignalen hervor ([10]).

Die aktuellen Herausforderungen für Forschung und Entwicklung liegen beim Einsatz des maschinellen Lernens für die sichere Ursachen-Unterscheidung sich ähnelnder dynamischer Fahrzeugreaktionen (z. B. Fahrzeug-Reaktionen auf unterschiedliche Fehler der Schienenfahrfläche mit ähnlichen Wellenlängen wie Squats und Schleuderstellen oder durch Schäden am Fahrzeug selbst) sowie der Erhebung und Berücksichtigung räumlich und zeitlich variabler Randbedingungen (z. B. Fahrzeuggeschwindigkeit, Fahrbahnverschmutzung, Gleistrassierung, Witterung, Radverschleiß, Degradation der Sensorik). Nur auf diese Weise entsteht ein tatsächlicher Mehrwert für das Instandhaltungsmanagement. Aufgrund der vielfältigen Einflussfaktoren gestaltet sich die Erhebung geeigneter Trainingsdaten hinreichender Qualität für das maschinelle Lernen als sehr schwierig und aufwendig. Die Verfügbarkeit weiterer offener Trainings- und Benchmarkdatensätze würde die Entwicklung robuster und zuverlässiger KI-Verfahren unterstützen und stark beschleunigen.

2.5 Eigene Vorarbeiten

Das im Rahmen der österreichischen Forschungsprojekte [exSentric](#), [ASSESS](#) und [STRAWE](#) am AIT erworbene Wissen in puncto Datenerfassung mittels eines dedizierten Gleismesswagens konnte bereits erfolgreich in die Instandhaltungsplanung der Wiener Linien einfließen und wurde auf fach einschlägigen Konferenzen ([11–14]) präsentiert. Der Fokus lag hierbei immer auf der Untersuchung von Straßenbahngleisen im Wiener Netz (Normalspur, eingebettetes Gleis) und die gewonnene Erfahrung sollte im Rahmen von OnboardEU auf andere europäische Stadt- und Straßenbahnnetze ausgeweitet werden. Die Forschungsschwerpunkte im Wiener Netz lagen auf der automatischen Detektion von Kurvenkreischen mit Mikrofonen im Bereich der nicht-angetriebenen Drehgestelle sowie die Klassifizierung von Riffel anhand einer Kombination aus Achslagerbeschleunigungen und Akustik. Außerdem wurden Geräuschmuster an Regelgarnituren bei Weichenüberfahrten

auf Basis eines eigens entwickelten MEMS-Sensorsystems untersucht und erste Basismodelle für Onboard-Emissionen abgeleitet werden.

Die wissenschaftlichen Arbeitsschwerpunkte des DLR liegen in der Datenerhebung und Datenanalyse für die gleisgenaue Ortung von Schienenfahrzeugen (z. B. [15]; [IHATEC-Ortung im Hafen](#)) sowie den Einsatz von KI-Verfahren für die Zustandsüberwachung der Fahrzeuge und des Gleisoberbaus mit regulär verkehrenden Schienenfahrzeugen (z. B. [8]; [IHATEC-HavenZuG](#)). Die Forschungsarbeiten wurden und werden gemeinsam mit Praxispartnern im Rahmen von nationalen (z. B. [IHATEC-Ortung im Hafen](#), [IHATEC-HavenZuG](#)) und europäischen Forschungsprojekten (z. B. [Horizon 2020-SIA](#), FR8RAIL 1 bis 4 in [Shift2Rail Innovationsprogramm 5](#)) durchgeführt. Das Institut für Verkehrssystemtechnik des DLR hat für die Datenerhebung in operativer Umgebung bereits prototypische Multi-Sensor-Systeme auf Schienenfahrzeugen bei der SBB, ÖBB sowie der Hafenbahn des Braunschweiger Hafens (Rangierlokomotive) betrieben.

Im Rahmen diverser Entwicklungsaufträge wurden von der i4M technologies GmbH für die Rheinbahn AG seit 2016 ein System zur Identifikation von periodischen Gleisfehlstellen (Riffeln, Wellen) sowie von stoßartigen Anregungen entwickelt ([7]). Hierbei stand die Belastung bestimmter Antriebskomponenten an den Schienenfahrzeugen im Fokus.

2.6 Fortschritte im Arbeitsgebiet

Im Rahmen des Projektes erfolgte eine kontinuierliche Recherche bezüglich relevanter wissenschaftlicher Publikationen im Bereich der Datenanalyse von Beschleunigungsmessungen auf Fahrzeugen, insbesondere auf Schienenfahrzeugen. Relevante aktuelle Erkenntnisse sowie Weiterentwicklungen im Bereich des maschinellen Lernens flossen in die Bearbeitung des Projektes ein. Mehrheitlich wurden Anwendungsfälle auf Vollbahnen untersucht. Eine Liste relevanter Publikationen aus dem Arbeitsgebiet ist im Folgenden gegeben:

- Hoelzl, Cyprien; Dertimanis, Vasilis; Landgraf, Matthias; Ancu, Lucian; Zurkirchen, Marcel; Chatzi, Eleni (2022): On-board monitoring for smart assessment of railway infrastructure: A systematic review. In: *The Rise of Smart Cities*: Elsevier, S. 223–259.
- Morais, João; Morais, Paulo; Santos, Carlos; Paixão, André; Fortunato, Eduardo (2022): Railway track support condition assessment—Initial developments on a vehicle-based monitoring solution through modal analysis. In: *ARCHIVE: Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit 1989-1996 (vols 203-210)* 236 (9), S. 1058–1069. DOI: 10.1177/09544097211064101.
- Silva-Rodríguez, Julio; Salvador, Pablo; Naranjo, Valery; Insa, Ricardo (2022): Supervised contrastive learning-guided prototypes on axle-box accelerations for railway crossing inspections. In: *Expert Systems with Applications* 207, S. 117946. DOI: 10.1016/j.eswa.2022.117946.
- Jelila, Yohanis Dabesa; Pamuła, Wiesław (2022): Detection of Tram Wheel Faults Using MEMS-Based Sensors. In: *Sensors (Basel, Switzerland)* 22 (17), S. 6373. DOI: 10.3390/s22176373.

In den Bereichen Onboard-Messsysteme, Datenmanagement, Georeferenzierung, Zustandsüberwachung, überwachtes und unüberwachtes maschinelles Lernen, Trainingsdaten und Datenkataloge wurde eine Vielzahl von technischen und wissenschaftlichen Fortschritten erreicht. Diese werden im folgenden Abschnitt 2.7 im jeweiligen Kontext detailliert.

2.7 Projektergebnisse

In den folgenden Abschnitten werden die Projektergebnisse eingehender dargestellt.

2.7.1 Messsystem und Datenerhebung

Grundlage der wissenschaftlichen Fragestellungen sind die am Fahrzeug gemessenen Schwingungen, sowohl in Form von abgestrahltem Luftschall als auch Vibrationen. Pro Fahrzeug werden mehrere Messkanäle mit hoher Abtastrate (mind. 4 kHz für triaxiale Accelerometer, bis zu 48 kHz für Mikrofone) erfasst. Für die Durchführung der Messkampagnen war im Projekt eine Kleinserie geeigneter Messsysteme zur vibroakustischen Erfassung auf regulär verkehrenden Straßenbahnen über einen längeren Zeitraum aufzubauen. Die Messsysteme sollten darüber hinaus die Fähigkeit für zukünftige Edge-Computing Anwendungen bereitstellen. Ziel war die Erreichung eines Technologiereifegrades von 6-7 als Grundlage für eine dem Projekt nachfolgende Produktentwicklung.

Auf jedem ausgerüsteten Fahrzeug sollten insgesamt vier Sensoren eingesetzt werden, wobei jeweils zwei Sensoren pro Fahrzeugseite an einer Fahrzeugachse vorgesehen wurden:

1. Vibrationssensor (Beschleunigungssensor) zur Erfassung von Vibrationen in allen drei Raumrichtungen (Fahrzeug Längs-, Quer und Hochrichtung) insbesondere auch mit hohem Messbereich bis zu 200 g, nahe des Radaufstandspunktes, am besten direkt am Radlager
2. Luftschallsensor (Mikrofon) zur Erfassung von Luftschall, nahe des Radaufstandspunktes

Ferner wurde eine Messsystem-Basiseinheit entwickelt, die die von den Sensoren erzeugten Messdaten erfasst, zwischenspeichert, per LTE/Cloud-Verbindung in voller Datenrate möglichst dauerhaft bereitstellt und ebenfalls zum Edge-Computing (KI-Inferencing) fähig ist. Ein Linux-OS dient als Betriebssystem der Basiseinheit und erlaubt einen dauerhaften Remote-Zugriff auf das System.

Das Zielsystem Straßenbahn ist insbesondere hinsichtlich der Emission von elektromagnetischen Störungen eine Herausforderung, weshalb das Messsystem entsprechend robust ausgeführt werden musste. Die Systemarchitektur wurde daher auf Basis einschlägiger Erfahrungen bei i4M derart gestaltet, dass die analogen Sensorsignale so nah wie möglich am Sensor digitalisiert und digital per robuster Datenschnittstelle (differentielle RS 485 Leitungen) zur Basiseinheit übertragen werden. Hierbei werden für den Einsatz in der Bahn zertifizierte Kabelverbindungen verwendet, da diese insbesondere hinsichtlich des Brandschutzes von besonderer Bedeutung sind. Die Spannungsversorgung erfolgt über Bahn-zertifizierte Module, sodass Überspannungen und Ausfälle sicher vermieden werden. Zur exakten Lokalisierung des Systems wurde innerhalb des Systems sowohl ein Hochpräzisions-GNSS Modul als auch eine inertielle Messeinheit (IMU) basierend auf MEMS-Sensoren eingesetzt. Ferner wurden LTE-Modem und Solid State Speicher (SSD) integriert sowie ein Steckplatz für ein AI Inferencing Modul (Google Coral Edge TPU) vorgesehen. Für Empfang der Satellitensignale und Kommunikation können je nach Möglichkeiten der spezifischen Fahrzeuge Aufdach- oder Innen-Antennen eingesetzt werden.

Eine Übersicht über das System aus Beschleunigungssensor (ACC), Mikrofon (MIC) und Basiseinheit (BASE) ist in Abbildung 2 gegeben.

Systembeschreibung - Schema – Systemaufbau, Übersicht

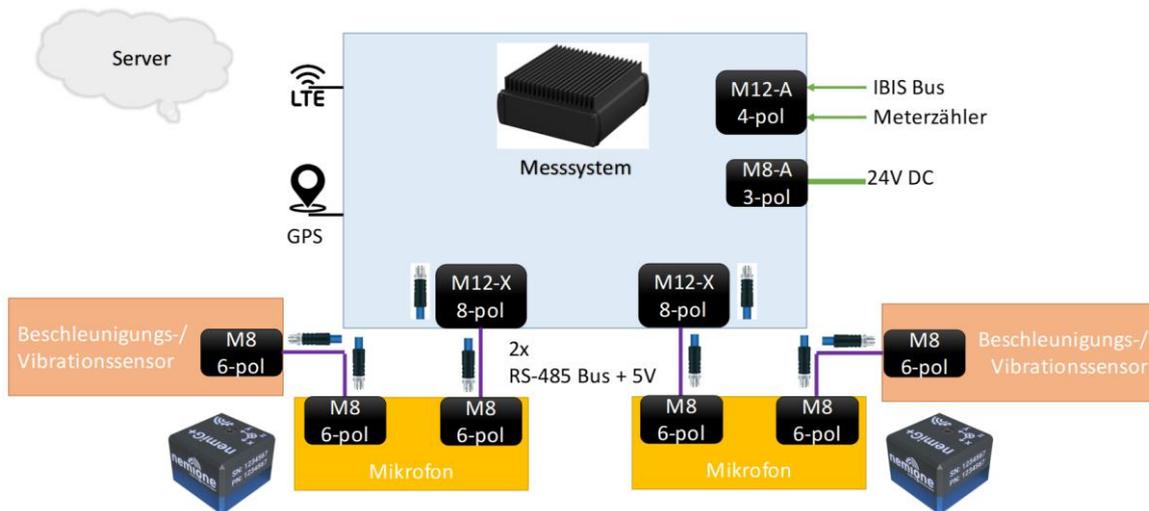


Abbildung 2. Übersicht über das System aus Beschleunigungssensor (ACC), Mikrofon (MIC) und Basiseinheit (BASE).

Das fertige System mit den wichtigsten Eigenschaften ist in Abbildung 3 gezeigt.

BASE

- x86 / 8 GB RAM
- GNSS / 10 Hz / 1 m
- IMU / 100 – 400 Hz
- GPIOs (IBIS)
- SSD / 480 GB
- ETH / LTE Cat. 4
- AI Beschleuniger

gemäß
EN 50155
EN 45545

ACC

200 g / 16 bit / 8 kHz / Z
40 g / 20 bit / 4 kHz / X Y Z

MIC

16 bit / 44,1 kHz

Abbildung 3. Basiseinheit mit abgesetzten Sensormodulen mit Beschleunigungssensoren (ACC) und Mikrofon (MIC).

Größte Herausforderung bei der Durchführung des Projekts war die weltweite Chipkrise in Verbindung mit starken Preissteigerungen für die Hardware im Jahr 2022. Bedingt durch den Chipmangel musste die gesamte interne Hardware-Struktur im Vergleich zur ursprünglichen Planung im Laufe der Zeit mehrmals angepasst werden. Die ursprünglich vorgesehenen Raspberry Pi Compute Module mit einem erforderlichen USB und SATA Controller Module wurden durch x86 SMARC Module ersetzt. Ferner mussten alle ursprünglich vorgesehenen Microcontroller von Microchip durch die zum entsprechenden Zeitpunkt gut lieferbare MCUs ersetzt werden.

Die Entwicklung der Hardware war Ende 2022 zu großen Teilen abgeschlossen. Vor Installation der Messsysteme im Feld wurden im ersten Halbjahr 2023 die zugrundeliegenden Soft- und Firmware-Komponenten erstellt. Alle echtzeit-kritischen Komponenten werden via kabelgebundener Half-Duplex RS485-Schnittstelle per Microcontroller angebunden, um das Betriebssystem des PC-Teils der BASE-Einheiten von diesen Aufgaben zu entkoppeln. Dabei wurde eine Mikrosekunden-genaue Zeitsynchronisierung aller Sensorsignale umgesetzt. Die Sensor Stränge links und rechts sowie die BASE-interne IMU bilden eigene Netzwerke (siehe Abbildung 2), die jeweils auf die zentrale System-Uhr synchronisiert werden, welche wiederum per GPS oder NTP (via Mobilfunk) auf das globale Zeitnormal synchronisiert wird. So können alle einlaufenden Sensor-Daten von MIC und ACC jeweils links und rechts sowie BASE-GNSS und BASE-IMU über einem synchronisierten Zeitstempel mit hoher Genauigkeit erfasst werden.

Innerhalb der BASE-Einheiten werden die jeweiligen Micro-Controller-gesteuerten Sensornetze (Links, Rechts, IMU) per gepufferter USB-Verbindung an ein x86-basiertes Linux PC-System angebunden, wobei auf Intel Atom Prozessoren in Verbindung mit Ubuntu IoT als Betriebssystem zurückgegriffen wird. Hierbei erfolgt eine laufende Überwachung aller Datenströme z. B. auf fehlende Datenpakete und Plausibilität sowie die darauffolgende Ablage der Daten in verlustfrei komprimierten Dateien. Das Linux System stellt via schnellem LTE-Mobilfunkmodem automatisch nach Systemstart eine Mobilfunkverbindung her und loggt sich in ein von i4M zur Verfügung gestelltes VPN-Netzwerk ein. Über das VPN-Netzwerk kann auf die Einheiten vollständig und sicher zugegriffen werden, wodurch das Abrufen neuer Mess-Daten und auch das Updaten und Warten der Systeme erfolgen kann. Die Daten der Systeme werden mittels auf den BASE-Einheiten laufenden FTP-Servern bereitgestellt (siehe auch Abschnitt 2.7.3).

Für die Installation der Systeme wurden neben umfangreichem Testing der Hard-, Firm- und Softwarekomponenten durch i4M technologies ergänzende Anleitungen für die ÖPNV Betreiber erstellt. Weiterhin wurde durch einen externen Gutachter der Fa. MFTEC ein Gutachten gemäß §40 des österreichischen Eisenbahngesetzes erstellt, welches die Messsysteme und deren testweisen Einbau als sach- und fachgerecht bestätigt. Für das Gutachten waren neben umfangreicher Dokumentation auch EMV-Messungen vonnöten, die von i4M technologies gemeinsam mit der FH Aachen in einem modernen Prüflabor der FH Aachen durchgeführt wurden (Abbildung 4).

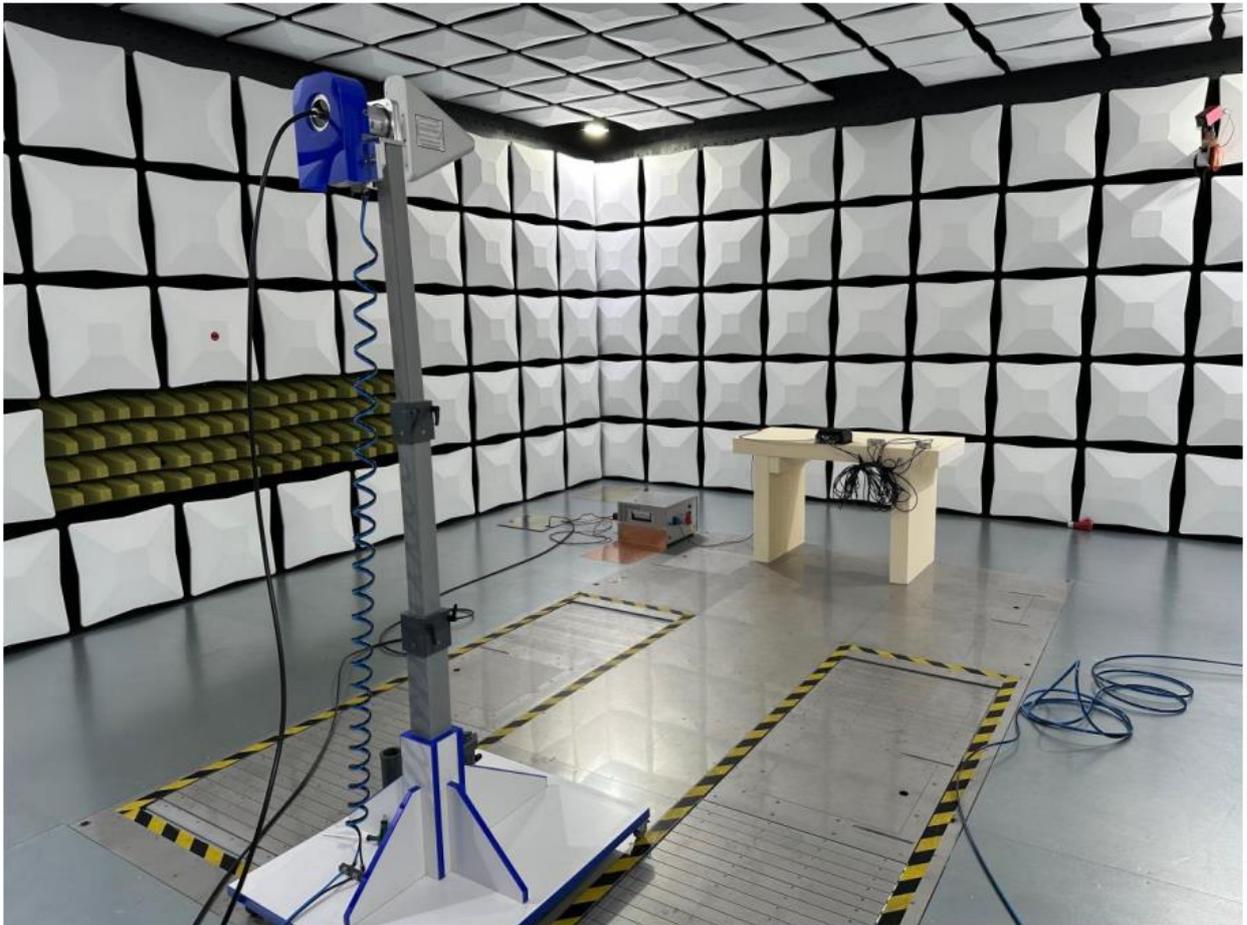


Abbildung 4. Durchführung der EMV-Messungen am Messsystem im Prüflabor der FH Aachen.

Zur einfacheren und schnelleren Installation und zum Test des Systems bei der Inbetriebnahme wurde zudem Software entwickelt, die eine Live-Darstellung der eintreffenden Sensordaten ermöglicht. Ein Beispiel mit Messdaten eines Fahrtabschnitts in Hannover ist in Abbildung 5 dargestellt. Tiefergehende Analysen der Messdaten sind in Abschnitt 2.7.6 gegeben.

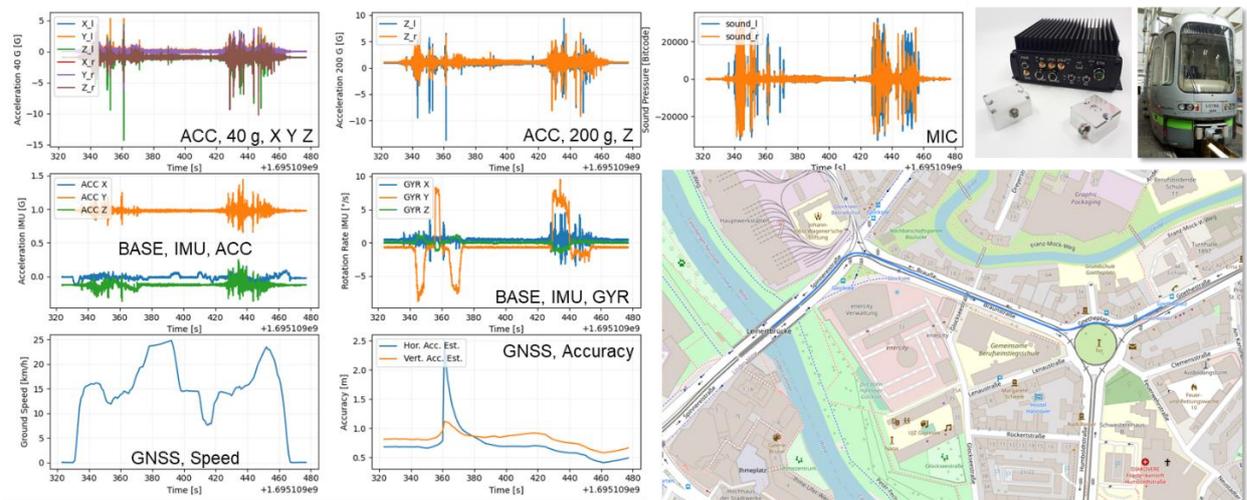


Abbildung 5. Darstellung von erhobenen Messdaten einer Onboard-Sensoreinheit in Hannover. Illustriert sind die hochfrequenten vibroakustischen Messungen (ACC und MIC) und die Sensordaten für die Georeferenzierung (GNSS, BASE IMU ACC und GYR).

Die fahrenden Systeme zeichnen somit Vibrationen in Form von Beschleunigungen und Schallemissionen in Form von Luftdruckänderungen mittels Beschleunigungssensoren und Mikrofonen auf. Hierbei ergeben sich Datenraten von bis zu 8 kHz pro Sensor und Messachse bei den Beschleunigungssensoren und 44.1 kHz Mono bei den Mikrofonen. Diese recht hohen Abtastraten bei hoher vertikaler Auflösung der Signale von 16 bis 20 Bit (je nach Sensor) bewirken eine hohe Datenrate. Pro Tag und Fahrzeug werden so bei dauerhafter, kontinuierlicher Aufzeichnung aller Sensoren ca. 20 GB Messdaten im bereits komprimierten Binär-Formaten von den Systemen erzeugt.

Nach einer anfänglichen Testphase wurde daher eine Triggerung implementiert, die die Speicherung der Messdaten nur bei Bewegung des Fahrzeugs auslöst. Hierbei wird laufend das GNSS-Geschwindigkeitssignal überwacht. Erst wenn eine Mindestgeschwindigkeit von 0,5 m/s überschritten wird, startet die Datenaufzeichnung, wobei 10 Sekunden vor Überschreiten dieser Grenze (Pre-Trigger) mit der Aufzeichnung begonnen und 10 Sekunden nach Unterschreiten dieser Grenze (Post-Trigger) die Aufzeichnung beendet wird. Sollte die Geschwindigkeit während einer laufenden Aufzeichnung kurzzeitig, also für weniger als 10 Sekunden unter den Wert fallen wird nicht mit der Aufzeichnung gestoppt. Es wird erst nach minimal zehnssekündigem Unterschreiten mit der Aufzeichnung aufgehört. Somit ergeben sich Einzelfahrten von Stillstand zu Stillstand (z. B. von Haltestelle zu Haltestelle oder Haltestelle zu Ampel etc.), die jeweils als Dateien abgelegt werden. Eine Aufzeichnung im Stillstand ist nicht sinnvoll und wird so vermieden. Insgesamt fallen durch die starke Nutzung der Fahrzeuge bei den öffentlichen Nahverkehrsunternehmen jedoch trotzdem ca. 5 bis 10 GB pro Tag pro System an. Diese Datenmengen sind weiterhin zu groß, um in einem finalen Produkt übertragen werden zu können. Für eine Skalierung der Zustandsüberwachung mit Regelfahrzeugen sind daher weiterführende Ansätze zur Datenreduktion erforderlich (siehe auch Arbeiten zur Datenreduktion in Abschnitt 2.7.7).

