

# Zustandsüberwachung mit Regelfahrzeugen

*Karoline Alten, Andreas Fuchs, Jan Struhar, Benjamin Baasch, Judith Heusel und Jörn C. Groos*

Die Künstliche Intelligenz (KI) bzw. das maschinelle Lernen ermöglicht neue Ansätze für die Zustandsüberwachung der Bahninfrastruktur im laufenden Betrieb. Dieser Beitrag gibt einen Überblick über Forschungsarbeiten des Austrian Institute of Technology (AIT) und des Deutschen Zentrums für Luft- und Raumfahrt DLR e. V. zur Nutzung der Fahrzeug-Fahrweg-Interaktion zur Erkennung von Fehlzuständen an Schienen.

## 1 Einleitung

Am DLR e. V. und am AIT werden seit einigen Jahren die Möglichkeiten eingebetteter Sensoren auf Schienenfahrzeugen in Bezug auf die Fehlstellendetektion an Gleisen untersucht. Beide Institute setzen dabei auf die Instrumentierung von Regelfahrzeugen in den jeweiligen Netzen mit Accelerometern zur Erfassung der Achslagerbeschleunigungen.

Durch den Einsatz verschiedener Methoden des maschinellen Lernens erforschen die Teams die Anwendbarkeit derartiger Sensorik und Algorithmik zur automatischen Schadstellenklassifizierung und präsentieren in diesem Beitrag Ergebnisse aus aktuell laufenden Forschungsprojekten. An zwei unterschiedlichen Fallbeispielen wird gezeigt, welche Ansätze zur Detektion von Gleisfehlstellen möglich sind und am Beispiel der Riffelerkennung erfolgreich an der Vollbahn (Hafen Braunschweig) und an der Straßenbahn (Wien) erprobt wurden.

Im Folgenden werden die jeweilige Sensorik und die damit ausgerüsteten Fahrzeuge in den beiden Schienennetzen beschrieben, welche Daten damit über die Jahre akquiriert wurden und wie diese anschließend mittels KI und geeigneter Georeferenzierung zu einer netzweiten Darstellung der Verriffelung verarbeitet wurden.

## 2 Riffeldetektion im Wiener Straßenbahnnetz

Periodische Unebenheiten am Schienenkopf erzeugen bei der Fahrzeugüberfahrt erhöhte dynamische Kräfte, die auf das Gesamtsystem Rad-Schiene wirken. Die Folgen sind erhöhte Verschleißraten am Fahrzeug und am Oberbau sowie verstärkte Emissionen, die sich in Form von Schall und Erschütterungen für Fahrgäste und im Wohn- und Arbeitsbereich der umliegenden Anrainer manifestieren [1–3]. Bedingt durch den Längsschlupf der angetriebenen Räder in Brems- und Beschleunigungsabschnit-

ten treten Riffel im Straßenbahnnetz häufig bei Ampeln oder im Stationsbereich bzw. aufgrund der unterschiedlichen Rollradien in Bögen auf. Sie weisen üblicherweise Wellenlängen zwischen 5-15 cm auf und sind von etwas geringerer Tiefe als das ähnliche, teilweise langwelligere Schadensbild der Schlupfwelle. Die plastische Verformung des Fahrkopfes durch Riffel ist als Wellenbild mit freiem Auge erkennbar.

Das Straßenbahnnetz der Wiener Linien stellt mit 220 km Gleis das sechstgrößte Straßenbahnnetz der Welt dar und wird durch geschultes Personal halbjährlichen In-situ-Inspektionen unterzogen. Hierbei wird der Zustand aller Oberbaukomponenten – von den Großflächenplatten zwischen den Gleisen bis zur Bahnsteigkante und den Weichenanlagen – durch visuelle Beurteilungen festgestellt und protokolliert. Der Schienenzustand wird durch Zustandsnoten A-D beschrieben, wobei A ein intaktes Gleis darstellt und D eine baldige Instandsetzungsmaßnahme erfordert. Die Dokumentation von Riffeln bzw. Schlupfwellen sowie die Beurteilung deren Schweregrades ist ein Teilaspekt der visuellen Beurteilung und basiert bei Straßenbahnnetzbetreibern üblicherweise auf der subjektiven Einschätzung des Fachpersonals.

Langfristig ist im Bereich Oberbau der verstärkte Einsatz messtechnischer Verfahren geplant, um das Instandhaltungsmanagement effizient und objektivierbar zu unterstützen. Das Schienenlängsprofil kann hierbei durch entsprechende Handmessgeräte oder Trolleys punktuell erfasst werden, beziehungsweise stehen bei Reprofilierungsarbeiten die Vor- und Nachmessungen entsprechend der EN 13231-2 zur Verfügung. Im Rahmen von Forschungsprojekten wurde am AIT über die letzten Jahre untersucht, inwieweit sich die kontinuierliche Messung von Emissionspegeln an Bord von Straßenbahngarnituren im Wiener Netz eignet, um periodische Fehlstellen wie Riffel automatisch zu erkennen und zu klassifizieren.

## 2.1 Onboard-Messungen an Wiener Straßenbahngarnituren

### 2.1.1 Der Gleismesswagen

Das Wiener Straßenbahnnetz verfügt seit 2004 über einen dedizierten Gleismesswagen, bestehend aus einem umgebauten Gelenkwagen in Hochflurbauweise. Das Fahrzeug befährt im Rahmen von Nachtmessungen zweimal jährlich das gesamte Netz und dient der Verschleißmessung mittels Laserlichtschnittverfahren [4]. Hierbei wird die Abweichung des Schienenprofils im aktuellen Messquerschnitt (alle 1 cm) vom Sollquerschnitt ermittelt, wobei sich das Verfahren sowohl für Rillen- als auch für Vignolgleis eignet. Zu Verortungszwecken wurde das Fahrzeug in den frühen Zehnerjahren mit kapazitiven Erschütterungssensoren aufgerüstet [5] und später folgte ein ½" Messmikrofon. Letzteres hat eine flächendeckende Rollgeräuschkarte des Netzes zum Ziel, in der relative Frequenz- und Amplitudenänderungen ersichtlich werden [6].

Die Beschleunigungssensoren (triaxiale MEMS) befinden sich an den vier Achslagern des nicht-angetriebenen, mittleren Drehgestells, am Drehgestellrahmen sowie am Wagenkasten. Für die Schienenzustandserkennung werden nur die Achslagersensoren verwendet, um die Vibrationen des Rad-Schiene-Kontakts unterhalb der Primärfeder zu erfassen. Nur die Radfeder – bestehend aus über den Umfang gleichmäßig verteilten