Die Installation des ersten Testsystems erfolgte am 12.06.2023 in Braunschweig auf einer Rangierlok der Hafenbahn Braunschweig (Abbildung 7, links oben). Nach erfolgreichem Abschluss der Tests im Braunschweiger Hafen erfolgte sukzessive ab August 2023 die Ausrüstung von Straßenbahnen in Graz, Hannover, Wien und Basel. Beispielhafte Fotos der Installationen können Abbildung 7 entnommen werden. Bis zum Projektende konnten insgesamt sieben Straßenbahnen in vier Städten und drei Ländern ausgerüstet und insgesamt Daten aus 74 Messmonaten erfasst werden (siehe Abbildung 6).

Messsystem	Fahrzeug	Installation	Deinstallation	Messzeitraum
OnboardEU001	Rangierlok	Juni 2023	Oktober 2023	3,5 Monate
OnboardEU002	Graz 1	August 2023	April 2025	12 Monate
OnboardEU003	Graz 2	Nov. 2023	April 2025	12 Monate
OnboardEU005	Hannover 1	Sept. 2023	Dez. 2023	3 Monate
OnboardEU006	Graz 3	Nov. 2023	April 2025	12 Monate
OnboardEU008	Hannover 2	Nov. 2024	laufend	6 Monate
OnboardEU007	Wien	Juli 2024	laufend	10 Monate
OnboardEU009	Hannover 1	März 2023	laufend	14 Monate
OnboardEU012	Basel	März 2025	laufend	2 Monate

Abbildung 6. Tabellarische Darstellung der Messdatenerhebung auf sieben Straßenbahnen in vier Städten und drei Ländern. Einige Messsysteme sind zum Zeitpunkt der Berichterstellung über das Projektende hinaus in Betrieb.

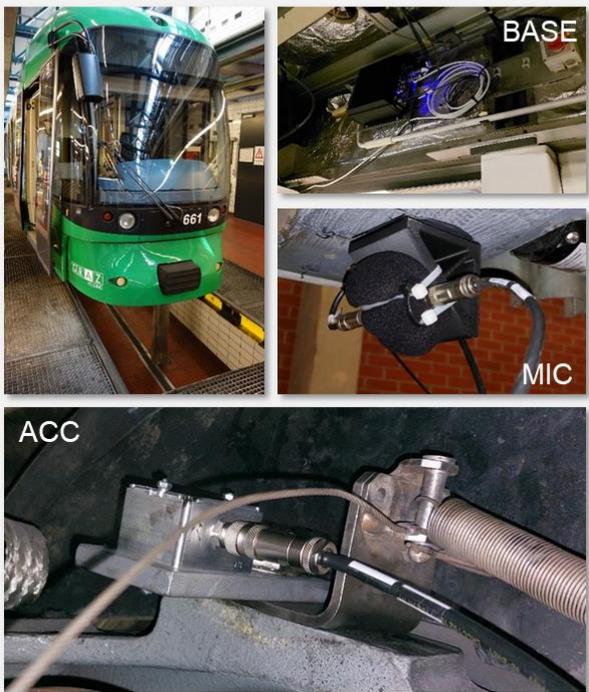
• Braunschweig (Hafenbahn)



• Hannover (ÜSTRA)



• Graz (Holding Graz)



• Basel (BVB)

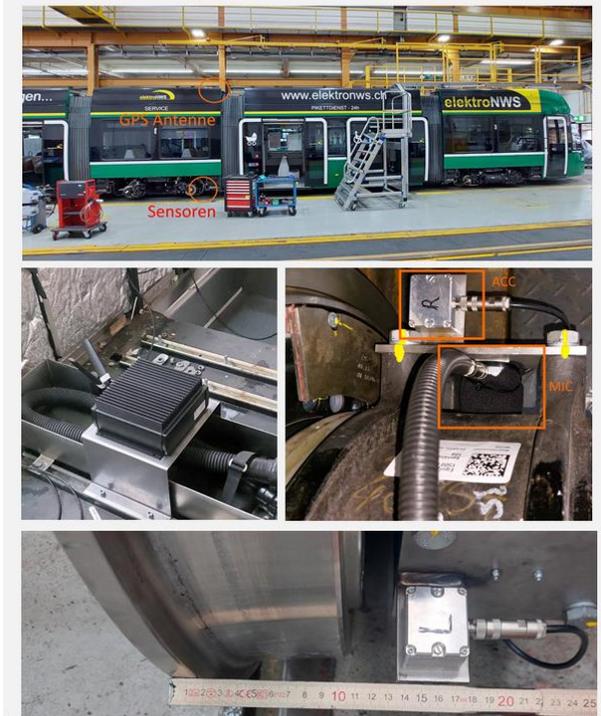


Abbildung 7. Beispielhafte Fotos von Messsysteminstallationen in Braunschweig (links oben), Hannover (rechts oben), Graz (links unten) und Basel (rechts unten).

2.7.2 Referenzdaten und Pass-by-Messungen

Für die Städte Basel, Graz und Hannover wurden Referenzdaten des Gleiszustandes erhoben. Dafür fanden in Graz Begehungen des Gleisnetzes gemeinsam mit dem Betreiber im Dezember 2023 sowie im Mai 2024 statt. Weiters wurden vom Netzbetreiber durchgeführte Erhaltungsmaßnahmen im Beobachtungszeitraum gemeldet. In Hannover wurde im August 2024 eine Begehung gemeinsam mit dem Betreiber durchgeführt, während für Basel vom Netzbetreiber im April 2025 der Gleiszustand inklusive durchgeführter Erhaltungsmaßnahmen übermittelt wurde. Im Rahmen der Begehungen durch die Projektpartner wurden folgende Kategorien der Referenzdaten erhoben:

Abnutzung, Blockherzschaden, Dehnstoß, Doppelspurkranz, Einsenkung, Fahrkantenausbruch, Geflickter Schienenbruch, Riffel, Risse, Schienenausziehvorrückung, Schienenbefestigung locker, Schienenbruch, Schienenkopfabnutzung, Schienenkopfausbruch, Schlupfwellen, Schweißstoß, Spitzblech locker, Spitzenbruch, Stoß, Überwälzung, Unterbau kaputt, Verschmutzung, Verschweißter Wurzelstoß, Weichenherzausbruch, Zungenspitzenausbruch, Zungenspitzenbruch sowie Zungenspitzenschaden.

Abbildung 8 zeigt zwei Fotos für Gleisschäden an dem Bereich der Schiene, die im Kontakt mit der Lauffläche des Rades steht. Daher wird eine deutliche Reaktion der vibroakustischen Emission des Fahrzeuges erwartet. Für jeden erhobenen Datenpunkt wurde neben der Kategorie der Zeitpunkt, die Lage im Gleisnetz sowie das Ausmaß des Schadens (leicht, mittel, schwer) erfasst. Zur Unterstützung des überwachten Lernens wurden auch Abschnitte im Gleisnetz erfasst, die im Rahmen der Begutachtung als optisch einwandfrei beurteilt wurden.



Abbildung 8. Fotos eines Schienenbruchs (links) sowie eines Schienenkopfausbruchs (rechts) für Beispiele an Gleisschäden, an denen von einer deutlichen Beeinflussung der vibroakustischen Sensordaten ausgegangen werden kann.

Zum Training der KI-Modelle des überwachten Lernens bilden die aufwendig erhobenen Referenzdaten eine grundlegende Basis, da den an den Fehlstellen auffällig auftretenden vibroakustischen

Merkmale die entsprechende Schadenskategorien zugeordnet werden kann. Dadurch ist ein tiefergehendes Verständnis der Auswirkungen der Gleisschäden möglich und bildet auch die Grundlage zur zeitlichen Modellierung der Entwicklung von Gleisschäden. Letztere ist eine Voraussetzung, um im Rahmen einer vorausschauenden Instandhaltung die Effizienz der aufzuwendenden Ressourcen im Erhaltungsmanagement zu maximieren.

Für die Verwendung von Onboard-Sensordaten in der Lärmkartierung wurden Pass-by-Messungen im Grazer Stadtgebiet durchgeführt, um den Vorbeifahrtspegel einer Straßenbahn unter unterschiedlichen Ausbreitungsbedingungen zu bestimmen. Dabei wurden variable Fahrzeuggeschwindigkeiten, unterschiedliche Bebauungsdichten, verschiedene Oberbautypen sowie Streckengeometrien (Bogen vs. gerade Strecke) untersucht. Die ausgewählten Messorte sind in Abbildung 9 dargestellt. Eine hohe Bebauungsdichte führt dabei durch Mehrfachreflexionen an den angrenzenden Fassaden der Häuser zu einem erhöhten Immissionserschalldruckpegel am Mikrofon im Vergleich zu einer Ausbreitung im Freifeld. Es wurden die Vorbeifahrten der mit Sensorik ausgestatteten Straßenbahnen gemessen, wobei ein Mikrofon in 7,5 m Entfernung zur jeweiligen Gleismitte und 1,2 m oberhalb der Schienenoberkante den Verlauf des Schalldrucks aufzeichnete. Die Vorbeifahrten wurden in beiden Fahrtrichtungen aufgezeichnet, wobei auf eine getrennte Auswertung aufgrund des akustisch gesehenen symmetrischen Aufbaus der Fahrzeuge verzichtet wurde.

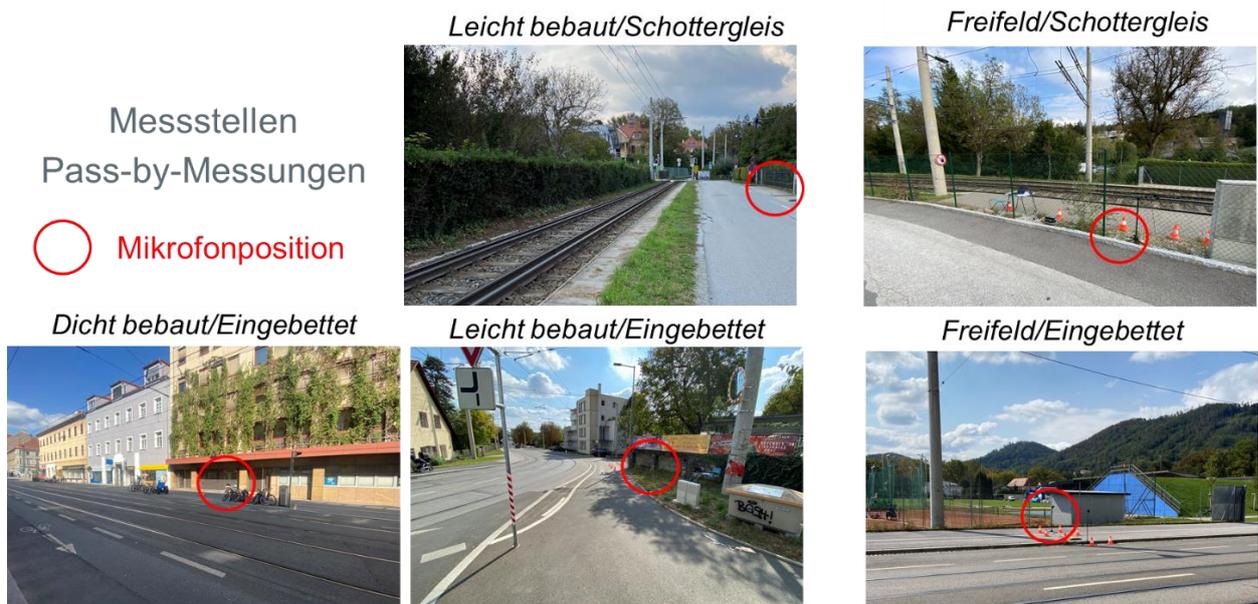


Abbildung 9. Orte der Pass-by-Messungen im Grazer Stadtgebiet. In rot ist die Mikrofonpositionen eingezeichnet.

Ein Datenbeispiel für eine Pass-by-Messung ist in Abbildung 10 gezeigt. Für das Onboard-Mikrofon ist für den relativ konstanten Schalldruckpegel eine Abhängigkeit von der Geschwindigkeit ersichtlich. Für das externe Mikrofon ist der typische Pegelverlauf einer Vorbeifahrt eines Fahrzeuges ersichtlich, der maßgeblich von der Entfernung (und auch der Geschwindigkeit) beeinflusst wird. Zur Bildung von Übertragungsfunktionen ist es zielführend, diesen zeitlichen Verlauf auf eine Kennzahl abzubilden. In der rechten Grafik von Abbildung 10 sind drei mögliche Varianten einer Kennzahl eingezeichnet: Der Schallereignispegel L_{AE} , der maximale Schalldruckpegel $L_{Af,max}$ sowie der energieäquivalente Dauerschallpegel L_{Aeq} . L_{AE} und L_{Aeq} werden für den Zeitbereich berechnet, in dem der Schalldruckpegel weniger als 10 dB unter dem Maximalwert der Vorbeifahrt liegt. Detailliertere Analysen und die Bildung der Transferspektren sind in Abschnitt 2.7.6.4 dargestellt.

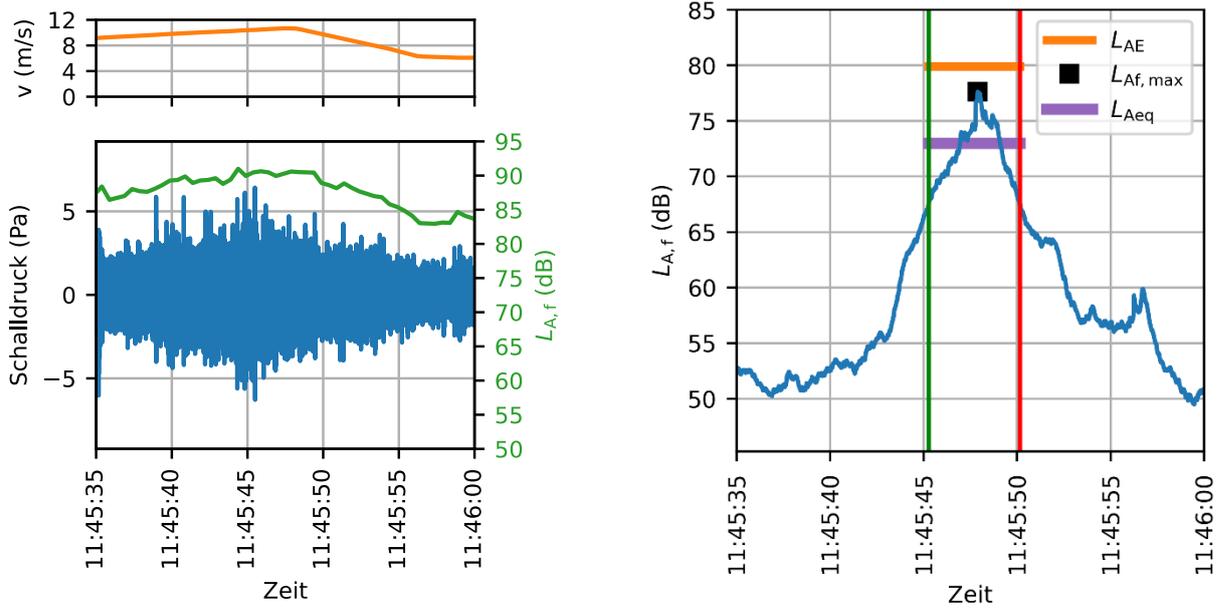


Abbildung 10. Datenbeispiel einer Pass-by-Messung in Graz. Auf der linken Seite ist der Schalldruck, der frequenz- und zeitwertige Schalldruckpegel $L_{A,f}$ sowie die gemessene Geschwindigkeit der Straßenbahn der Vorbeifahrt gezeigt. Auf der rechten Seite der Schalldruckpegel $L_{A,f}$ an der externen Mikrofonposition.

2.7.3 Datenmanagement

Für das Projekt wurde bei der i4M technologies GmbH ein Datenmanagementsystem mit 2 Terabyte Speicherplatz eingerichtet. Die Daten der Messsysteme auf den Straßenbahnen werden über ein mobiles VPN-Netzwerk auf das zentrale Management-System übertragen (Abbildung 11) und von dort allen Projektpartnern für die weiterführenden Verarbeitungsschritte und Analysen bereitgestellt. Aufgrund des begrenzten Speicherplatzes auf den Messsystemen sowie den begrenzten Datenübertragungsbandbreiten über Mobilfunk wurden die Messdaten in einem stark komprimierten und optimierten Binärformat erzeugt und übertragen.



Abbildung 11. Schematische Darstellung des Datenhandlings im Projekt OnboardEU über das zentrale Datenmanagementsystem der i4M technologies GmbH.

Im Zuge des Datenmanagements erfolgt eine Umwandlung der Messdaten in das im wissenschaftlichen Bereich weit verbreitete und einfacher zu verarbeitende Format HDF5 ([16]). Insgesamt wurden im Projektverlauf über 3,2 Terabyte Messdaten im Format HDF5 erzeugt. Ergänzend zu den Messdaten wurden die Metadaten der Messsysteme in leicht menschen- und maschinenlesbaren TOML-Dateien aufbereitet.

Die Metadaten umfassen folgende Informationen über die individuellen Messsysteme:

- Absolute Positionen der Sensoren (Beschleunigungssensoren, Mikrofone, Inertialmesseinheit, Antenne des GNSS-Empfängers) im Fahrzeugbezugsrahmen
- Orientierung (Quaternions) der Sensoren im Fahrzeugbezugsrahmen
- Eigenschaften der Sensoren (Typ, Abstraten Umrechnungsfaktoren)

Die weiterführenden Datenverarbeitungsschritte erfolgten unter Nutzung der HDF5 und TOML-Dateien. Beispiele der erzeugten Dateien sind in den veröffentlichten Datensätzen enthalten (siehe Abschnitt 2.7.5). Für die geisgenaue Georeferenzierung der erhobenen Messdaten (siehe Abschnitt 2.7.4) wurden beim DLR stadtspezifische automatisierte Verarbeitungsketten umgesetzt. Die erzeugten Georeferenzierungen wurden ebenfalls im Format HDF5 bereitgestellt. Die weiterführenden Datenanalysen (AP5, Abschnitt 2.7.6) erfolgten darauf aufbauend in den Prozessierungs- und Entwicklungsumgebungen der Projektpartner AIT und DLR.

2.7.4 Georeferenzierung

Gegenstand der Arbeiten in „AP 3 Datenmanagement, digitale Karte und Georeferenzierung“ war die gleisgenaue Verortung von Onboard-Daten (siehe auch [17]). Der Begriff Georeferenzierung ist als Anreicherung von z. B. Vibrationsdaten mit gleisgenauen Positions- und Bewegungsinformationen zu verstehen. Position bedeutet Position im Gleisnetz mit Bezug zu einer digitalen Karte. Zusätzlich zu geographischen Koordinaten werden also Gleisnummern und Distanzen bereitgestellt.

Die entwickelte Implementierung wurde veröffentlicht. Dokumentierter Open-Source Code für die Georeferenzierung ([18], <https://github.com/DLR-TS/railpos-onboardeu>) mitsamt einem Datenbeispiel (<https://doi.org/10.5281/zenodo.16368240>) kann ergänzend zu diesem Bericht eingesehen werden.

Folgende Aspekte wurden erforscht und für die Ausführung auf Projektdaten in Python implementiert und integriert.

Digitale Gleiskarten wurden aus unterschiedlichen Quellen extrahiert und für die Georeferenzierung aufgearbeitet. Als Quellen wurden OpenStreetMap (OSM) und Betreiberdaten genutzt. Mit der Aufarbeitung der offen zugänglichen OSM-Daten konnte eine agile Umsetzung der Georeferenzierung für verschiedene Städte auch ohne Betreiberdaten sichergestellt werden. Mithilfe von Betreiberdaten aus Graz wurde die Arbeit mit unterschiedlichen Detailgraden im Kartenmaterial untersucht (von sehr kleinteiligen Kartendaten mit einer separaten Geometrie pro Kurve/Gerade/Übergangselement zu Linienkarten mit einer einzelnen Geometrie für alle Abschnitte von der Anfangs- bis zur Endhaltestelle).

Die in AP2 erhobenen Onboard-Daten beinhalten einerseits Sensordaten für die Zustandserfassung (Schall, Achslagerbeschleunigungen). Andererseits werden GNSS- und IMU-Daten als Datengrundlage für die Georeferenzierung / Verortung erhoben. GNSS steht für Global Navigation Satellite Systems und beschreibt die Satellitennavigation mit GPS und Galileo. Onboard-GNSS umfasst immer mindestens eine Antenne und einen Empfänger. IMU steht für Inertial Measurement Unit, eine Kombination aus günstigen Sensoren für Fahrzeugbeschleunigungen und -drehraten. Um die vereinheitlichte Verarbeitung von Daten mehrerer Fahrzeuge zu ermöglichen, wurden Metadaten für die Positionen und Orientierungen der Sensorkomponenten in einem Fahrzeugkoordinatensystem gelistet.

Die Georeferenzierung wurde modular in mehreren separaten Arbeitsschritten realisiert (Abbildung 12). Hierzu gehören die Vorverarbeitung der Sensordaten, die Aufteilung von Messtagen (oder längeren Aufnahmen mit mehreren Stopps und möglichen Änderungen der Fahrtrichtung) in einzelne Fahrten, die Pfadschätzung für einzelne Fahrten, die Positionsschätzung mithilfe von Kalman-Filter-Methoden für eine Fahrt und einen zuvor bestimmten Pfad, sowie die abschließende Bereitstellung von Ergebnisdaten für die weitere Verarbeitung in geeigneten Dateiformaten und Koordinatensystemen.

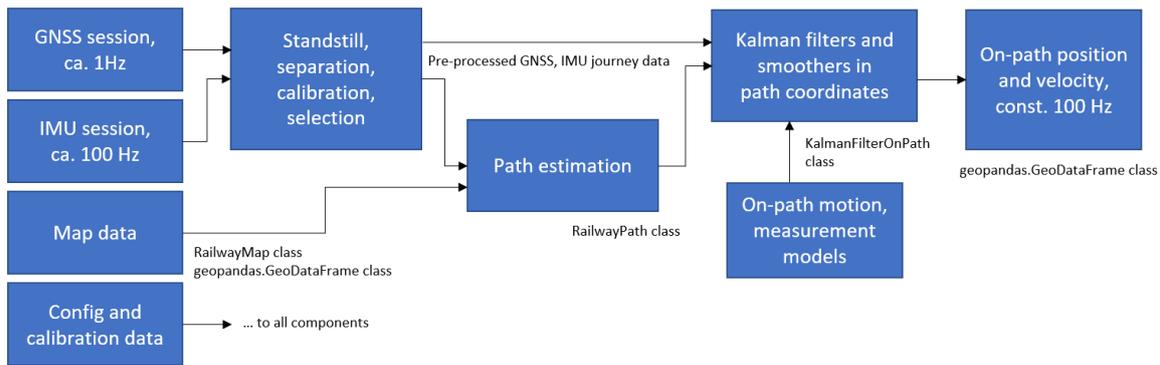


Abbildung 12. Modulare Verarbeitungskette der Georeferenzierung mit Details zu Eingangs- und Ergebnisdaten, Verarbeitungsschritten und genutzten Software-Klassen.

Die Pfadschätzung für einzelne Fahrten wurde zuvor auf Basis von Karten- und GNSS-Daten realisiert. Eine Liste von Pfadhypothesen wurde aus den möglichen Pfaden (Gleissequenzen) zwischen potentiellen Start- und Endgleisen erstellt und mithilfe von projizierten GNSS-Positionen bewertet. Durch die Struktur von Tram- und Stadtbahnnetzen (mit zahlreichen Depots und Schleifen) kann die Anzahl der Pfadhypothesen jedoch sehr hoch werden. Dieser Herausforderung wurde durch die Einführung erweiterter Gütekriterien begegnet (Projektionsfehler, Abgleich von Distanzen, Gleisanzahl bei vergleichbarer Güte). Zudem wurde die Einbindung von betrieblichen Informationen realisiert (insbesondere Rechtsverkehr).

Kalman-Filter-Methoden wurden als modulare, robuste und etablierte Werkzeuge für die Berechnung von Positions- und Bewegungsinformationen mit einer konstanten Rate von 100 Hz gewählt. Die KF-Implementierung besteht hierbei aus einzelnen Funktionen für die Initialisierung, die Prädiktion von Zeitschritt zu Zeitschritt mithilfe von IMU-Beschleunigungen, sowie Mess-Updates für die Einbindung von GNSS-Positionen und -Geschwindigkeiten (Raten von 1 Hz mit Lücken durch mangelnden GNSS-Empfang). Da eine Offline-Anwendung basierend auf zuvor gesammelten Daten in einem Batch vorliegt, können die KF-Ergebnisse der Vorwärts-Iteration in einer Rückwärts-Iteration mit einem Rauch-Tung-Striebel-Smoother geglättet werden. Insbesondere führt dies zu Verbesserungen bei kurzen Lücken in den GNSS-Daten in Unterführungen oder überdachten Haltestellen.

In Abbildung 13 ist beispielhaft das Geschwindigkeitsprofil einer Fahrt illustriert (oben links), wie es anhand der Georeferenzierung bereitgestellt wird. Die GNSS-Punkte mit geringerer Rate werden als Eingangsgröße in Kalman Filter Mess-Updates verarbeitet. Das Vorzeichen zeigt die Fahrtrichtung. Oben rechts ist die Beschleunigung des Fahrzeugs in Fahrtrichtung illustriert, wie sie von der Inertialmesseinheit (IMU) gemessen wird. Der Offset- oder Bias-Fehler wird separat geschätzt und kompensiert. Die Beschleunigung wird in Kalman Filter Zeit-Updates verarbeitet. Unten links ist die Güte verschiedener Pfade im Schritt der Pfadschätzung gezeigt. Unten rechts ist ein herausforderndes Beispiel gezeigt, bei welchem trotz GNSS-Positionsfehlern, der befahrene Pfad korrekt bestimmt werden konnte. Dies ist durch die Einbindung von Informationen zum Rechtsverkehr möglich.

Die Georeferenzierung wurde für die automatisierte Verarbeitung von Sensordaten, Metadaten und digitalen Karten der jeweiligen Fahrzeuge und Einsatzorte umgesetzt. Der modularen Verarbeitungskette folgend wurden Software-Bausteine in Python programmiert. Für die Softwareentwicklung wurde der Ansatz Domain-Driven-Design (DDD) genutzt.

Die Leistungsfähigkeit der umgesetzten Georeferenzierung wurde kontinuierlich durch verschiedene Ansätze überprüft. Hierzu zählen die qualitative Analyse von Zwischen- und Endergebnissen der Georeferenzierung mithilfe von interaktiven Plots und Karten, um eine geeignete Passung der

Ergebnisse mit Einsichten aus den Eingangsdaten festzustellen. Quantitative Überprüfungen wurden u. a. bei der Rechenzeit vorgenommen. Dies war z. B. besonders wichtig, um einen performanten Umgang mit der großen Zahl von Pfadhypothesen in Gleisnetzen mit Depots und Schleifen zu erreichen.

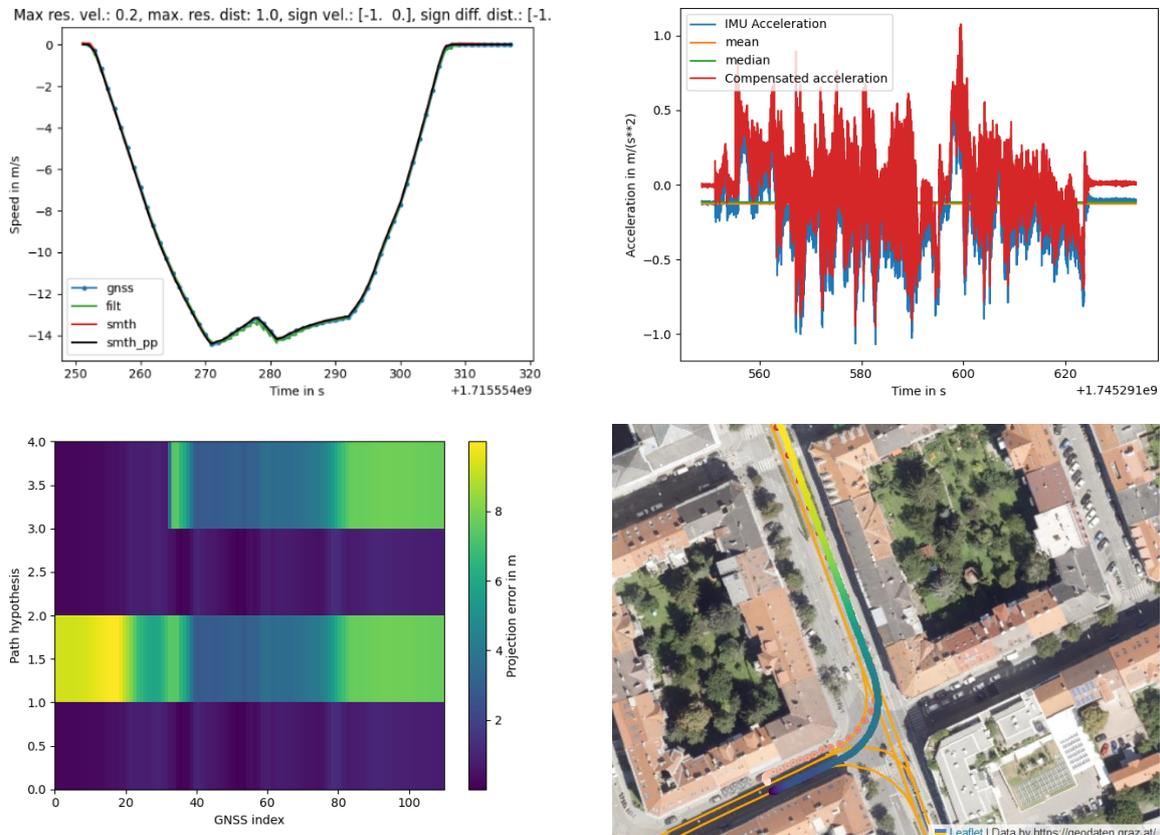


Abbildung 13. Beispielergebnisse der Georeferenzierung.

Ergebnisse wurden für mehrere Einsatzorte und -fahrzeuge über längere Zeiträume erzeugt. Diese gleisgenauen Positions- und Bewegungsinformationen stellen die Grundlage für eine gleisbezogene Analyse von z. B. Achslagerbeschleunigungsdaten dar. Jedoch können sie auch für sich allein relevante Informationen über die Nutzung der Infrastruktur bieten und somit einen Mehrwert für die Betreiber und weitere Stakeholder bieten.

In Abbildung 14 und Abbildung 15 sind die Anzahl der äquivalenten vollständigen Befahrungen der verschiedenen Streckenabschnitte in Hannover, Basel und Graz gezeigt. Die Anzahl äquivalenter vollständiger Befahrungen ergibt sich aus der Gesamtsumme der auf dem Streckensegment zurückgelegten Fahrtmeter geteilt durch Länge des Streckensegments in Metern. Teilweise wurden über 800 äquivalente vollständige Befahrungen erreicht (Farbskala siehe Abbildung 15).

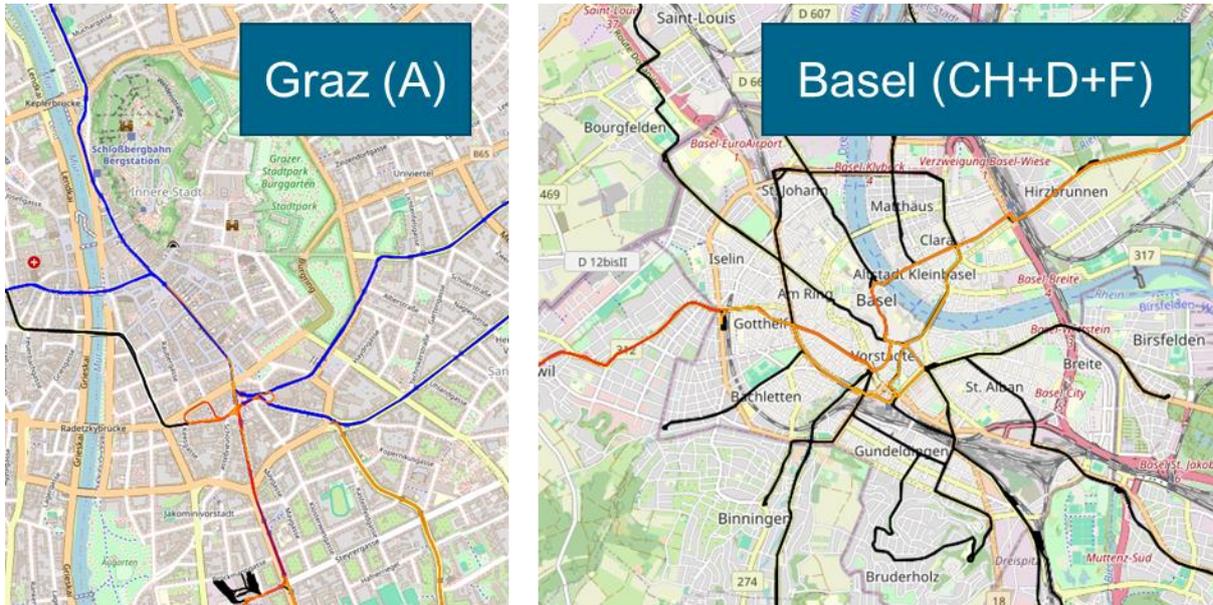


Abbildung 14. Aggregierte Informationen aus den Ergebnissen der Georeferenzierung über längere Zeiträume für verschiedene Einsatzorte. Blau gefärbt sind Gleise, welche mehr als 800 äquivalente Befahrungen aufweisen. Die Farbskala ist in Abbildung 15 enthalten.

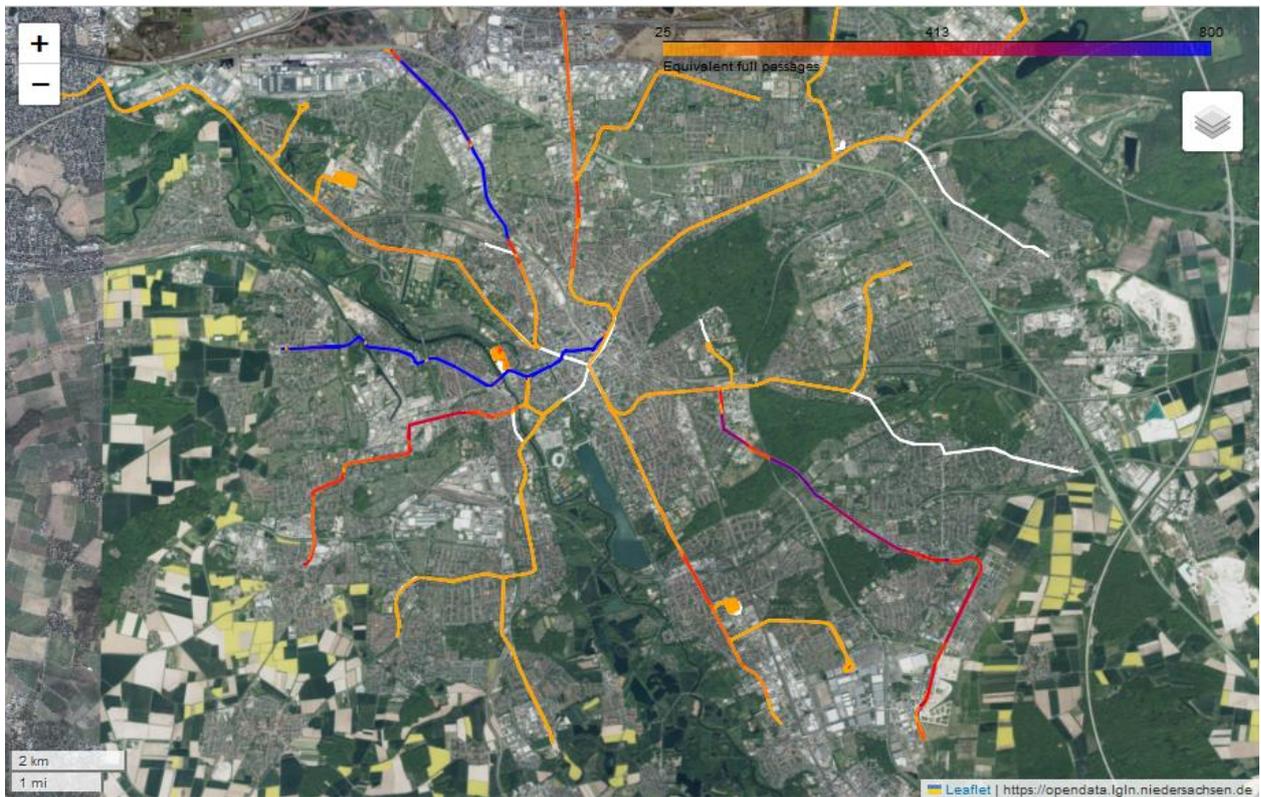


Abbildung 15. Aggregierte Befahrungen für das gesamte Netz in Hannover.

2.7.5 Datenkatalog

Im Rahmen des Projektes wurden zwei offene Datensätze erzeugt und über die Plattform zenodo zitierfähig unter einer permissiven Lizenz (CC-BY 4.0) veröffentlicht. Beide Datensätze sind über die Mobiltheke auffindbar.

Der Datensatz „OnboardEU: Track-Selective Georeferencing for Railways – Sample Measurement Data“ (<https://doi.org/10.5281/zenodo.16368240>) ergänzend zur Veröffentlichung einer Beispiel-Implementierung der Georeferenzierung ([18]) umfasst Messdaten (GNSS und Inertialmesseinheit), Metadaten des Messsystems, die erforderliche hochgenaue digitale Karte sowie die daraus abgeleiteten Georeferenzierungen für Fahrten einer Rangierlok im Braunschweiger Hafen.

Der Datensatz „OnboardEU: Urban light rail vehicle-track interaction for infrastructure condition monitoring“ (<https://doi.org/10.5281/zenodo.16980642>) umfasst einen Katalog mit ausgewählten Datenbeispielen von Fahrzeugreaktionen an verschiedenen Gleisfehlstellen. Die Datenbeispiele wurden anhand der erhobenen Referenzdaten aus den georeferenzierten Messsystemdaten (Beschleunigungs- und Mikrofonmessungen) der regulär verkehrenden Straßenbahnen extrahiert. Der Datenkatalog besteht aus anonymisierten Daten ohne absoluten Ortsbezug.

Der Datensatz besteht aus aufbereiteten Sensormessdaten im Format HDF5 ([16]) sowie wo erforderlich Metadaten in Form von mensch- und maschinenlesbaren toml-Dateien sowie begleitenden Dateien und Abbildungen in weit verbreiteten, leicht lesbaren Formaten.

Detailliertere Informationen können den jeweiligen Datenveröffentlichungen entnommen werden.

location_identifier	location_description	# number_of_vehicles	# number_of_journeys_total
Missing: 0 (0%) Distinct: 25 (100%)	Missing: 0 (0%) Distinct: 22 (88%)	Missing: 0 (0%) Distinct: 2 (8%)	Missing: 0 (0%) Distinct: 13 (52%)
25 Distinct values		Bar chart showing distribution of number of vehicles and journeys per location.	
0	Y27_1545050	Corrugated track, section of 9 m length	146
1	Y27_18650100	Weakly corrugated track, 86 meter long track	146
2	Y40_285050	Squats at two spots, 12 meters apart	145
3	Y42_235050	Change slab to ballast track	141
4	Y43_15050	Worn frog	146
5	Y1066_1475050	Rail joint	131
6	Y1066_1625050	Rail joint	131
7	Y1066_1765050	Rail joint	131
8	Y617_3285050	Corrugation in narrow curve, several spots over	2
9	Y457_545050	Corrugated track section of 14 m length	144
10	Y762_335050	Corrugated track section of 7 m length. Conta	146
11	Y841_1645050	Squats. Following the squats, this section also	144
12	Y841_1705050	Corrugated track section (10 m length). Conta	144
13	Y841_1905050	Emerging broken rail near a rail joint. Before t	144
14	Y1057_245050	Rail joint	138
15	Y1063_75050	Corrugated track	116
16	Y596_1545050	Corrugated track, section of 6 m length. Conta	138
17	Y596_1705050	Corrugated track section, 6 m length. Contain	138
18	Y596_2315050	Emerging broken rail. Section contains corrug	138
19	Y596_2505050	Corrugated track section (4 m). Contains an ei	138
20	Y596_4325050	Squats	133
21	X1666_175050	Broken rail, medium severity, at two spots, 13.	45
22	X1198_2985050	Lightly broken rail at two spots, 1.6 meters ap	95
23	X590_33050	Heavily broken rail at four close spots, with in	356
24	X1417_95050	Corrugated track section of 21 m length	387

Abbildung 16. Informationen zum Datenkatalog in tabellarischer Form (anonymisierte Gleisfehlstellen-ID, Beschreibung der Gleisfehlstelle, Anzahl von Fahrzeugen im Datenbeispiel, Anzahl der Überfahrten).

Schlussbericht mFUND OnboardEU

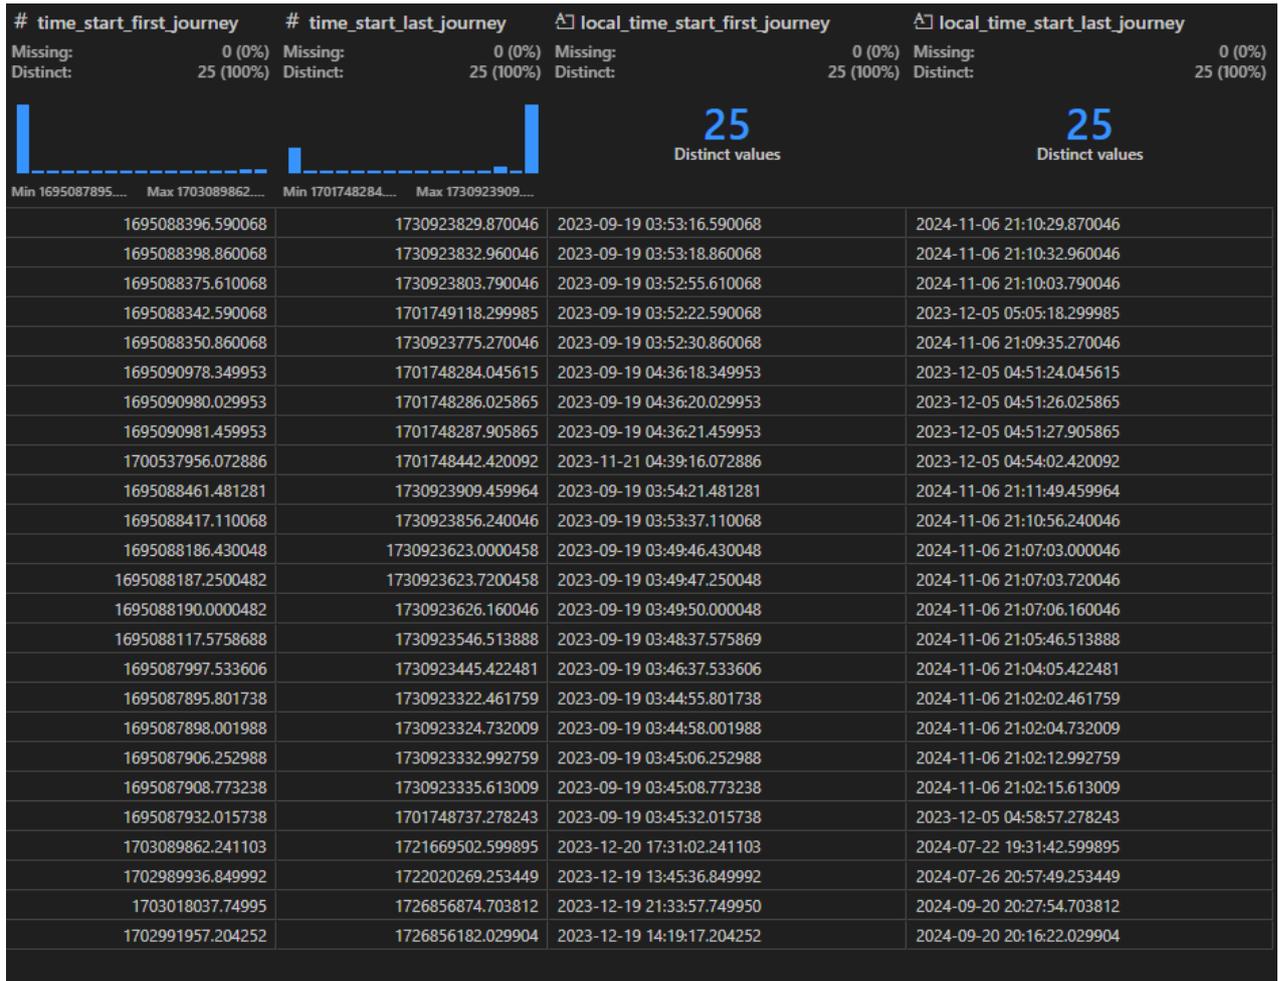


Abbildung 17. Informationen zum Datenkatalog in tabellarischer Form (Zeitstempel der ersten und letzten Überfahrt im Datenbeispiel).

Schlussbericht mFUND OnboardEU

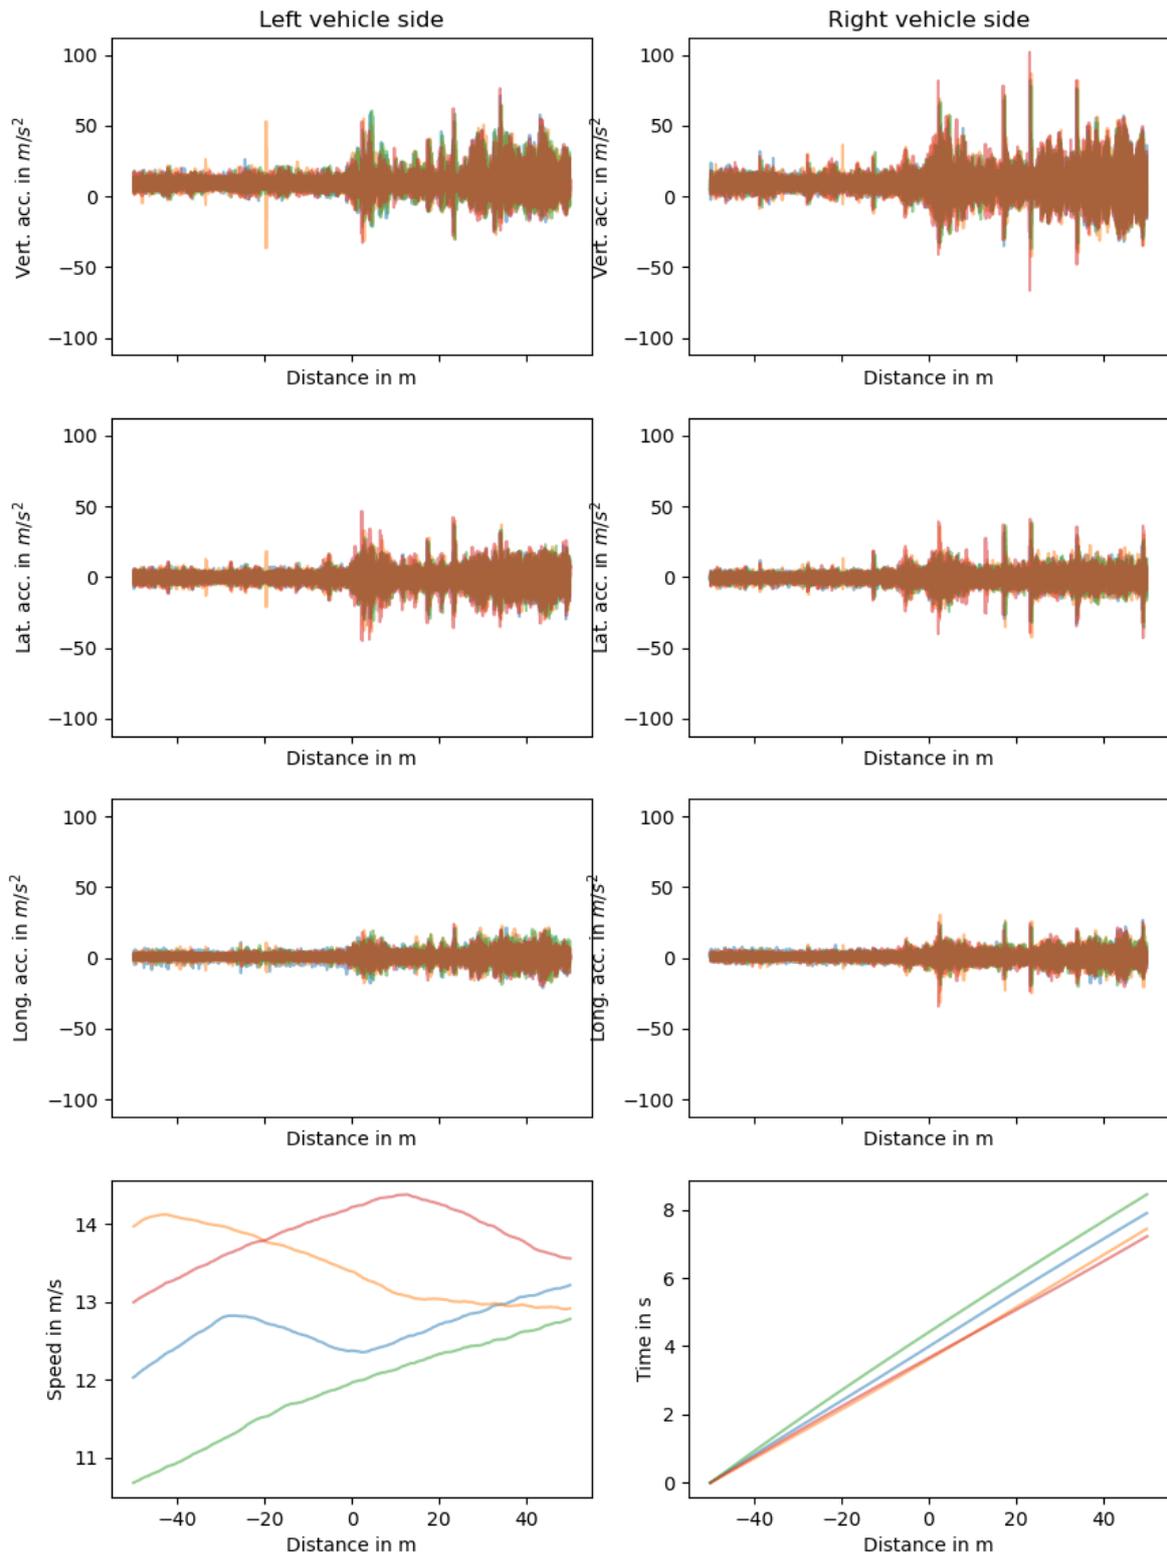


Abbildung 18. Beispiel aus dem Datenkatalog. Anonymisierte Beschleunigungsdaten aus mehreren Überfahrten rund um eine annotierte Fehlstelle. Zudem enthalten sind Geschwindigkeiten, Zeitstempel, relevante Metadaten und Informationen über die Fehlstelle.

2.7.6 Zustandsüberwachung und Lärmkartierung

Bezüglich der Anwendung maschineller Lernverfahren für die Zustandsüberwachung wurden im Projekt zwei Ansätze verfolgt: Das überwachte und das unüberwachte maschinelle Lernen.

Der Vorteil unüberwachter Lernverfahren ist deren unmittelbare Anwendbarkeit zur Erkennung von Anomalien und Mustern in bislang unbekanntem Daten. Auf die vorausgehende aufwändige Erstellung von umfangreichen annotierten Trainingsdaten kann verzichtet werden. Dies verringert erheblich den vor der Datenanalyse erforderlichen Aufwand und erlaubt die schnelle Bereitstellung von ersten Ergebnissen. Nachteilig ist, dass die erkannten Muster und Anomalien im Nachgang mit entsprechender Fachexpertise ausgewertet und interpretiert werden müssen, um praktisch nutzbare Informationen für die Zustandsüberwachung und Instandhaltung abzuleiten.

Der Vorteil überwachter Lernverfahren liegt dahingehend darin, dass diese als Ergebnis einer durchgeführten Klassifizierung direkt nutzbare Informationen aus den Daten gewinnen können. Nachteilig ist, dass dafür im Vorhinein entsprechende Trainingsdaten bereitgestellt werden müssen. Dieser Vorgang der Annotation benötigt entsprechende Referenzdaten, tiefgehende Fachexpertise und ist sehr zeitaufwändig.

Bei der Etablierung eingebetteter Zustandsüberwachungsansätze wie der Nutzung von vibroakustischen Daten aus dem Regelbetrieb ist zu Beginn eine gleichzeitige Anwendung beider Ansätze empfehlenswert. Der Einsatz der unüberwachten Lernverfahren stellt unmittelbar erste nutzbare Ergebnisse bereit, da Streckenbereiche mit auffälligen Fahrzeugreaktionen automatisch erkannt und näher inspiziert werden können. Erfahrenen Anlagenverantwortlichen ist damit häufig bereits eine erste Einschätzung der Strecken möglich. Insbesondere können Bereiche mit erhöhtem Inspektionsbedarf identifiziert und Streckenbegehungen zielgerichtet und effektiv durchgeführt werden. Diese Nutzung der mit unüberwachten Lernverfahren erkannten Anomalien und Muster stellt gleichzeitig die Grundlage für eine Annotation der erhobenen Messdaten dar. Dadurch entsteht im operativen Betrieb iterativ ein kontinuierlich wachsender mit der vorhandenen Fachexpertise annotierter Datenbestand, der begleitend für das Training überwachter Verfahren genutzt werden kann. Nach einer entsprechenden Trainingsphase der überwachten Verfahren kann dann längerfristig auf den Einsatz unüberwachter Lernverfahren verzichtet werden.

Die Arbeiten zur Zustandsüberwachung mit unüberwachten (Abschnitt 2.7.6.2) und überwachten (Abschnitt 2.7.6.3) maschinellen Lernverfahren sowie zur Lärmkartierung (Abschnitt 2.7.6.4) sind in den jeweiligen Unterabschnitten dargestellt.

Grundlage für diese weiterführenden Analysen waren die erhobenen vibroakustischen Messungen sowie die Ergebnisse der Georeferenzierung, jeweils im HDF5-Format. Den weiteren Analysen vorausgehend wurde eine Evaluation der Daten hinsichtlich Qualität und Wiederholbarkeit durchgeführt. Dabei konnte eine allgemeine hohe Datenqualität der erhobenen Messdaten bestätigt sowie eine sehr gute Wiederholbarkeit der erhobenen Achslagerbeschleunigungen auf den individuellen Streckenabschnitten festgestellt werden. Die durchgeführten Analysen werden im Folgenden an Beispielen eines Streckenabschnitts in Hannover exemplarisch dargestellt.

In Abbildung 19 ist das Geschwindigkeitsprofil einer Fahrt zwischen den Haltestellen Brunnenstraße und Ehrhartstraße in Hannover nach der erfolgten Georeferenzierung dargestellt. Das Vorzeichen der Fahrzeuggeschwindigkeit ist richtungsabhängig und zeigt so die Fahrtrichtung der Zweirichtungs-Fahrzeuge in Hannover an. Gut zu erkennen sind die Bereiche mit geringeren Geschwindigkeiten (gelbe bis grüne Färbung) im Bereich der beiden Haltestellen und der Kurve.



Abbildung 19. Farbkodiertes Geschwindigkeitsprofil einer Fahrt von Haltestelle Brunnenstraße (rechts) zur Haltestelle Ehrhartstraße (links). Hohe Geschwindigkeiten in blau, niedrige Geschwindigkeiten in gelb. Das Vorzeichen zeigt die Fahrtrichtung des Zweigrichtungs-Fahrzeugs an.

In Abbildung 20 sind die vertikalen Beschleunigungen am Radlager für zwei Befahrungen dieses Streckenabschnitts dargestellt. Erkennbar sind die ausgeprägten streckenabhängigen Signalanteile und die gute Wiederholbarkeit der Messungen. Aufgrund leicht unterschiedlicher Geschwindigkeitsprofile ergibt sich bei der Fahrtdauer zwischen den Haltestellen ein Unterschied von ca. 10 Sekunden. Diese betriebstypischen Unterschiede werden im weiteren Verlauf durch die Übertragung in den Distanzbereich anhand der gleisgenauen Georeferenzierung ausgeglichen. Weiterhin gehen die ermittelten Geschwindigkeitsprofile in die weiteren Auswertungen mit ein, um die gegebene Geschwindigkeitsabhängigkeit der Achslagerbeschleunigungen zu berücksichtigen (siehe auch Abbildung 22).

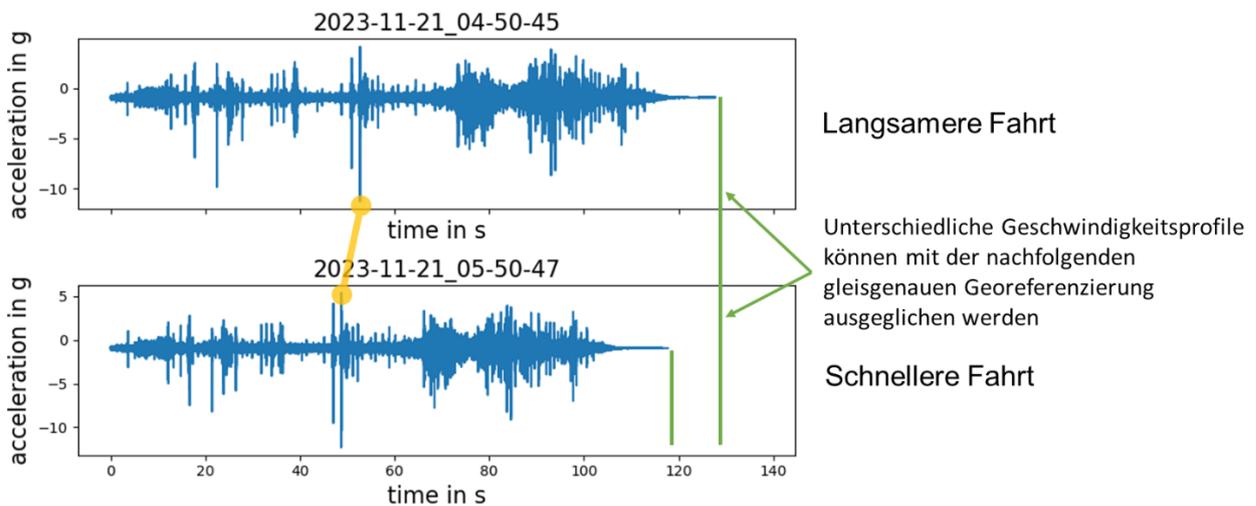


Abbildung 20. Vertikale Beschleunigungen am Radlager zweier Fahrten von Haltestelle Brunnenstraße zu Haltestelle Ehrhartstraße mit leicht unterschiedlichem Geschwindigkeitsprofilen.

Eine Zeit-Frequenzbereichs-Analyse (Abbildung 21) bestätigt die gute Wiederholbarkeit in einem breiten Frequenzbereich bis zu 2000 Hz. Gut zu erkennen sind in Ihrer Frequenz geschwindigkeitsabhängige Signalanteile unter 300 Hz von ca. 70 bis 90 Sekunden bei beiden Fahrten

In Vorbereitung auf die Auswertung mit maschinellen Lernverfahren wurden Frequenzbereichsmerkmale (z. B. Schwingleistungen in Oktav-Bändern, siehe Abbildung 22) berechnet und analysiert. Wie erwartet zeigt sich eine ausgeprägte systematische Abhängigkeit von der Geschwindigkeit

der Fahrzeuge (Abbildung 22, rechts, „Hockey-Schläger“). Ausgeprägte Fahrzeugreaktionen aufgrund von Besonderheiten an der Strecke (z. B. Fehlzustände und Weichen) zeigen sich als deutlich erhöhte Schwingleistungen in Bezug auf das Geschwindigkeitsnormal.

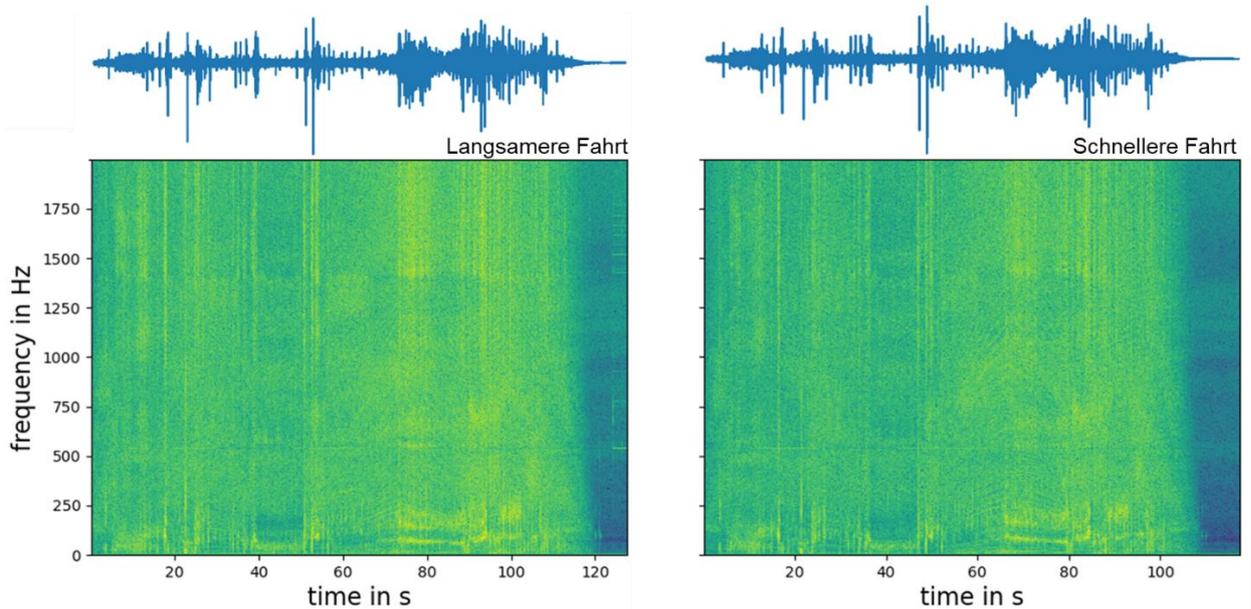


Abbildung 21. Zeit-Frequenzbereichsanalysen (Spektrogramme) für zwei Fahrten von Haltestelle Brunnenstraße zu Haltestelle Ehrhartstraße. Die Spektrogramme zeigen farbkodiert die Leistungsdichte der Achslagerbeschleunigungen bis ca. 2000 Hz (hohe Leistungsdichten gelb, niedrige blau).

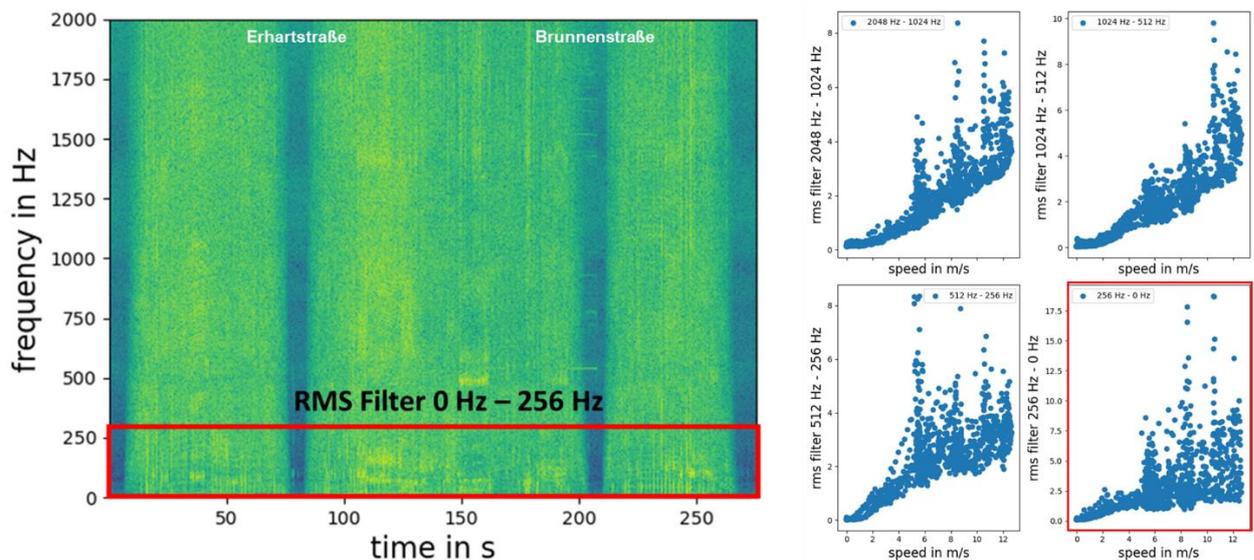


Abbildung 22. Zeit-Frequenzbereichsanalyse (links) einer Fahrt stadteinwärts von Ehrhartstraße in Richtung Brunnenstraße. Rechts: Schwingleistungen in verschiedenen Oktavbändern für kurze Streckenabschnitte (ca. 1 m) über die Fahrzeuggeschwindigkeit aufgetragen. Deutlich erkennbar ist die systematische Zunahme der Schwingleistungen mit der Fahrzeuggeschwindigkeit („Hockey-Schläger“) sowie erhöhte Schwingleistungen im Vergleich zum Geschwindigkeitsnormal aufgrund von Streckenbesonderheiten.

Ergänzend wurden die Daten mit etablierten klassischen Methoden der Signalanalyse auf bestimmte typische Fehlzustände hin ausgewertet. Die Eignung eines im IHATEC-Projekt HavenZuG ([19]) demonstrierten Verfahrens zur Erkennung von Schienenriffeln mit Achslagerbeschleunigungen einer Rangierlokomotive ([20]) konnte erfolgreich übertragen werden. Beispielhaft sind in Abbildung 23 mittels u. a. doppelter Integration, Filterung und Übertragung in den Distanzbereich abgeleiteten Schienenprofile für verschiedene Wellenlängenbereiche dargestellt. Die Wellenlängenbereiche 10-30 cm und 3-10 cm entsprechen typischen Wellenlängen von Schienenriffeln bzw. verschiedenen Formen kurzweiliger Fehlzustände der Schienenfahrfläche.

Die im Streckenabschnitt Brunnenstraße-Ehrhartstraße festgestellten Bereiche mit Abweichungen im Schienenlängsprofil (Abbildung 24 und gelbe bis grüne Abschnitte in Abbildung 23) stimmen gut mit den bei der Ortsbegehung festgestellten Riffeln im Bereich des langgestreckten Bogens sowie Squat-artigen Fehlzuständen im Bereich der Brücken überein.

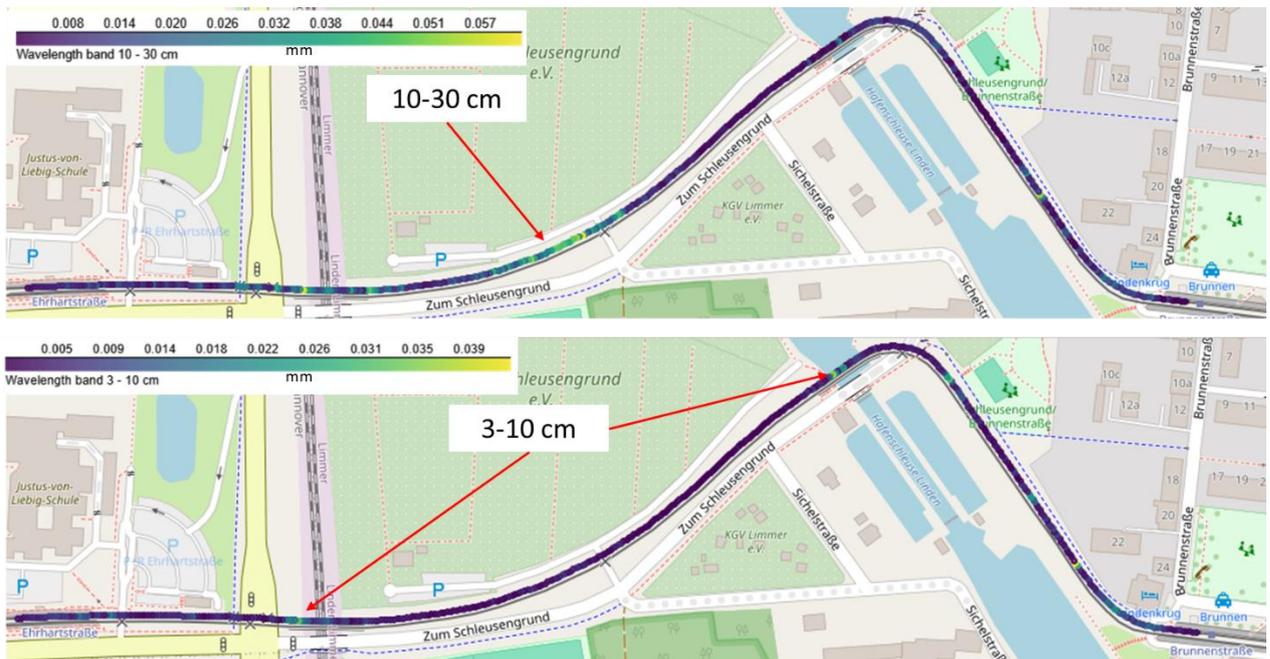


Abbildung 23. Schienenlängsprofile in den Wellenlängenbereichen 10-30 cm (oben) und 3-10 cm (unten) für den Streckenabschnitt zwischen Brunnenstraße (rechts) und Ehrhartstraße (links). Die festgestellten Abweichungen im Profil stimmen gut mit den bei der Streckenbegehung festgestellten Riffeln im Bereich des langgestreckten Bogens und Squat-artiger Fehlzustände im Bereich der Brücken überein.

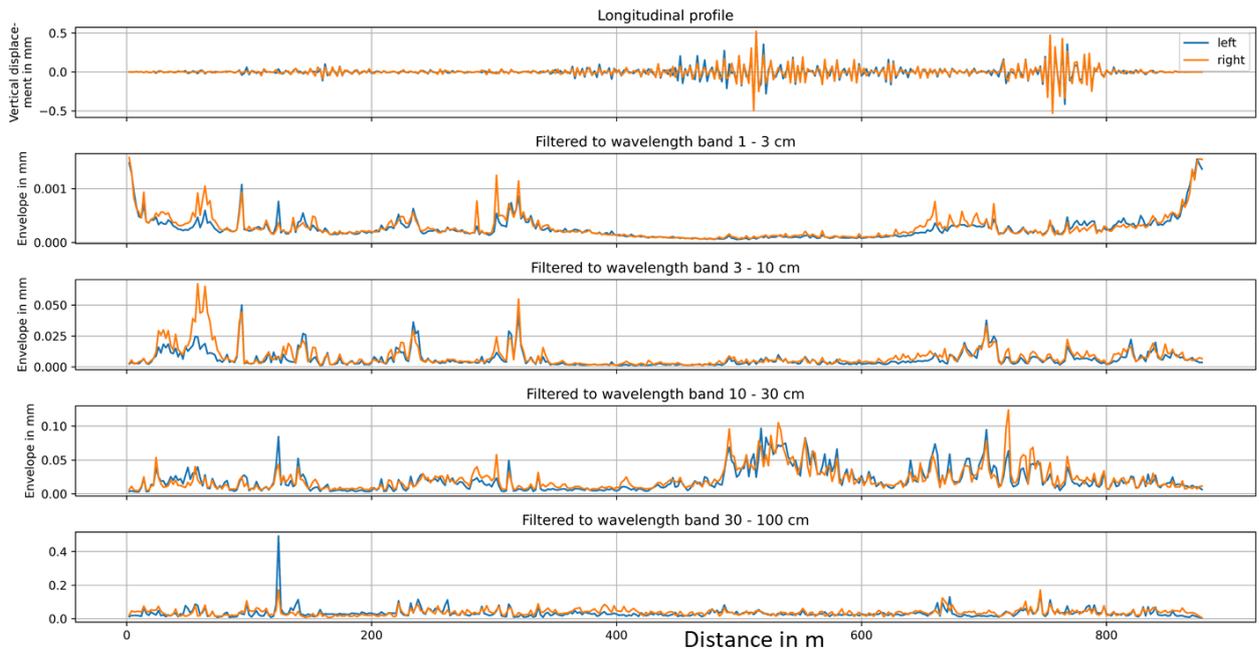


Abbildung 24. Aus den Achslagerbeschleunigungen für die linke (blau) und rechte (orange) Schiene abgeleitete Schienenlängsprofile für verschiedene Wellenlängenbereiche auf dem Streckenabschnitt Brunnenstraße – Ehrhartstraße.

2.7.6.1 Basismodelle

Anhand von Basismodellen wurden die grundlegenden Zusammenhänge der Sensordaten mit der Fahrdynamik, den örtlichen Gegebenheiten sowie der vorherrschenden Witterung in Bezug gesetzt, um den jeweiligen Einfluss zu untersuchen. Dies kann je nach verwendetem Modell die Erkennung in den maschinellen Lernverfahren verbessern, da der Einfluss dieser Effekte entsprechend kompensiert werden kann. Für den Schalldruckpegel liefern die Basismodelle weiters anschauliche Abschätzungen der genannten Einflussfaktoren.

Für die drei in Graz verkehrenden Systeme wurde ein lineares, multivariates Regressionsmodell mit den folgenden unabhängigen Variablen zur Vorhersage des mittleren Schalldruckpegels L_{Aeq} für 5m lange Abschnitte untersucht:

$$L_{Aeq} \sim \log_{10} v_{vehicle} + a + d + X + \kappa + o + b + T + R + v_{wind} + p$$

mit

$v_{vehicle}$	Geschwindigkeit der Straßenbahn in m/s,
a	Beschleunigung der Straßenbahn in m/s^2 (≥ 0),
d	Verzögerung der Straßenbahn in m/s^2 (< 0),
X	Kombinierter Faktor aus Messsystem (OnboardEU002, OnboardEU003 bzw. OnboardEU003) sowie Mikrofonseite (links, rechts),
κ	Krümmung des Gleises in $1/m$,
o	Oberbautyp (Schotter, Grünleis, Eingebettetes Gleis)
b	Blockherz im 5 Meterabschnitt vorhanden
T	Lufttemperatur in $^{\circ}C$,
R	Niederschlagsmenge in mm/h ,
p	Luftdruck in hPa .

In der folgenden Tabelle sind die Koeffizienten des zwar einfachen, aber anschaulichen Regressionsmodells, die Standardfehler und der jeweilige Effektbeitrag angegeben. Der Effektbeitrag ist der maximale Beitrag des Parameters zum Pegel, den dieser Parameter im Durchschnitt für seinen maximalen Wert im Vergleich zu seinem minimalen Wert liefert. Alle Parameter sind hoch signifikant ($p < 0,001$). Das Bestimmtheitsmaß R^2 ist 0,63. Das linke Mikrofon des OnboardEU002 Systems wird als Referenz verwendet. Dabei zeigt sich eine sehr gute Vergleichbarkeit der Systeme und der linken und rechten Mikrofonpositionen zueinander. So ist die maximale durchschnittliche Abweichung 0,6 dB, wobei auch ein Einfluss des Radzustandes sowie des Fahrzeuges zu berücksichtigen ist. Durch die geringe Abhängigkeit des Modells von den einzelnen Messsysteme, erscheint der verfolgte Ansatz der Onboard-Messung von Schalldruckpegeln an Regelfahrzeugen als durchaus geeignet, um als Eingangsparameter für die Lärmkartierung zu dienen.

<i>Parameter</i>	<i>Koeffizient</i>	<i>Standardfehler</i>	<i>Effektbeitrag (dB)</i>
<i>Intercept</i>	86,7962	0,093	-
<i>OnboardEU002 rechts</i>	-0,6047	0,003	-0,6
<i>OnboardEU003 links</i>	-0,3728	0,003	0,4
<i>OnboardEU003 rechts</i>	0,2463	0,004	0,3
<i>OnboardEU006 links</i>	-0,6213	0,003	-0,6
<i>OnboardEU006 rechts</i>	0,3825	0,004	0,4
κ	-4,2503	0,018	10,8
<i>Grüngleis</i>	-1,3091	0,005	-1,3
<i>Schottergleis</i>	-0,8034	0,003	-0,8
<i>Blockherz</i>	3,2727	0,007	3,3
$\log_{10} v_{vehicle}$	19,6901	0,003	42,8
<i>a</i>	0,0564	0,003	0,3
<i>d</i>	1,3356	0,003	6,7
<i>T</i>	-0,1078	0,000	-4,5
<i>R</i>	0,2777	0,002	3,0
<i>p</i>	-0,0145	0,000	-0,7

Der Onboard-Schalldruckpegel über einen Grün- bzw. Schottergleis sinkt im Schnitt um 1,3 dB bzw. 0,8 dB, während die Überfahrt über ein Blockherz den Pegel um 3,5 dB deutlich anhebt. Eine fahrende Straßenbahn ist bis zu 43 dB lauter als eine stehende Straßenbahn. Während Beschleunigungsvorgänge nur einen geringen Einfluss haben, können vor allem starke Bremsvorgänge deutlich erhöhte Pegel hervorrufen. In der Analyse ist zu beachten, dass Kolinearitäten zwischen den Parametern nicht berücksichtigt sind. So treten hohe Krümmungen immer nur bei niedrigen Geschwindigkeiten auf, bei denen es jedoch zu einem relativen Pegelanstieg von fast 11 dB im Vergleich zu einer geraden Strecke und allen anderen fixierten Parametern kommen kann.

In Bezug auf die vorherrschende Witterung während der Fahrt zeigt sich ein eher geringer Einfluss des statischen Luftdrucks. Die Lufttemperatur und Niederschlagsmenge zeigen hier jedoch einen relativ starken Einfluss. Mit einem Effektbeitrag von -4,5 dB für die Temperaturspanne von -8,5°C bis 33,5°C ist die Straßenbahn an heißen Tagen deutlich leiser als im Winter. Andersrum ist bei starken Niederschlägen der Schalldruckpegel deutlich höher.

Sofern absolute Schalldruckpegel in der Analyse des Gleiszustandes verwendet werden, sind daher neben der Gleisgeometrie und Fahrdynamik auch die vorherrschenden Witterungsbedingungen zu berücksichtigen.

2.7.6.2 Unüberwachte Lernverfahren

Im Rahmen des Projektes wurden verschiedene Ansätze erprobt, um mittels unüberwachter Lernverfahren aus den breitbandigen Achslagerbeschleunigungen und unter Berücksichtigung der Fahrzeuggeschwindigkeit einen eindimensionalen sogenannten Zustandsindikator zu ermitteln (siehe auch [21]). Der Zustandsindikator soll im befahrenen Netz Abschnitte mit auffälligen Fahrzeugreaktionen aufzeigen. Eine unmittelbare Korrelation des Zustandsindikators mit der „Schwere“ etwaiger Fehlzustände oder die Unterscheidung spezifischer Fehlzustände wird nicht angestrebt (siehe überwachtes Lernen). Bei gleichbleibenden Rahmenbedingungen (z. B. Betrachtung eines bestimmten Streckenabschnitts) können jedoch Veränderungen des Zustandsindikators im Zeitverlauf (Zu- oder Abnahme) entsprechende Veränderungen an der Strecke in der Regel qualitativ abbilden.

Dieser Ansatz mittels unüberwachter Lernverfahren ist in Abbildung 25 schematisch dargestellt.



Abbildung 25. Schematische Darstellung des Einsatzes unüberwachter Lernverfahren für die Zustandsüberwachung. Mittels des maschinellen Lernens erfolgt anhand der aus den Sensordaten extrahierten Merkmale sowie der Fahrzeuggeschwindigkeit die Ableitung eines eindimensionalen Zustandsindikators. Die weiterführende Auswertung der Zustandsindikatoren pro Streckenmeter und für viele Streckenbefahrungen ((Big Data) Analyse) erlaubt bei fachlicher Auswertung tiefgehende Einblicke in Zustand und Zustandsentwicklung des Netzes.

Zu Beginn erfolgt eine Aufbereitung der erhobenen Messdaten mittels digitaler Signalverarbeitung (siehe Abbildung 26 und [21]). Dieser Schritt umfasst typischerweise die Anwendung von Skalierungsfaktoren (z. B. Umrechnung in m/s^2), die Entfernung linearer Trends und des Mittelwerts aus den Zeitreihen sowie ggfs. Frequenzbereichsfilterungen.

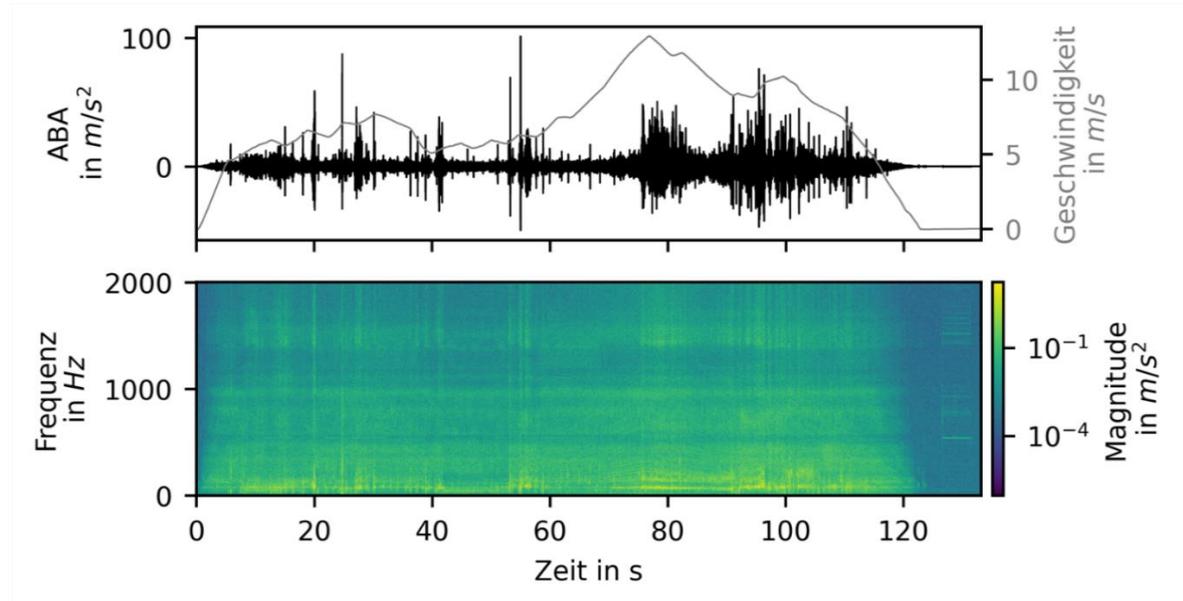


Abbildung 26. Zeitreihe der vertikalen Achslagerbeschleunigungen nach der Signalaufbereitung mit der Fahrzeuggeschwindigkeit (oben) mit entsprechender Zeit-Frequenz-Analyse als Grundlage für die Gewinnung von Zeitreihenmerkmalen (z. B. Schwingleistungen in Oktavbändern).

Nach Aufbereitung der Sensordaten werden Merkmale der Zeitreihen extrahiert (siehe Abbildung 27 und [21]).

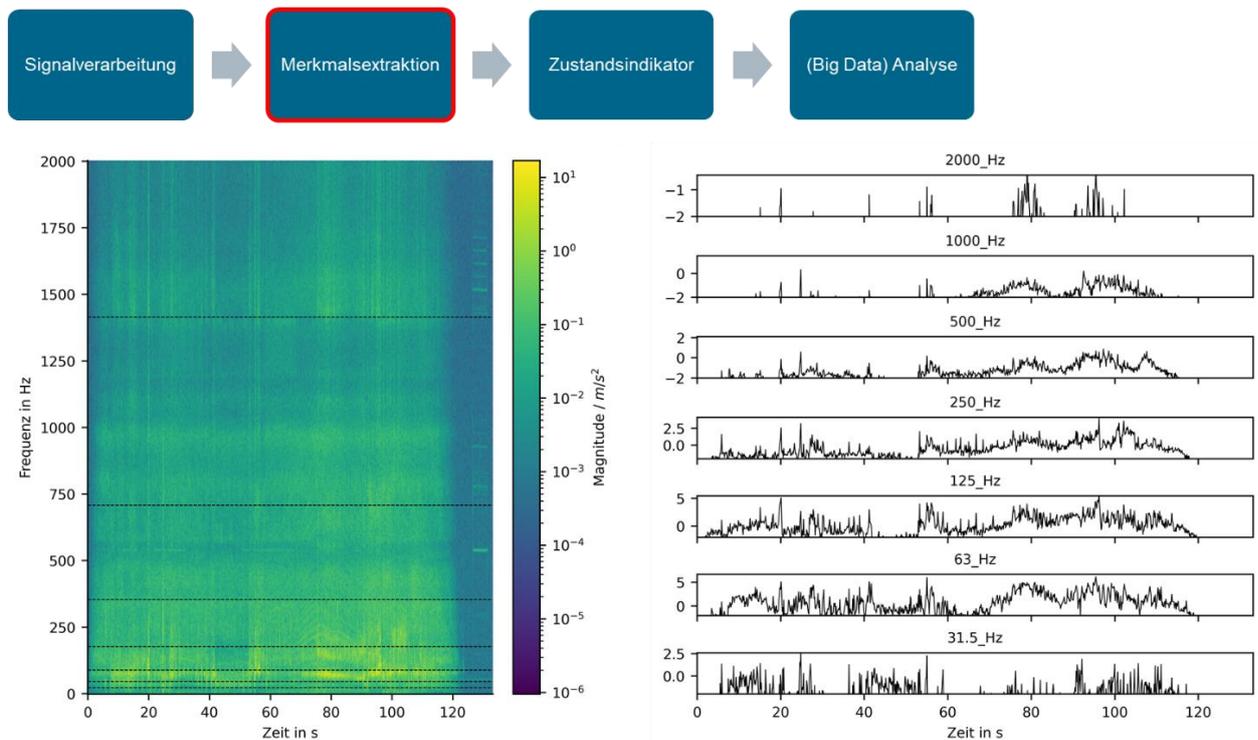


Abbildung 27. Im Frequenzbereich extrahierte Zeitreihenmerkmale (Oktavbänder) als Grundlage für das unüberwachte Lernen.

Für den Einsatz unüberwachter Lernverfahren für Achslagerbeschleunigungen haben sich spektrale Leistungsdichten in Oktav- und Terzbändern als robust und geeignet erwiesen (siehe Abbildung 22 und Abbildung 27). Möglich ist auch der Einsatz von Autoencodern für eine automatische Merkmalsextraktion (siehe [9]). Sowohl der Schritt der Signalverarbeitung als auch die Merkmalsextraktion wurden im Rahmen des Projektes nach der Übertragung auf das Datenmanagement-System landseitig durchgeführt. Zukünftig sollen beide Schritte direkt auf dem Fahrzeug erfolgen (siehe Abschnitt Edge-Computing). Hier bietet sich eine Kombination der Merkmalsextraktion mit der Datenreduktion mittels Autoencodern (z. B. sparse dictionary learning, siehe Abschnitt 2.7.7 Edge-Computing und [22]) an.

Für die Ableitung des eindimensionalen Zustandsindikators bieten sich sowohl Autoencoder-basierte Ansätze (siehe [21]) als auch verschiedene Distanzmaße wie z. B. die Mahalanobis-Distanz (siehe Abbildung 28) an. Für die praktische Anwendung ist zu Beginn eine vergleichende Berechnung der Zustandsindikatoren mit verschiedenen Ansätzen und Parametrisierungen zu empfehlen, um eine für den jeweiligen konkreten Anwendungskontext optimale Konfiguration zu bestimmen.

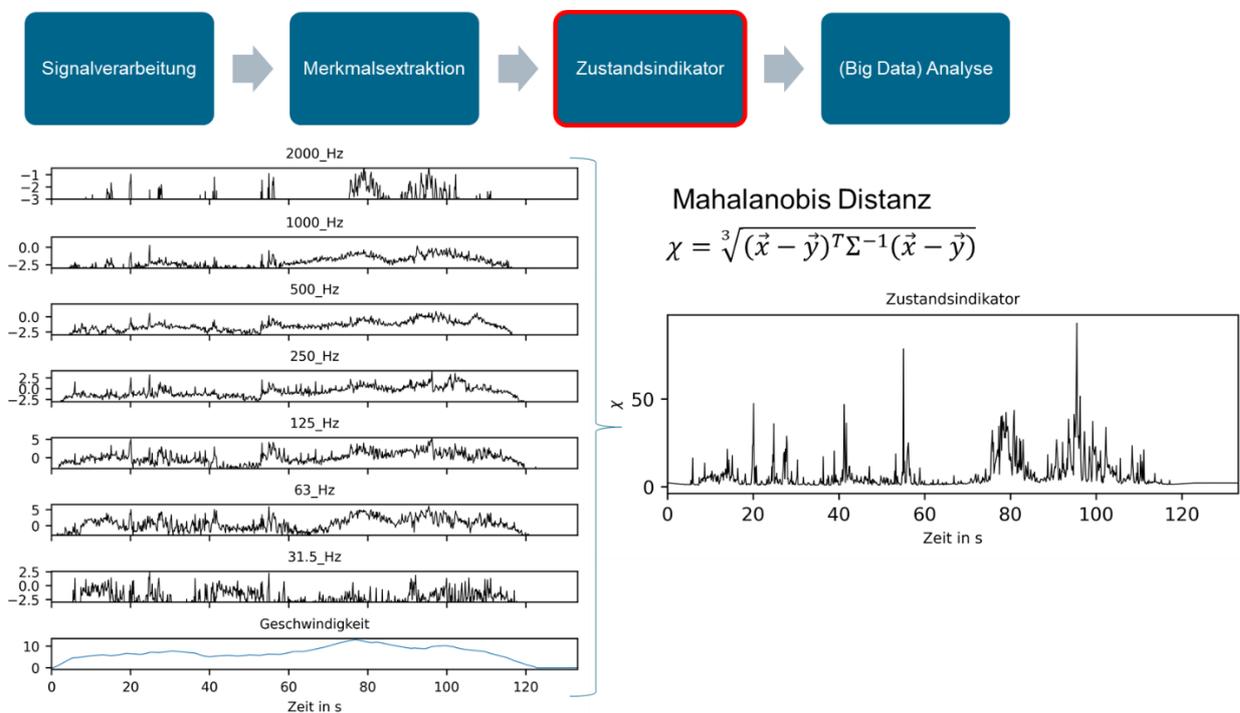


Abbildung 28. Ableitung eines eindimensionalen Zustandsindikators aus einem mehrdimensionalen Merkmalsvektor einschließlich der Fahrzeuggeschwindigkeit. Hier am Beispiel der Mahalanobis-Distanz.

Die Berechnung der Zustandsindikatoren erfolgt pro Fahrt und pro Streckenmeter aufbauend auf den Ergebnissen der Georeferenzierung. Aufgrund der zahlreichen äußeren Einflussfaktoren auf die erfassten Achslagerbeschleunigungen (z. B. aktuelle Beladung, aktueller Zustand der Räder, Witterung, Beschleunigungs- und Bremsmanöver, etc.) weisen die abgeleiteten Zustandsindikatoren pro Fahrt weiterhin eine zum Teil erhebliche Streuung auf. Diesbezüglich können die Vorteile einer kontinuierlichen Erfassung im Regelbetrieb und die daraus resultierende hohe Anzahl an Befahrungen (siehe auch Abbildung 15) genutzt werden, um Variationen des Zustandsindikators aufgrund des Streckenzustands durch Mittelung zahlreicher Überfahrten zuverlässig herauszubilden. Diesbezüglich hat sich eine tagesweise Mittelung der fahrtweise bestimmten Zustandsindikatoren als vorteilhaft erwiesen. Dies minimiert den Einfluss einzelner Überfahrten mit abweichenden Fahrzeugreaktionen. In Abbildung 29 sind beispielhaft die Zustandsindikatoren pro Tag auf zwei Strecken-

abschnitten der Linie 10 in Hannover dargestellt. Erkennbar sind verschiedene Bereiche mit erhöhten Zustandsindikatoren, die sich über den gesamten Zeitraum oder längere Phasen wiederholt beobachten lassen und Hinweise auf mögliche Fehlzustände oder andere fahrdynamisch relevante Besonderheiten entlang der Strecke geben. Die Tageswerte der Zustandsindikatoren pro Streckenmeter im Netz sowie über längere Zeiträume bilden somit die Grundlage für darauf aufsetzende Analysen zum Zustand der Gleisinfrastruktur und zur Zustandsentwicklung durch Anlagenverantwortliche.

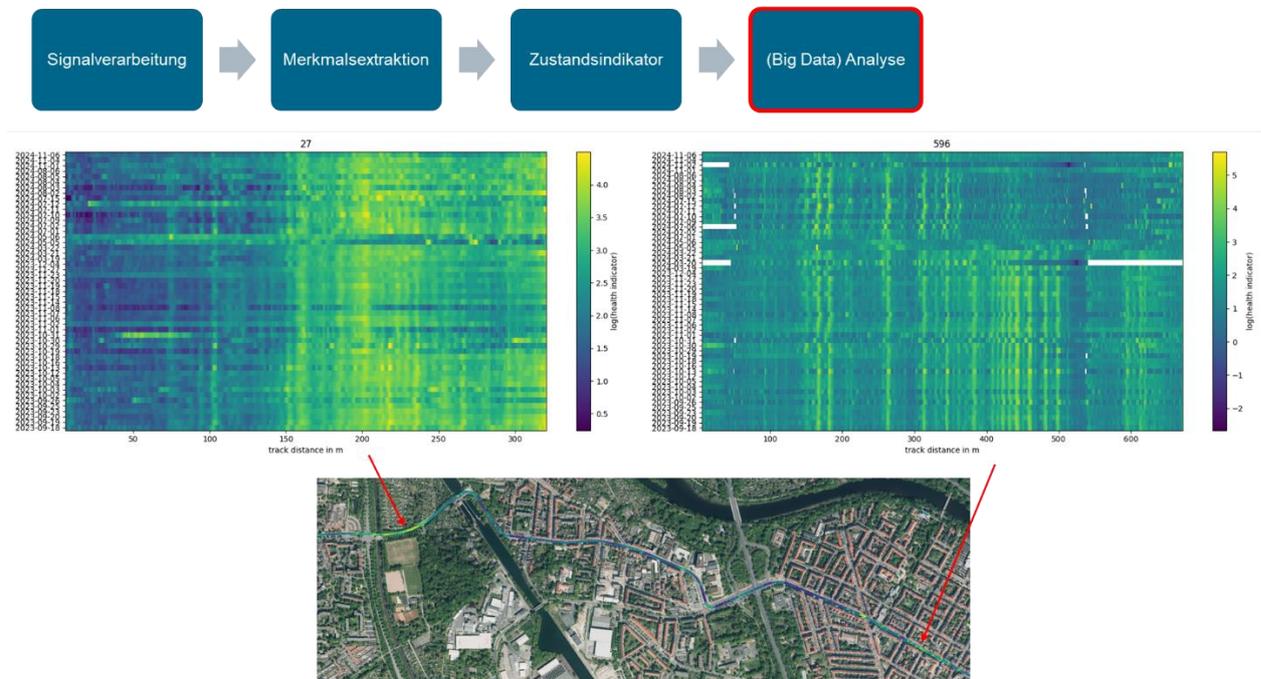


Abbildung 29. Darstellung von tageweise gemittelten Zustandsindikatoren für zwei Streckenabschnitte der Linie 10 in Hannover. In beiden Fällen bilden sich räumlich Bereiche erhöhter Zustandsindikatoren (gelb). Dies weist auf fahrdynamisch relevante Fehlzustände und anderweitige Besonderheiten entlang der Strecke hin. Links: Erhöhte Zustandsindikatoren im Bereich eines verirrten Bogens. Rechts: Räumlich eng begrenzte fahrdynamische Auffälligkeiten.

In Abbildung 30 ist der mittlere monatliche Zustandsindikator entlang Linie 10 in Hannover mit einer räumlichen Auflösung von einem Meter für September 2023 (oben) und November 2024 (unten) im Vergleich dargestellt. Sichtbar werden weitgehend übliche Fahrzeugreaktionen (dunkle Farben) mit stellenweise auffälligen Fahrzeugreaktionen (grüne bis gelbe Farben) mit einem über den betrachteten Zeitraum von 14 Monaten weitgehend stabilem räumlichen Muster. Auffällige Fahrzeugreaktionen sind nicht ausschließlich mit Fehlzuständen verbunden, sondern können auch an Weichen oder anderen besonderen baulichen Eigenschaften der Strecke (z. B. sehr enge Kurven) auftreten. Aufgrund der Wechselwirkungen und gegenseitigen Verstärkung zwischen Fehlzuständen und ausgeprägten Fahrzeugreaktionen bieten sich Bereiche mit erhöhten Zustandsindikatoren für zielgerichtete Inspektionen an.

In Abbildung 31 sind die mittleren monatlichen Zustandsindikatoren aus Abbildung 30 im der Bereich Brunnenstraße und Ehrhartstraße dargestellt. Fahrdynamisch relevante Fehlzustände wie Riffel und Squat-artige Fehlzustände der Schienenfahrfläche bilden sich wie erwartet mit erhöhten Zustandsindikatoren ab (siehe Abbildung 32 und vergleiche Abbildung 23).

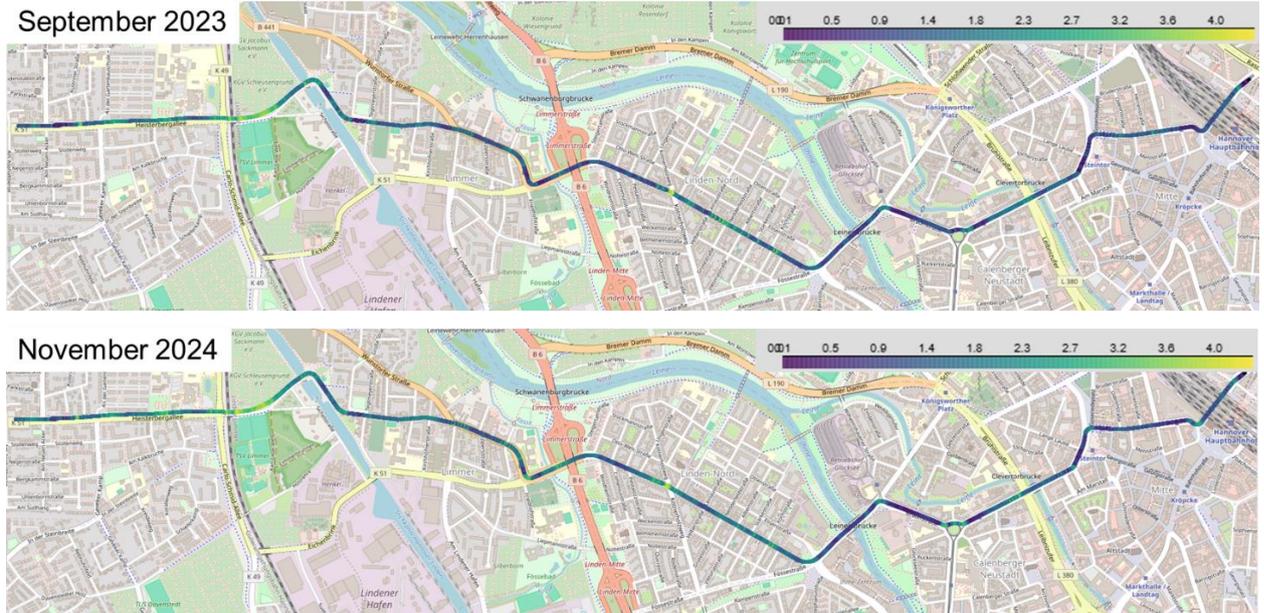


Abbildung 30. Mittlere monatliche Zustandsindikatoren der Linie 10 (stadtauswärts) in Hannover. Oben: September 2023. Unten: November 2024.

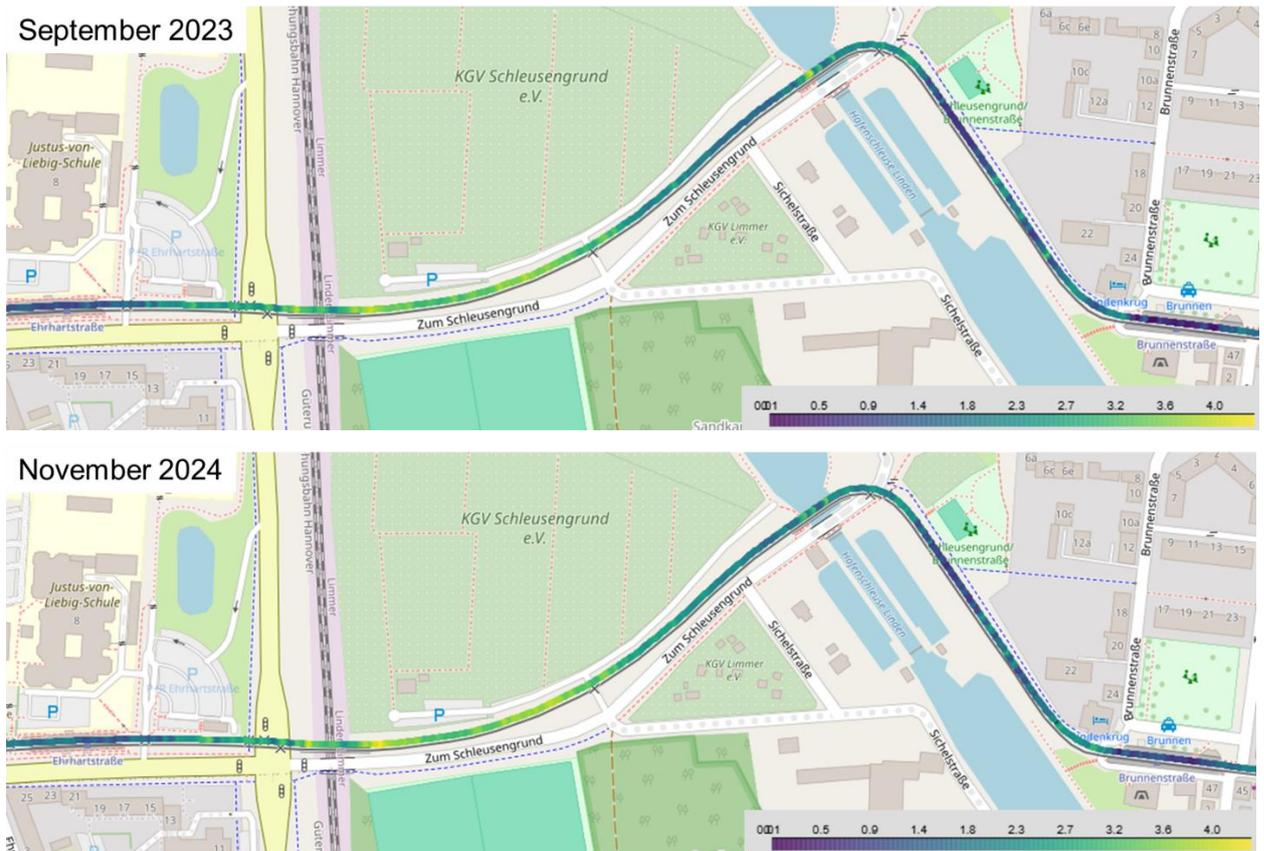


Abbildung 31. Mittlere monatlichen Zustandsindikatoren aus Abbildung 28 im der Bereich Brunnenstraße und Ehrhartstraße. Oben: September 2023 Unten: November 2024. Erhöhte Zustandsindikatoren im Bereich des verirrerten Bogens sowie im Bereich der Brücken.

Schlussbericht mFUND OnboardEU

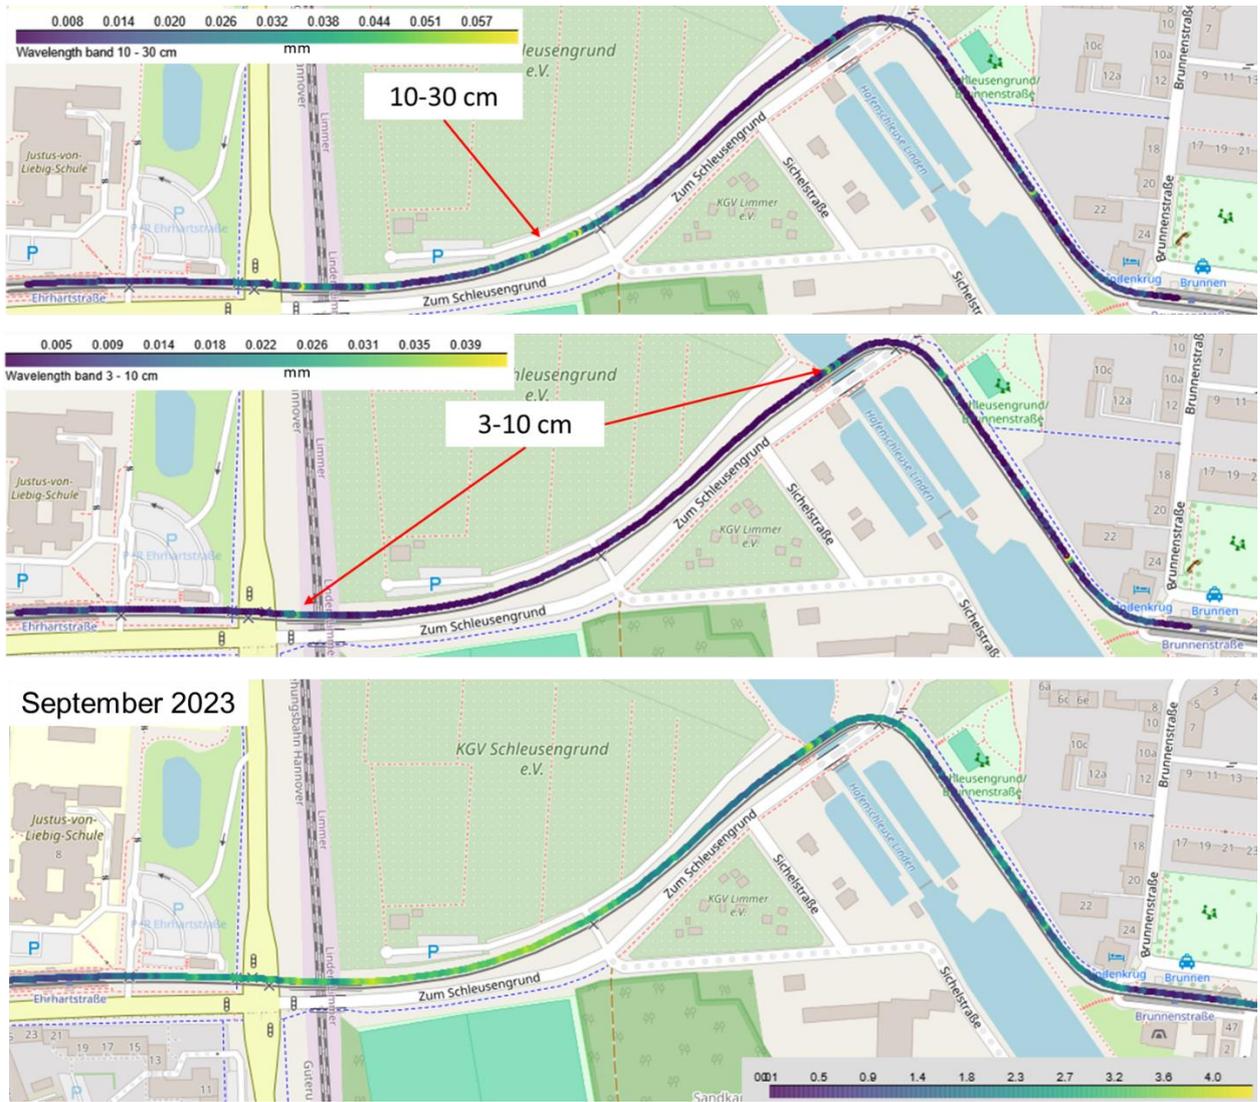


Abbildung 32. Vergleich der Zustandsindikatoren (Unten) aus September 2023 mit den aus den Achslagerbeschleunigungen abgeleiteten Schienelängsprofilen in den Wellenlängenbereichen 10-30 cm (Oben) und 3-10 cm (Mitte).

2.7.6.3 Überwachte Lernverfahren

Verfahren des überwachten Lernens (von „supervised learning“) benutzen annotierte Datensätze in denen den gesammelten Daten ein Zielwert (z. B. ein bestimmter Zustand oder ein bestimmter Zustandswert) zugeordnet ist. Anschließend wird eine Funktion gesucht, welche in der Lage ist, zu jedem Inputdatenpunkt die korrekte Zustandszuschreibung zu liefern. Es handelt sich dabei im Grunde um eine klassische Modellkalibration aus empirischen Daten mit bekanntem Zielwert. Die Modelle können dabei sehr vielfältig und durchaus komplex sein (z. B. künstliche neuronale Netze). Der Schritt der Modellkalibration wird in diesem Kontext als „Training“ des Modells bezeichnet.

In dem Projekt OnboardEU war das Vorliegen von Gleisschäden (Riffel, Schlupfwellen, Schienenkopfausbruch, Schienenkopfabnutzung) ausschlaggebend für die Annotation der Daten zu einem bestimmten Zielwert. Die Aufgabe der Methodik des überwachten Lernens war folglich, einem Datensatz aus Umweltparametern (Wetterdaten, Netzgeometrie) und spezifischer Onboard-Sensorik (Beschleunigungssensoren „Acc“, Mikrophone zur akustischen Datenaufnahme und GPS-Verortung) anhand von annotierten Daten aus einer Begehung des Gleisnetzes einen Zustand zuzuordnen (z. B. Gutes Gleis, Riffel, Schlupfwellen, Schienenkopfabnutzung). Eine schematische Darstellung dieser Zuordnungsaufgabe findet sich in Abbildung 32 unten. Ein Modell, dass auf eine solche Zuordnungsaufgabe hin gebaut und trainiert ist, wird als „Klassifikationsmodell“ bezeichnet und kann neuen Datensätzen aus den genannten Parametern einen Zielwert zuordnen. Im Falle des Projektes OnboardEU handelte es sich bei dem Modell um ein künstliches neuronales Netz.

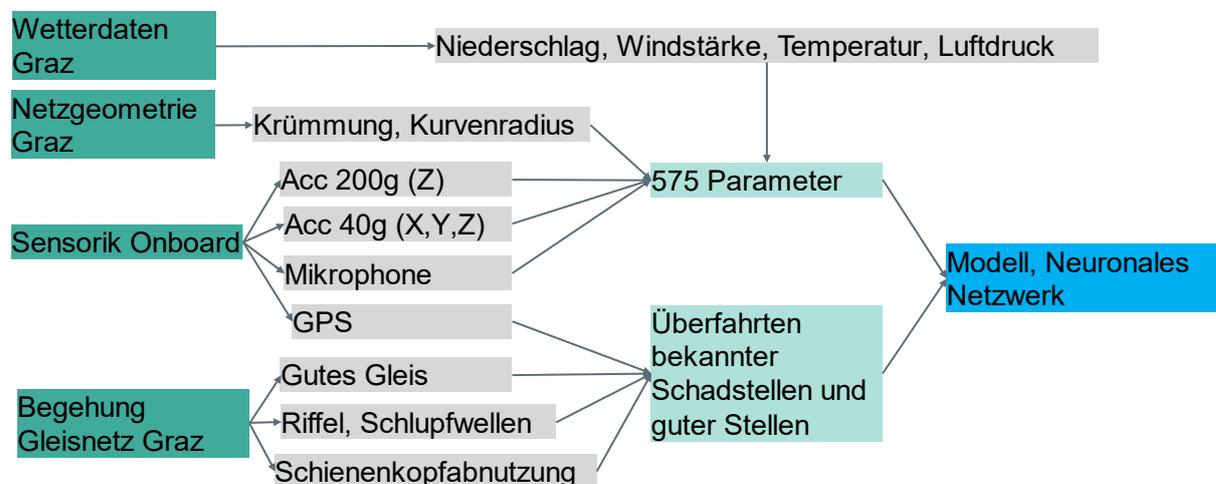


Abbildung 33. Hier sind die Quellen der Eingangsdaten und Klassifikationen (Grüne Boxen, am linken Rand), die Daten selbst (Graue Boxen mit Pfeilen direkt aus den Datenquellen folgend), die Anwendung der Parameter und die Art der Anwendungsdaten (hellgrüne Boxen), sowie die Art des verwendeten Modells (blaue Box, rechter Rand) dargestellt.

Basis für all dies waren die Referenzdaten (Ground Truth) der Netzbegehung und Einmessung von Fehlstellen vor Ort. Ein relevanter Schadenskatalog wurde mit den Netzbetreibern erstellt. Der Fokus lag dabei auf Schienenbrüchen, Head Checks, Riffel, Kurvenkreischen und Überwalzung sowie Schienenkopfverschleiß.

Für die Modellierung wurden als Ausgangspunkt die Messdaten der Onboard-Systeme und die Geodatenbank des Grazer Schienennetzes, sowie Daten einer Wetterstation in Graz und Schadensklassifikationen aus einer Begehung des Netzes verwendet. Das Grazer Schienennetz war mit dem höchsten Detailgrad vorhanden (detaillierte Daten wurden als Geodatabase durch die Netzbetreiber zur Verfügung gestellt, 2 Begehungen des Schienennetzes waren im Rahmen des Projektes möglich), wodurch sie sich als Ausgangspunkt besonders eigneten. Im Folgenden wurden die Arbeiten zum überwachten Lernen anhand der Grazer Daten durchgeführt.

Ein zentraler Schritt um die große von den Onboard-Systemen generierte Datenmenge handhabbar zu machen und ebenso um örtliche Vergleichbarkeit herzustellen, war die Zusammenfassung von Daten in 5 Meter Abschnitte („bins“). Alle Messdaten, die innerhalb eines gegebenen solchen Abschnittes erfasst wurde, wurden mit einer Überfahrts-id versehen und gewissen Standardoperationen unterzogen (Mittelwertbildung, Standardabweichung, Fouriertransformation), um eine handhabbare Datenmenge zu erhalten. Zur Illustration sind die Abschnitte eines Ausschnittes des Grazer Netzes in Abbildung 34 dargestellt.

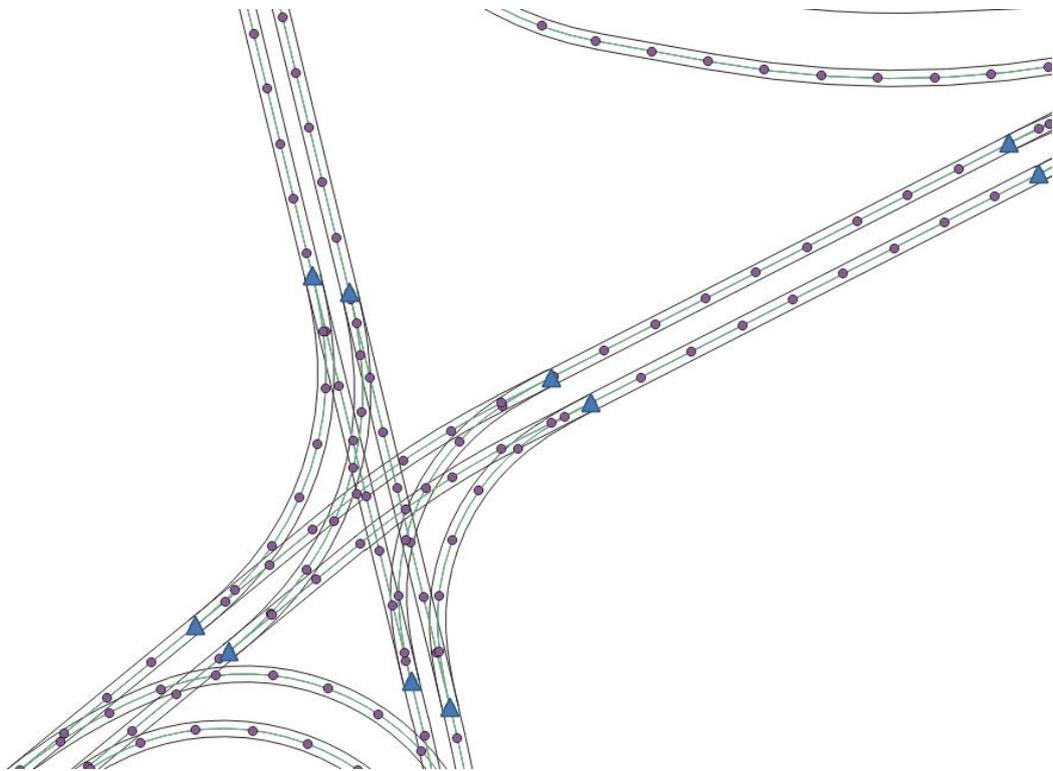


Abbildung 34. Ausschnitt des Grazer Schienennetzes auf dem die 5 Meter Abschnitte/„bin“ als violette Punkte dargestellt sind (die Punkte zeigen den Mittelpunkt eines 5 Meter Abschnittes an). Zusätzlich sind die Positionen von Weichen als blaue Dreiecke dargestellt. Die Datengrundlage des Schienennetzes wurde von der Holding Graz – Kommunale Dienstleistungen GmbH erhalten.

Als Ergebnis dieser Arbeiten konnte anschließend ein künstliches neuronales Netz darauf trainiert werden, für neue Eingangsdaten den Gleiszustand zuzuordnen (siehe Abbildung 35). Dabei wurden die Gleiszustände vorerst reduziert auf die Gruppen „Gutes Gleis“, „Riffel“, „Schienenkopfschäden“, da es für diese Gruppen die meisten Referenzpunkte gab. Das trainierte Modell kann anschließend Überfahrtsdaten in die gelernten Gruppen einteilen. Zum Zweck des Trainings wurden die annotierten Ausgangsdaten in 3 Gruppen unterteilt: Die Trainingsdaten auf denen das Modell die Zuordnung Eingangsdaten in die 3 Gruppen lernt. Die Validierungsdaten die während des Trainings eine gewisse Übertragbarkeit der Modellergebnisse sicherstellen sollen. Und schließlich die Testdaten auf denen Modell abschließend evaluiert wurde.

Für die Trainingsdaten wurden 10% der „Gutes Gleis“ Daten, 60% der Riffelstellen und 60% der Schienenkopfschadenstellen herangezogen. Für die Validierungsdaten wurden 50% der „Gutes Gleis“ Daten, 20% der Riffelstellen und 20% der Schienenkopfschadenstellen herangezogen. Für die Testdaten wurden 40% der „Gutes Gleis“ Daten, 20% der Riffelstellen und 20% der Schienenkopfschadenstellen herangezogen.

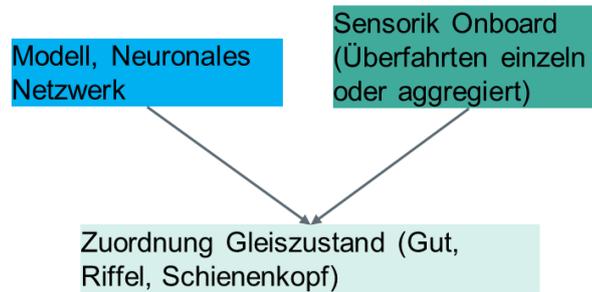


Abbildung 35. Schematisch die Nutzung eines künstlichen neuronalen Netzes nach dem Training.

Die Klassifikationsqualität auf dem gesamten Netz ergibt sich wie in Abbildung 36 ersichtlich. Schadenfreie Stellen wurden zu mehr als 90% wiedererkannt, Riffel zu 81% und Schienenkopfschadenstellen zu 90%. Die Klassifikation ist damit durchaus gewinnbringend möglich, jedoch gibt es noch einen beträchtlichen Teil an fälschlich als schadhaft klassifizierten Stellen („false positives“).

5-Meter-Bins im Netz	Klassifiziert als schadensfrei	Klassifiziert als Riffel, Schlupfwellen	Klassifiziert als Schienenkopfschaden
Original Schadensfrei	92,15%	7,6%	0,25%
Original Riffel, Schlupfwellen	16%	81%	3%
Original Schienenkopfschaden	10%	0%	90%

Abbildung 36. Ergebnisse der Klassifikation von Schadensstellen auf dem ganzen Grazer Netz (Zeilen ursprüngliche Kategorie, Spalten geschätzte Kategorie in Prozent). Die Diagonale dieser Matrix gibt die korrekten Klassifikationen in der jeweiligen Klasse an. Diese Art der Matrix bezeichnet man als „Konfusionsmatrix“.

Im Projekt OnboardEU wurde als spezifischer Verbesserungsansatz ein weiteres künstliches neuronales Netz erstellt, welches die Eigenschaften des Oberbaus in 3 Kategorien („Eingebettet“, „Schottergleis“, „Grüngleis“) als Zielwert klassifizierte, basierend auf denselben Eingangsdaten wie das ursprüngliche Schadensmodell. Hintergrund dieses Bemühens um ein derartiges Vorhersagemodell des Oberbaus war, dass dieser deutlich die akustischen und dynamischen Eingangsdaten beeinflusst und eine Berücksichtigung die Trennschärfe zwischen Gleisschäden und schadensfreiem Gleis erhöhen sollte. Ziel war somit, den Oberbautyp vorhersagen zu können, um ihn anschließend als Eingangsparameter in ein erweitertes Schadensklassifikationsmodell einfließen lassen zu können. Während für das Grazer Gleisnetz eine entsprechende Klassifikation zur Verfügung stand, sollte mit diesem Oberbaumodell auch ein einfacher Weg bereitstehen, um ohne eine solche vorherige Annotation den Oberbautyp in anderen Städten als Eingangsparameter in ein Schadensmodell nutzen zu können.

Für die Trainingsdaten wurden 10% der „eingebettetes Gleis“ Daten, 60% der Schottergleisstellen und 60% der Grüngleisstellen herangezogen. Für die Validierungsdaten wurden 50% der „eingebettetes Gleis“ Daten, 20% der Schottergleisstellen und 20% der Grüngleisstellen herangezogen. Für

die Testdaten wurden 40% der „eingebettetes Gleis“ Daten, 20% der Schottergleisstellen und 20% der Grüngleisstellen herangezogen.

Das Ergebnis der Klassifikation auf dem gesamten Netz ist in Abbildung 37 ersichtlich. Der Oberbautyp kann noch etwas verlässlicher klassifiziert werden als die Schadenstypen, was wohl auch an dem eher flächig verfügbaren Trainingsmaterial liegen mag.

5-Meter-Bins im Netz	Klassifiziert als Eingebettet	Klassifiziert als Schottergleis	Klassifiziert als Grüngleis
Original Eingebettet	98,4%	1,4%	0,2%
Original Schottergleis	18%	82%	0%
Original Grüngleis	4,6%	0%	95,6%

Abbildung 37. Die „Konfusionsmatrix“ stellt die Anteile der verschiedenen Klassenzuordnungen (Zeilen: ursprüngliche Kategorie, Spalten: geschätzte Kategorie) als Prozentzahlen dar. Die Diagonale gibt die korrekt zugeordneten „bins“ wieder.

Die Klassifikation von Grüngleis funktioniert sehr robust. In Abbildung 38 sind einige Klassifikationsergebnisse an konkreten Orten im Grazer Netz dargestellt. Man beachte die Klassifikation in der linken Abbildung. In der Tat befanden sich in der dort abgebildeten Kurve auf beiden Fahrtrichtungen Grüngleis, auch wenn es ursprünglich im Testdatensatz nur einseitig annotiert war. Das Modell ergänzte hier korrekt. Auch die rechte Abbildung bietet einen interessanten Einblick, da hier im nördlichen Gleisverlauf zwar kein Grüngleis annotiert war, jedoch ein bereiter Grünsteifen sehr nahe an die Einbettung herankommt, was die Klassifikation als Grüngleis möglicherweise beeinflusst hat.



Abbildung 38. Vergleich von als Grüngleis klassifizierten Stellen (orangene Rechtecke) und Grüngleis in den Trainingsdaten (grüne Punkte) an zwei Streckenabschnitten in Graz. Quelle ist ein Orthophoto erhalten von geodaten.graz.at.

Auch bei Schottergleis gelingt die Verortung verlässlich, wie Abbildung 39 zeigt.

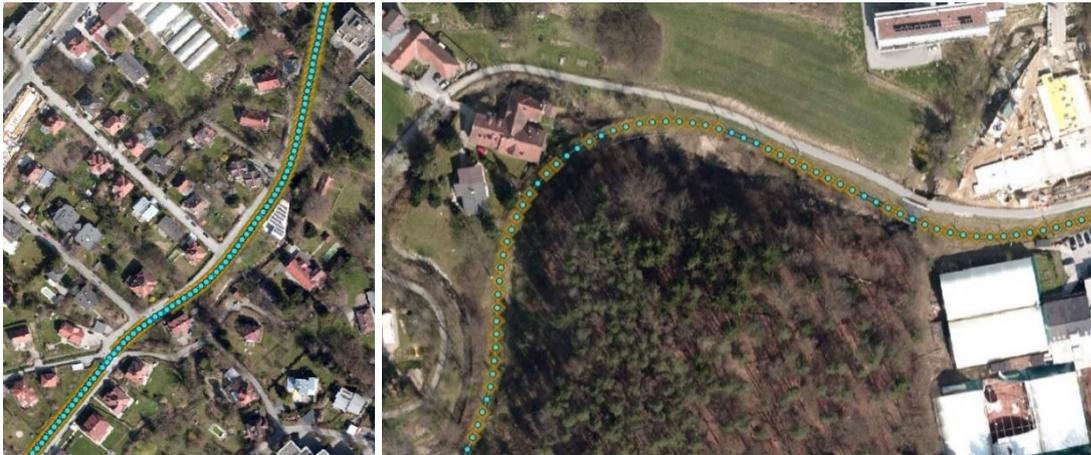


Abbildung 39. Hier sieht man einen Vergleich von als Schottergleis klassifizierten Stellen (orangene Rechtecke) und Schottergleis in den Trainingsdaten (blaue Punkte) an zwei Streckenabschnitten in Graz. Quelle ist ein Orthophoto erhalten von geodaten.graz.at.

Abschließend lässt sich sagen, dass sowohl für die Klassifikation von Schadensstellen als auch für die Klassifikation des Oberbautypes Methoden des überwachten Lernens aussichtsreiche Kandidaten sind, um eine Detektion rein aus Überfahrtsdaten zu ermöglichen. Die weitere Optimierung der gezeigten Beispiele ist ein längerer Prozess, der über das Projektende hinausgeht, da es viele Optimierungsparameter gibt (tiefe der verwendeten künstlichen neuronalen Netze, Qualität der Trainingsdaten). Die Klassifikationssicherheit auf den Grazer Daten stimmt hierbei optimistisch und zeigt klares Potential der Onboard-Sensorik und darauf aufbauender Methodiken auf.

2.7.6.4 Lärmkartierung

In der klassischen Lärmkartierung werden anhand des vorhandenen Rollmaterials, der Eigenschaften des Gleises, der Befahrungsstärke sowie der Ausbreitungsbedingungen die Lärmimmissionspegel berechnet. Mit einer flächendeckenden akustischen Überwachung mit den im Rahmen des Projekts entwickelten und verwendeten vibroakustischen Sensoren ist es möglich, den aktuellen akustischen Gleiszustand zu bewerten. Dies ermöglicht eine detaillierte Analyse des durch den Straßenbahnverkehr erzeugten Lärm. Zu diesem Zweck werden die Onboard-Pegel mit den Vorbeifahrtspegeln der Pass-by-Messungen verglichen. Abbildung 40 zeigt die energieäquivalenten Dauerschallpegel aller aufgenommenen Vorbeifahrten. Die Onboard-Pegel wurden anhand eines Zeitfensters mit einer Länge von 30 m um dem Vorbeifahrtmesspunkt berechnet. Die Vorbeifahrtspegel sind durch den größeren Abstand sowie den Wagenaufbau (Abschattung) geringer, wobei eine langsamere Vorbeifahrt in beiden Pegeln deutlich geringer ist. In der Abbildung sind konstante Pegeldifferenzen als schwarz strichlierte Linien eingezeichnet, wobei sich die Pegel für ähnliche örtliche Gegebenheiten anhand dieser konstanten Pegeldifferenzen orientieren. So ist für eine dichte Bebauung die absolute Pegeldifferenz geringer, da der Vorbeifahrtspegel durch Mehrfachreflexionen an Gebäuden erhöht wird. Auf der anderen Seite ist die absolute Pegeldifferenz für eine Schottergleis im Freifeld im Vergleich größer. Ein relativ gesehen geringerer Vorbeifahrtspegel erscheint durch zusätzliche Schallabsorption des Gleisschotters plausibel.

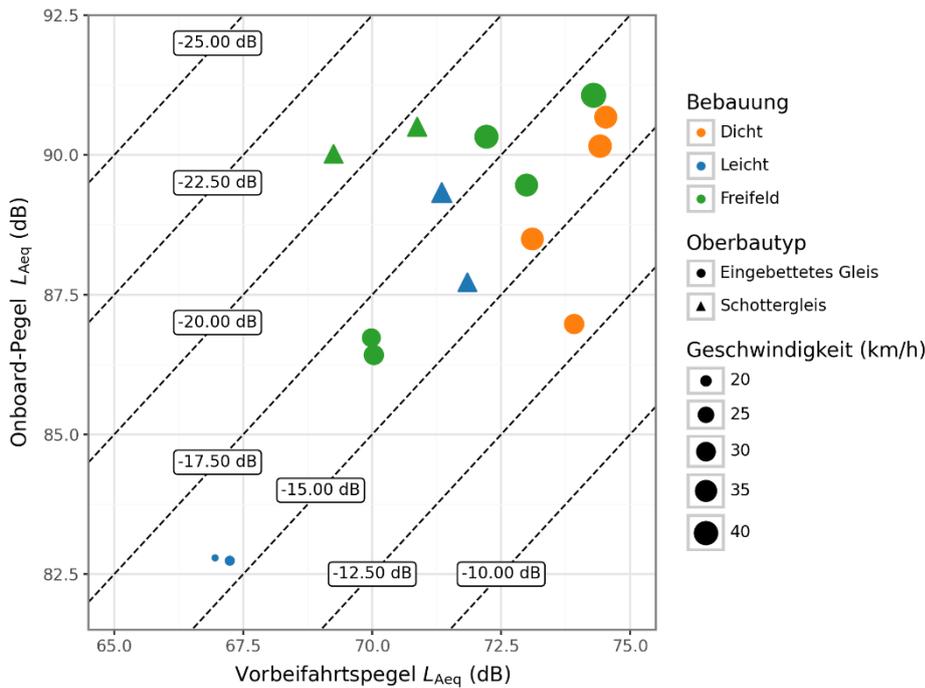


Abbildung 40. Energieäquivalente Dauerschallpegel der Vorbeifahrten als am Fahrzeug aufgenommener Onboard- und extern aufgenommener Vorbeifahrtspegel.

Abbildung 41 zeigt diese gemittelten Pegeldifferenzen als Transferspektren sowohl als Gesamtpegel als auch in Oktavbändern. In Oktavbändern zeigt sich für die eingebetteten Gleise ein ähnlicher Verlauf, wobei eine leichte Bebauung ähnlich Freifeldbedingungen entspricht und eine dichte Bebauung eine konstante Erhöhung des Vorbeifahrtspegels von ca. 2 dB verursacht. Zwei Messstellen waren in einem Gleisbogen und zeigen in den Oktavbändern bei 4 kHz und 8 kHz ebenso einen erhöhten Vorbeifahrtspegel.

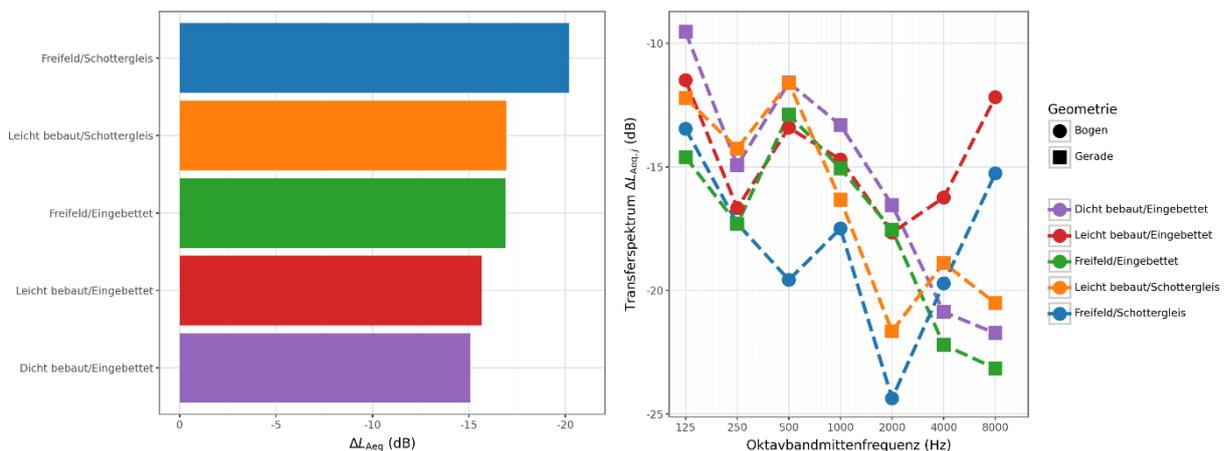


Abbildung 41. Transferspektren als gemittelte Pegeldifferenzen zwischen Vorbeifahrts- und Onboardpegel breitbandig (links) und in Oktavbändern (rechts).

Im Rahmen des Projekts konnten zwei wesentliche Aspekte erforscht werden, um eine auf Onboardpegeln basierte Lärmkartierung zu ermöglichen:

1. Anhand der in Abschnitt 2.7.6.1 analysierten Basismodelle ist neben der Gleisgeometrie und der Fahrdynamik auch das vorherrschende Wetter ein relevanter Einflussparameter in der Bewertung des durch eine Straßenbahn hervorgerufenen Schalldruckpegels.
2. Die drei instrumentierten Regelfahrzeuge sind sowohl an den auftretenden Onboard-Schalldruckpegel als auch an den Vorbeifahrtspegeln vergleichbar, wobei sich im Bezug auf die örtlichen Gegebenheiten sinnvolle Transferspektren lassen.

Somit erscheint eine auf Onboardpegeln basierte Lärmkartierung möglich. Über dieses Projekt weiterführende Forschung beinhaltet die genaue Umrechnung des Onboardschalldruckpegels auf einen für die Lärmkartierung typischerweise gebrauchten Schallleistungspegels sowie eine Evaluierung mit rein rechnerisch erstellten Lärmkarten.

2.7.7 Edge-Computing

Schwerpunkt der Arbeiten zum Edge-Computing war die Untersuchung von Ansätzen zur Reduktion der zu übertragenden Datenmengen. Hierzu wurden im Rahmen von Arbeitspaket 5.5 „Edge-Computing“ Algorithmen untersucht, die auf den Basiseinheiten der Systeme laufen können. Es wurden zwei miteinander kombinierbare Ansätze untersucht. Der grundlegende Ansatz ist die Beschränkung der zu übertragenden Messdaten auf Streckenbereiche mit auffälligen Fahrzeugreaktionen. Der gewählte Ansatz wird in Abbildung 42 erläutert. Die zwischen zwei Haltepunkten des Fahrzeuges erfassten Daten (siehe Triggerung, Abschnitt 2.7.1) werden mittels Edge-Computing sofort nach Ablage der Einzelfahrten vom System auf dem Fahrzeug vergleichbar zum unüberwachten Lernen (siehe Abschnitt 2.7.6.2) automatisiert analysiert. Die Analyse beruht auf ebenfalls für das maschinelle Lernen verwendeten Merkmalen. Insbesondere werden pro Fahrt Schwingungsleistungen in verschiedenen Frequenzbereichen berechnet, siehe Abbildung 43.

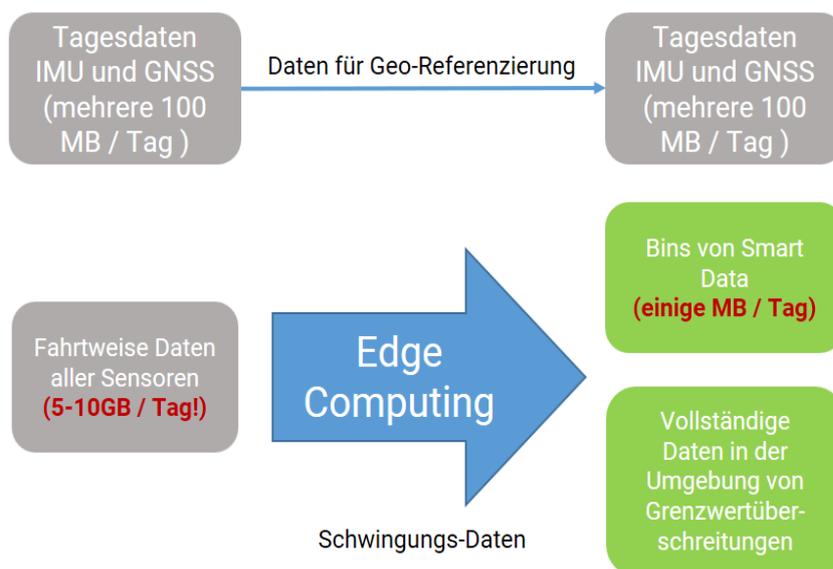


Abbildung 42. Die für die gleisgenaue Georeferenzierung erforderlichen Daten von Inertialmesseinheit (IMU) und Satellitennavigation (GNSS) können in vollem Umfang übertragen werden. Die hochfrequenten Messdaten der übrigen Sensoren werden mittels Edge-Computing erheblich reduziert. Für Streckenabschnitte mit auffälligen Fahrzeugverhalten werden die Messdaten für spätere detaillierte Analysen vollständig gespeichert und übertragen.

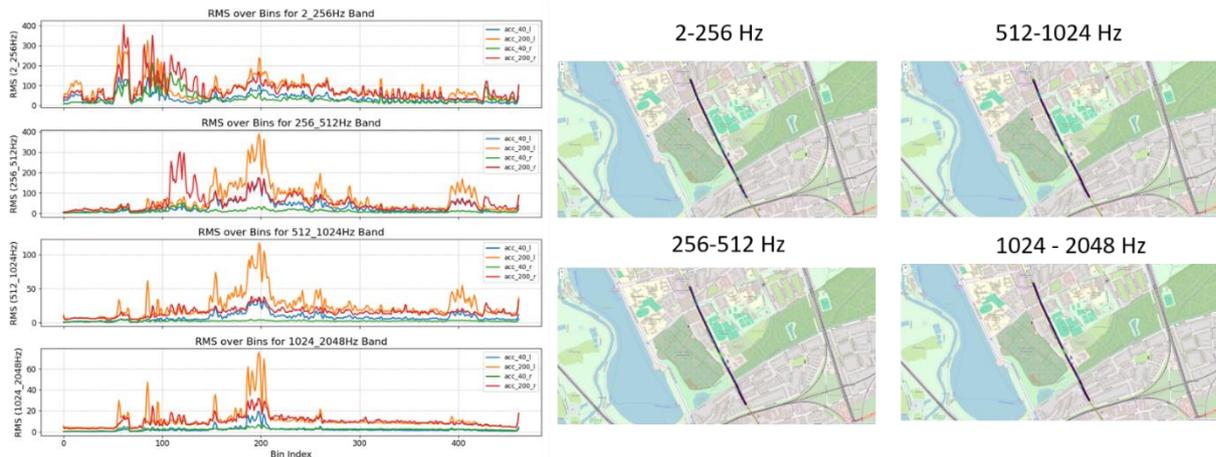


Abbildung 43. Schwingleistungen in verschiedenen Frequenzbereichen entlang eines Streckenabschnitts als Grundlage für die Auswahl von zu übertragenden Messdaten auf dem Fahrzeug.

Treten Überschreitungen von zuvor anhand des unüberwachten Lernens abgeleiteten Grenzwerten auf, werden die Daten vollständig für den betroffenen Bereich sowie jeweils fünf Meter davor und danach übertragen. Die gleisgenaue Georeferenzierung kann im Nachhinein anhand der vollständig übertragenen IMU und GNSS-Daten durchgeführt werden. Die Messdaten aus unkritischen Bereichen werden verworfen bzw. können zukünftig einer Datenkompression unterzogen werden.

Der zweite im Projekt untersuchte Ansatz (siehe Preprint [22]) umfasst eine entsprechende, im Sinne der weiterführenden Analysen möglichst verlustfreie Datenreduktion. Der Ansatz basiert auf „dünn besetzter Kodierung“ (Sparse Coding, [23–25]) im Zeit-/Frequenzbereich durch die Kombination einer Kurzzeit-Fourier-Transformation der Sensormessdaten (Short-Time-Fourier-Transform, STFT) mit Sparse Dictionary Learning ([26, 27]). Das Sparse Coding im Frequenzbereich hat die gleichen Eigenschaften wie im Zeitbereich, ist aber rechnerisch weniger komplex. Es existieren skalierbare, effiziente Algorithmen, die in Echtzeit implementiert und auf den Onboard-Einheiten ausgeführt werden können. Durch das Dictionary Learning entsteht eine adaptive reduzierte Darstellung der vibroakustischen Eingangsdaten, die deren für die weiteren Auswertungen relevanten Frequenzcharakteristika trotz erheblicher Datenreduktion erhält. Die experimentellen Auswertungen haben gezeigt ([22]), dass durch die Auswahl eines geeigneten Regularisierungsparameters eine Kompressionsrate von 63 ohne Verlust relevanter Informationen im Sinne der nachgelagerten Analysen erreicht werden kann. Die ursprünglichen Daten können dabei im Nachhinein anhand des Sparse Dictionary mit geringem Verlust rekonstruiert werden. Dies erlaubt große Flexibilität bei der anschließenden Datenanalyse. Insbesondere sind auch im Nachhinein noch umfassendere Untersuchungen der aufgetretenen Fahrzeugreaktionen möglich, falls im weiteren Verlauf der Untersuchungen bislang unbekannte Muster in Erscheinung treten.

In Abbildung 44 ist links eine Zeit-Frequenz-Analyse der vertikalen Achslagerbeschleunigungen (Abtastrate 4 kHz) einer fünfminütigen Fahrt mit drei Haltestellen dargestellt. Auf der rechten Seite ist die anhand des gelernten Sparse Dictionary (Datenreduktion größer Faktor 60) rekonstruierte Zeit-Frequenz-Analyse im Vergleich gezeigt. Für die Zeiten mit Fahrzeugstillstand erfolgte keine Rekonstruktion. Die Variationen der Schwingleistung über Zeit und Frequenz wurden bis in Details (siehe z. B. Zeitbereich 15 bis 55 Sekunden) hinreichend verlustfrei konstruiert.

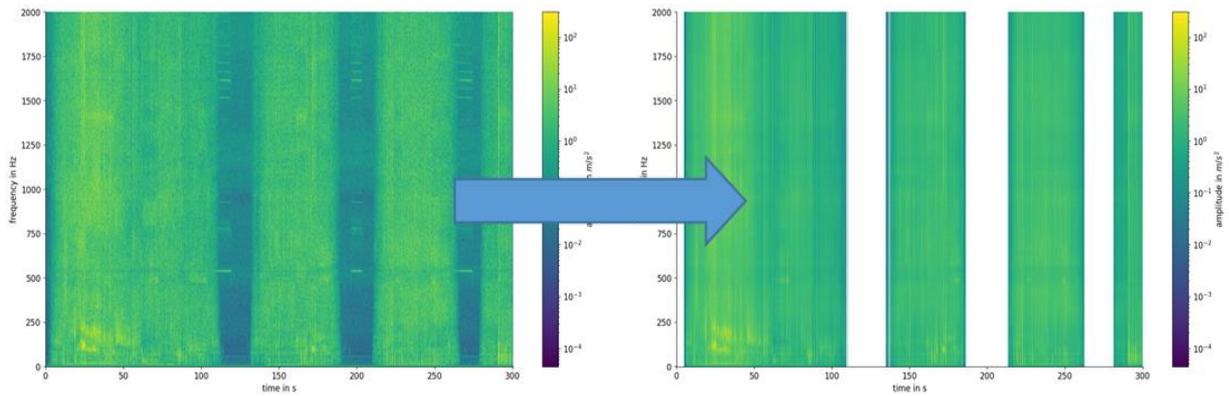


Abbildung 44. Vergleich einer Zeit-Frequenz-Analyse aus den breitbandigen Zeitreihen (links) mit der Zeit-Frequenz-Analyse aus den rekonstruierten Daten (Datenreduktion ca. Faktor 60). Siehe auch entsprechende Veröffentlichung im Preprint ([22]).

2.8 Verwertung

Zusammenfassend stellt der nachhaltige und kosteneffiziente Betrieb einer zuverlässigen und belastbaren Verkehrsinfrastruktur einen hohen gesamtgesellschaftlichen Wert dar. Eine Immissionsreduktion von schienengebundenen Fahrzeugen bringt eine Vielzahl von Vorteilen mit sich: Das ruhigere Fahrverhalten erhöht zum einen den **Fahrgastkomfort**, zum anderen wird die dynamische Beanspruchung der Fahrzeugkomponenten und somit die **Instandhaltungsnotwendigkeit** gesenkt. Gleichzeitig erzielt eine Verringerung der Schall- und Erschütterungsemissionen im urbanen Raum eine größere **Akzeptanz für den Ausbau und die Intervallverdichtung von Schienenverkehr**, um die Attraktivität nachhaltiger Verkehrsmittel zu steigern. Angesichts stetig wachsender innerstädtischer Gleisnetze werden die erfassten Daten auch in anderen europäischen Städten von zunehmendem Interesse für ÖPNV-Betreiber sein.

Die verwendete Sensorik ist robust, günstig und hat keine besonderen Platzanforderungen (daher geeignet für Niederflurfahrzeuge), wodurch sich eine Instrumentierung wesentlich einfacher als mit optischen Verfahren gestaltet und auch zu temporären Zwecken für jene Infrastrukturbetreiber interessant sein kann, die über kein dediziertes Messfahrzeug verfügen

Die eingebettete Zustandsüberwachung als Grundlage einer prädiktiven Instandhaltung ist ein Kernaspekt gegenwärtiger Digitalisierungsanstrengungen zahlreicher etablierter Unternehmen und innovativer Startups. Mit Hinblick auf die Instandhaltung ist aufgrund der Größe der europäischen urbanen Schienennetze sowie des an vielen Stellen bestehenden Instandhaltungszustands mittelfristig eine hohe Nachfrage nach entsprechenden Systemen und Dienstleistungen zu erwarten.

Die wissenschaftlichen Arbeitsergebnisse sowie der zu erstellende Trainingsdatensatz können in die Entwicklung entsprechender Produkte eingehen und so unternehmerisch verwertet werden.

DLR: Die im Projekt erarbeiteten Ergebnisse zur Georeferenzierung, Erstellung des Datenkatalogs sowie zur KI-basierten Datenanalyse fließen in die weitere Forschung ein. Die Kommunikation an die Fachöffentlichkeit wird durch wissenschaftliche Artikel, Konferenz-Beiträge, Messeauftritte und andere Veranstaltungen realisiert. Somit wird ein Wissenstransfer der praxisnahen Forschung für die Stärkung der involvierten Stakeholder (Industrie, öffentliche Einrichtungen) erreicht. Erarbeitete Daten und Software wurden verfügbar gemacht und sind somit eine bestmögliche Grundlage für Transfer und Anschlussaktivitäten.

AIT: Das Vorhaben ermöglichte AIT den Ausbau seiner Erfahrungen zum Thema automatische Zustandserkennung von Rillenschienen auf einem europäischen Level sowie relevante Forschungstätigkeiten im Bereich Onboard-Monitoring mittels vibroakustischer Messungen. Auch bei AIT wird der Wissenstransfer an relevante Stakeholder über Veröffentlichungen realisiert.

i4M: Durch die Zusammenarbeit mit den Forschungseinrichtungen wurde eine signifikante Weiterentwicklung vorhandener Lösungen bei i4M erreicht. Die vorhandene Technologie wurde im Funktionsumfang deutlich erweitert, wodurch eine erhöhte Attraktivität für Neukunden im Infrastruktur-Monitoring erzielt wurde. Somit wurde die Sichtbarkeit von i4M sowohl in globaler Sicht als auch in der Zielbranche ÖPNV aufgewertet. i4M kann die aus den Erfahrungen des Projektes abgeleiteten Produkte federführend gemeinsam mit DLR und AIT vermarkten. Ferner bieten sich durch die gemeinsamen Forschungsaktivitäten Möglichkeiten zur Akquise weiterer geförderter Forschungsvorhaben. Es werden zusätzliche Umsätze bei i4M durch weitere neu gewonnene Kunden und dort betriebene Systeme zum Infrastrukturmonitoring im ÖPNV erwartet.

2.9 Veröffentlichungen

Im Rahmen des Projektes erfolgten projektbegleitend bereits folgende Veröffentlichungen:

[17]: Roth, Michael und Heusel, Judith und Groos, Jörn Christoffer (2023) Kartengestützte GNSS/Multi-Sensor-Ortung von Schienenfahrzeugen. *Der Eisenbahningenieur EI*, Seiten 16-19. Tetzlaff Verlag. ISSN 0013-2810.

[21]: Baasch, Benjamin und Heusel, Judith und Lähns, Alexander und Roth, Michael (2025) *Spectral characterization of the rail surface in urban environments using in-service vehicles*. Springer. 10th Transport Research Arena, TRA 2024, 2024-04-15 - 2024-04-18, Dublin. doi: 10.1007/978-3-031-85578-8_42. ISBN 978-3-031-85578-8. ISSN 2196-5544.

Zum Zeitpunkt der Berichtserstellung befand sich folgende Preprint-Veröffentlichung im Peer-Review:

[22]: Baasch, Benjamin und Groos, Jörn Christoffer und Heusel, Judith und Noll, Martin (2025) *Data-Driven Sparse Coding for Onboard Condition Monitoring of Railway Tracks*. Available at SSRN: <https://ssrn.com/abstract=5295146> or <http://dx.doi.org/10.2139/ssrn.5295146>.

Weitere Veröffentlichung zu OnboardEU-Inhalten werden bei den Partnern auch nach Projektende realisiert. Dies betrifft z. B. technische Details zu Georeferenzierung, Datenmanagement und Machine Learning auf vibroakustischen Daten.

3 Abbildungsverzeichnis

Abbildung 1. Arbeitspaketstruktur des Projekts.	6
Abbildung 2. Übersicht über das System aus Beschleunigungssensor (ACC), Mikrofon (MIC) und Basiseinheit (BASE).	14
Abbildung 3. Basiseinheit mit abgesetzten Sensormodulen mit Beschleunigungssensoren (ACC) und Mikrofon (MIC).	14
Abbildung 4. Durchführung der EMV-Messungen am Messsystem im Prüflabor der FH Aachen. .	16
Abbildung 5. Darstellung von erhobenen Messdaten einer Onboard-Sensoreinheit in Hannover. Illustriert sind die hochfrequenten vibroakustischen Messungen (ACC und MIC) und die Sensordaten für die Georeferenzierung (GNSS, BASE IMU ACC und GYR).	16
Abbildung 6. Tabellarische Darstellung der Messdatenerhebung auf sieben Straßenbahnen in vier Städten und drei Ländern. Einige Messsysteme sind zum Zeitpunkt der Berichterstellung über das Projektende hinaus in Betrieb.	17
Abbildung 7. Beispielhafte Fotos von Messsysteminstallationen in Braunschweig (links oben), Hannover (rechts oben), Graz (links unten) und Basel (rechts unten).	18
Abbildung 8. Fotos eines Schienenbruchs (links) sowie eines Schienenkopfausbruchs (rechts) für Beispiele an Gleisschäden, an denen von einer deutlichen Beeinflussung der vibroakustischen Sensordaten ausgegangen werden kann.	19
Abbildung 9. Orte der Pass-by-Messungen im Grazer Stadtgebiet. In rot ist die Mikrofonpositionen eingezeichnet.	20
Abbildung 10. Datenbeispiel einer Pass-by-Messung in Graz. Auf der linken Seite ist der Schalldruck, der frequenz- und zeitbewerte Schalldruckpegel $L_{A,f}$ sowie die gemessene Geschwindigkeit der Straßenbahn der Vorbeifahrt gezeigt. Auf der rechten Seite der Schalldruckpegel $L_{A,f}$ an der externen Mikrofonposition.	21
Abbildung 11. Schematische Darstellung des Datenhandlings im Projekt OnboardEU über das zentrale Datenmanagementsystem der i4M technologies GmbH.	22
Abbildung 12. Modulare Verarbeitungskette der Georeferenzierung mit Details zu Eingangs- und Ergebnisdaten, Verarbeitungsschritten und genutzten Software-Klassen.	24
Abbildung 13. Beispielergebnisse der Georeferenzierung.	25
Abbildung 14. Aggregierte Informationen aus den Ergebnissen der Georeferenzierung über längere Zeiträume für verschiedene Einsatzorte. Blau gefärbt sind Gleise, welche mehr als 800 äquivalente Befahrungen aufweisen. Die Farbskala ist in Abbildung 15 enthalten.	26
Abbildung 15. Aggregierte Befahrungen für das gesamte Netz in Hannover.	26
Abbildung 16. Informationen zum Datenkatalog in tabellarischer Form (anonymisierte Gleisfehlstellen-ID, Beschreibung der Gleisfehlstelle, Anzahl von Fahrzeugen im Datenbeispiel, Anzahl der Überfahrten).	27
Abbildung 17. Informationen zum Datenkatalog in tabellarischer Form (Zeitstempel der ersten und letzten Überfahrt im Datenbeispiel).	28
Abbildung 18. Beispiel aus dem Datenkatalog. Anonymisierte Beschleunigungsdaten aus mehreren Überfahrten rund um eine annotierte Fehlstelle. Zudem enthalten sind Geschwindigkeiten, Zeitstempel, relevante Metadaten und Informationen über die Fehlstelle.	29
Abbildung 19. Farbkodiertes Geschwindigkeitsprofil einer Fahrt von Haltestelle Brunnenstraße (rechts) zur Haltestelle Ehrhartstraße (links). Hohe Geschwindigkeiten in blau, niedrige Geschwindigkeiten in gelb. Das Vorzeichen zeigt die Fahrtrichtung des Zweigrichtungs-Fahrzeugs an.	31

Abbildung 20. Vertikale Beschleunigungen am Radlager zweier Fahrten von Haltestelle Brunnenstraße zu Haltestelle Ehrhartstraße mit leicht unterschiedlichem Geschwindigkeitsprofilen.	31
Abbildung 21. Zeit-Frequenzbereichs-Analysen (Spektrogramme) für zwei Fahrten von Haltestelle Brunnenstraße zu Haltestelle Ehrhartstraße. Die Spektrogramme zeigen farbkodiert die Leistungsdichte der Achslagerbeschleunigungen bis ca. 2000 Hz (hohe Leistungsdichten gelb, niedrige blau).....	32
Abbildung 22. Zeit-Frequenzbereichs-Analyse (links) einer Fahrt stadteinwärts von Ehrhartstraße in Richtung Brunnenstraße. Rechts: Schwingleistungen in verschiedenen Oktavbändern für kurze Streckenabschnitte (ca. 1 m) über die Fahrzeuggeschwindigkeit aufgetragen. Deutlich erkennbar ist die systematische Zunahme der Schwingleistungen mit der Fahrzeuggeschwindigkeit („Hockey-Schläger“) sowie erhöhte Schwingleistungen im Vergleich zum Geschwindigkeitsnormal aufgrund von Streckenbesonderheiten.	32
Abbildung 23. Schienenlängsprofile in den Wellenlängenbereichen 10-30 cm (oben) und 3-10 cm (unten) für den Streckenabschnitt zwischen Brunnenstraße (rechts) und Ehrhartstraße (links). Die festgestellten Abweichungen im Profil stimmen gut mit den bei der Streckenbegehung festgestellten Riffeln im Bereich des langgestreckten Bogens und Squat-artiger Fehlzustände im Bereich der Brücken überein.	33
Abbildung 24. Aus den Achslagerbeschleunigungen für die linke (blau) und rechte (orange) Schiene abgeleitete Schienenlängsprofile für verschiedene Wellenlängenbereiche auf dem Streckenabschnitt Brunnenstraße – Ehrhartstraße.....	34
Abbildung 25. Schematische Darstellung des Einsatzes unüberwachter Lernverfahren für die Zustandsüberwachung. Mittels des maschinellen Lernens erfolgt anhand der aus den Sensordaten extrahierten Merkmale sowie der Fahrzeuggeschwindigkeit die Ableitung eines eindimensionalen Zustandsindikators. Die weiterführende Auswertung der Zustandsindikatoren pro Streckenmeter und für viele Streckenbefahrungen ((Big Data) Analyse) erlaubt bei fachlicher Auswertung tiefgehende Einblicke in Zustand und Zustandsentwicklung des Netzes.	36
Abbildung 26. Zeitreihe der vertikalen Achslagerbeschleunigungen nach der Signalaufbereitung mit der Fahrzeuggeschwindigkeit (oben) mit entsprechender Zeit-Frequenz-Analyse als Grundlage für die Gewinnung von Zeitreihenmerkmalen (z. B. Schwingleistungen in Oktavbändern.	37
Abbildung 27. Im Frequenzbereich extrahierte Zeitreihenmerkmale (Oktavbänder) als Grundlage für das unüberwachte Lernen.	37
Abbildung 28. Ableitung eines eindimensionalen Zustandsindikators aus einem mehrdimensionalen Merkmalsvektor einschließlich der Fahrzeuggeschwindigkeit. Hier am Beispiel der Mahalanobis-Distanz.	38
Abbildung 29. Darstellung von tageweise gemittelten Zustandsindikatoren für zwei Streckenabschnitte der Linie 10 in Hannover. In beiden Fällen bilden sich räumlich Bereiche erhöhter Zustandsindikatoren (gelb) aus. Dies weist auf fahrdynamisch relevante Fehlzustände und anderweitige Besonderheiten entlang der Strecke hin. Links: Erhöhte Zustandsindikatoren im Bereich eines verriffelten Bogens. Rechts: Räumlich eng begrenzte fahrdynamische Auffälligkeiten.	39
Abbildung 30. Mittlere monatliche Zustandsindikatoren der Linie 10 (stadtauswärts) in Hannover. Oben: September 2023. Unten: November 2024.	40
Abbildung 31. Mittlere monatlichen Zustandsindikatoren aus Abbildung 28 im der Bereich Brunnenstraße und Ehrhartstraße. Oben: September 2023 Unten: November 2024. Erhöhte Zustandsindikatoren im Bereich des verriffelten Bogens sowie im Bereich der Brücken.....	40
Abbildung 32. Vergleich der Zustandsindikatoren (Unten) aus September 2023 mit den aus den Achslagerbeschleunigungen abgeleiteten Schienenlängsprofilen in den Wellenlängenbereichen 10-30 cm (Oben) und 3-10 cm (Mitte).	41

Abbildung 33. Hier sind die Quellen der Eingangsdaten und Klassifikationen (Grüne Boxen, am linken Rand), die Daten selbst (Graue Boxen mit Pfeilen direkt aus den Datenquellen folgend), die Anwendung der Parameter und die Art der Anwendungsdaten (hellgrüne Boxen), sowie die Art des verwendeten Modells (blaue Box, rechter Rand) dargestellt.	42
Abbildung 34. Ausschnitt des Grazer Schienennetzes auf dem die 5 Meter Abschnitte/“bin“ als violette Punkte dargestellt sind (die Punkte zeigen den Mittelpunkt eines 5 Meter Abschnittes an). Zusätzlich sind die Positionen von Weichen als blaue Dreiecke dargestellt. Die Datengrundlage des Schienennetzes wurde von der Holding Graz – Kommunale Dienstleistungen GmbH erhalten.	43
Abbildung 35. Schematisch die Nutzung eines künstlichen neuronalen Netzes nach dem Training.	44
Abbildung 36. Ergebnisse der Klassifikation von Schadensstellen auf dem ganzen Grazer Netz (Zeilen ursprüngliche Kategorie, Spalten geschätzte Kategorie in Prozent). Die Diagonale dieser Matrix gibt die korrekten Klassifikationen in der jeweiligen Klasse an. Diese Art der Matrix bezeichnet man als „Konfusionsmatrix“.	44
Abbildung 37. Die „Konfusionsmatrix“ stellt die Anteile der verschiedenen Klassenzuordnungen (Zeilen: ursprüngliche Kategorie, Spalten: geschätzte Kategorie) als Prozentzahlen dar. Die Diagonale gibt die korrekt zugeordneten „bins“ wieder.	45
Abbildung 38. Vergleich von als Grüngleis klassifizierten Stellen (orangene Rechtecke) und Grüngleis in den Trainingsdaten (grüne Punkte) an zwei Streckenabschnitten in Graz. Quelle ist ein Orthophoto erhalten von geodaten.graz.at.	45
Abbildung 39. Hier sieht man einen Vergleich von als Schottergleis klassifizierten Stellen (orangene Rechtecke) und Schottergleis in den Trainingsdaten (blaue Punkte) an zwei Streckenabschnitten in Graz. Quelle ist ein Orthophoto erhalten von geodaten.graz.at.	46
Abbildung 40. Energieäquivalente Dauerschallpegel der Vorbeifahrten als am Fahrzeug aufgenommener Onboard- und extern aufgenommener Vorbeifahrtspegel.	47
Abbildung 41. Transferspektren als gemittelte Pegeldifferenzen zwischen Vorbeifahrts- und Onboardpegel breitbandig (links) und in Oktavbändern (rechts).	47
Abbildung 42. Die für die gleisgenaue Georeferenzierung erforderlichen Daten von Inertialmesseinheit (IMU) und Satellitennavigation (GNSS) können in vollem Umfang übertragen werden. Die hochfrequenten Messdaten der übrigen Sensoren werden mittels Edge-Computing erheblich reduziert. Für Streckenabschnitte mit auffälligen Fahrzeugverhalten werden die Messdaten für spätere detaillierte Analysen vollständig gespeichert und übertragen.	48
Abbildung 43. Schwingleistungen in verschiedenen Frequenzbereichen entlang eines Streckenabschnitts als Grundlage für die Auswahl von zu übertragenden Messdaten auf dem Fahrzeug.	49
Abbildung 44. Vergleich einer Zeit-Frequenz-Analyse aus den breitbandigen Zeitreihen (links) mit der Zeit-Frequenz-Analyse aus den rekonstruierten Daten (Datenreduktion ca. Faktor 60). Siehe auch entsprechende Veröffentlichung im Preprint ([22]).	50

4 Literaturverzeichnis

- [1] BUNDESMINISTERIUM FÜR VERKEHR: *Onboard-Daten für die Erkennung von Gleisfehlstellen – OnboardEU*. URL <https://www.bmv.de/SharedDocs/DE/Artikel/DG/mfund-projekte/onboard-eu.html> – Überprüfungsdatum 2025-07-15
- [2] KOLMORGEN, Vasco Paul ; RAHMIG, Christian ; LINGEN, Jörg von: *Über IDX4rail*. URL <https://www.idx4rail.de/de/ueberblick/ueber-idx4rail> – Überprüfungsdatum 2025-07-15
- [3] GRASSIE, Stuart L.: Corrugation on Australian National: Cause, Measurement and Rectification. In: *Railways in action : 4th International heavy haul railway conference : Preprints* : Institution of Engineers, 1989 (National conference publication - Institution of Engineers, Australia, 12), S. 188–192
- [4] LEWIS, Raymond B. ; RICHARDS, Arthur N.: *A new method for the routine measurement of railhead corrugations*. In: *Rail International* (1986), Nr. 2, S. 37–41
- [5] VINKÓ, Ákos: *Monitoring and condition assessment of tramway track using in-service vehicle*. In: *Pollack Periodica* 11 (2016), Nr. 3, S. 73–82. DOI:10.1556/606.2016.11.3.7
- [6] FALAMARZI, Amir ; MORIDPOUR, Sara ; NAZEM, Majidreza: *Development of a tram track degradation prediction model based on the acceleration data*. In: *Structure and Infrastructure Engineering* 15 (2019), Nr. 10, S. 1308–1318. DOI:10.1080/15732479.2019.1615963
- [7] NOLL, Martin-Christopher: Predictive Maintenance am Beispiel Schienennahverkehr : Auswirkungen von Gleisfehlstellen auf die mechanischen Belastungen an Straßenbahnradern und Konzept zur zustandsorientierten Instandhaltung von Gleisinfrastruktur. In: DONCKER, Rik W. de; NIEBEN, Nils; SCHINDLER, Christian Franz Wilfried (Hrsg.): *IRSA 2019: Tagungsband, Proceedings : 2nd International Railway Symposium Aachen, Aachen, Germany, 26-28 November 2019* : RWTH Aachen University. DOI:10.18154/RWTH-2020-00144
- [8] BAASCH, Benjamin ; HEUSEL, Judith ; ROTH, Michael ; NEUMANN, Thorsten: *Train Wheel Condition Monitoring via Cepstral Analysis of Axle Box Accelerations*. In: *Applied Sciences* 11 (2021), Nr. 4, S. 1432. DOI:10.3390/app11041432
- [9] NIEBLING, Julia ; BAASCH, Benjamin ; KRUSPE, Anna: Analysis of Railway Track Irregularities with Convolutional Autoencoders and Clustering Algorithms, Bd. 1279. In: BERNARDI, Simona; VITTORINI, Valeria; FLAMMINI, Francesco; NARDONE, Roberto; MARRONE, Stefano; ADLER, Rasmus; SCHNEIDER, Daniel; SCHLEIB, Philipp; NOSTRO, Nicola; LØVENSTEIN OLSEN, Rasmus; DI SALLE, Amleto; MASCI, Paolo (Hrsg.): *Dependable Computing - EDCC 2020 Workshops*. Cham : Springer International Publishing, 2020 (Communications in Computer and Information Science), S. 78–89. DOI:10.1007/978-3-030-58462-7_7
- [10] NIEWALDA, Tobias: *Deep Learning Based Classification of Rail Defects Using On-board Monitoring in the Stockholm Underground*. KTH, Rail Vehicles. 2020
- [11] ALTEN, Karoline: Vibro-Acoustic Inspection of Vienna's Tram Network. In: *WRI EU 2019 - Wheel Rail Interaction Conference EU*, 2019
- [12] ALTEN, Karoline ; WEHR, Reinhard ; FUCHS, Andreas ; WEHR, Werner ; HAUSER, T.: Flächendeckende Emissionsmessungen im Wiener Linien Straßenbahnnetz: Erkenntnisse auf Befahrung mit dem Gleismesswagen. In: *6. VDI-Fachtagung Baudynamik 2018 // Baudynamik 2018 : 6. VDI-Fachtagung ; Würzburg, 17. und 18. April 2018*. Nichtredigierter Manuskriptdruck. Düsseldorf : VDI Verlag GmbH, 2018 (VDI-Berichte, 2321), S. 307–313

- [13] WEHR, Reinhard ; FUCHS, Andreas ; WEHR, Werner: Akustische Zustandsbewertung von Gleisen im Straßenbahnnetz. In: *DAGA 2017*, 2017
- [14] ALTEN, Karoline ; FUCHS, Andreas ; WEHR, Werner ; WEHR, Reinhard: *Vibroakustische Überwachung des Schienenzustandes durch Regelfahrzeuge im Straßenbahnnetz*. In: *e & i Elektrotechnik und Informationstechnik* 138 (2021), Nr. 3, S. 190–196. DOI:10.1007/s00502-021-00879-0
- [15] ROTH, Michael ; BAASCH, Benjamin ; HAVRILA, Patrik ; GROOS, Jorn: Map-Supported Positioning Enables In-Service Condition Monitoring of Railway Tracks. In: *2018 21st International Conference on Information Fusion (FUSION)* : IEEE, 2018, S. 2346–2353. DOI:10.23919/ICIF.2018.8455377
- [16] THE HDF GROUP, NONE ; KOZIOL, Quincey: *HDF5-Version 1.12.0* : Lawrence Berkeley National Laboratory (LBNL), Berkeley, CA (United States), 2020
- [17] ROTH, Michael ; HEUSEL, Judith ; GROOS, Jörn Christoffer: *Kartengestützte GNSS/Multi-Sensor-Ortung von Schienenfahrzeugen*. In: *Der Eisenbahningenieur EI* (2023), S. 16–19. URL <https://elib.dlr.de/197334/>
- [18] ROTH, Michael ; HEUSEL, Judith ; HEDBERG, Erik ; KIYANFAR, Keivan: *railpos-onboardeu*, 2025. URL <https://github.com/DLR-TS/railpos-onboardeu>
- [19] BAASCH, Benjamin ; GROOS, Jörn ; HEUSEL, Judith ; JAHAN, Kanwal ; RIEDLER, Wolfgang ; ROTH, Michael ; SCHULZ, Sebastian ; HOHLS, Jens ; SELIGER, Kirstin ; HILT, Britta ; DIEST, Konstantin ; GELZHÄUSER, Roman: *Hafenbetrieboptimierung durch vorausschauende eingebettete Zustandsüberwachung der Gleisinfrastruktur (HavenZuG)* : BMVI-Förderprogramm IHATEC : gemeinsamer Schlussbericht der Verbundpartner. In: *Hafenbetrieboptimierung durch vorausschauende eingebettete Zustandsüberwachung der Gleisinfrastruktur (HavenZuG)*. DOI:10.2314/KXP:1859247458
- [20] HEUSEL, J. ; BAASCH, B. ; RIEDLER, W. ; ROTH, M. ; SHANKAR, S. ; GROOS, J. C.: *Detecting corrugation defects in harbour railway networks using axle-box acceleration data*. In: *Insight - Non-Destructive Testing and Condition Monitoring* 64 (2022), Nr. 7, S. 404–410. DOI:10.1784/insi.2022.64.7.404
- [21] BAASCH, Benjamin ; HEUSEL, Judith ; LÄHNS, Alexander ; ROTH, Michael ; GROOS, Jörn: Spectral Characterization of the Rail Surface in Urban Environments Using in-Service Vehicles. In: McNALLY, Ciaran; CARROLL, Páraic; MARTINEZ-PASTOR, Beatriz; GHOSH, Bidisha; EFTHYMIIOU, Marina; VALANTASIS-KANELLOS, Nikolaos (Hrsg.): *Transport Transitions: Advancing Sustainable and Inclusive Mobility*. Cham : Springer Nature Switzerland, 2025 (Lecture Notes in Mobility), S. 335–341. DOI:10.1007/978-3-031-85578-8_42
- [22] BAASCH, Benjamin ; GROOS, Jörn Christoffer ; HEUSEL, Judith ; NOLL, Martin: *Data-Driven Sparse Coding for Onboard Condition Monitoring of Railway Tracks*. In: *preprint in peer review available at SSRN: <https://ssrn.com/abstract=5295146>* (2025). DOI:10.2139/ssrn.5295146
- [23] SONG, Liqiang ; MA, Weining ; LIU, Zhongxin ; SHI, Zhiyong: *Application of optimized sparse encoding algorithm in data compression*. In: *Digital Signal Processing* 151 (2024), S. 104549. DOI:10.1016/j.dsp.2024.104549
- [24] WANG, Jun ; QIAO, Wei ; QU, Liyan: *Wind Turbine Bearing Fault Diagnosis Based on Sparse Representation of Condition Monitoring Signals*. In: *IEEE Transactions on Industry Applications* 55 (2019), Nr. 2, S. 1844–1852. DOI:10.1109/TIA.2018.2873576

- [25] ZHANG, Xinpeng ; HU, Niaoqing ; HU, Lei ; CHEN, Ling ; CHENG, Zhe: *A bearing fault diagnosis method based on the low-dimensional compressed vibration signal*. In: *Advances in Mechanical Engineering* 7 (2015), Nr. 7. DOI:10.1177/1687814015593442
- [26] MAIRAL, Julien ; BACH, Francis ; PONCE, Jean ; SAPIRO, Guillermo: Online dictionary learning for sparse coding. In: DANYLUK, Andrea; BOTTOU, Léon; LITTMAN, Michael (Hrsg.): *Proceedings of the 26th Annual International Conference on Machine Learning*. New York, NY, USA : ACM, 2009, S. 689–696. DOI:10.1145/1553374.1553463
- [27] ELAD, Michael ; AHARON, Michal: *Image denoising via sparse and redundant representations over learned dictionaries*. In: *IEEE transactions on image processing : a publication of the IEEE Signal Processing Society* 15 (2006), Nr. 12, S. 3736–3745. DOI:10.1109/TIP.2006.881969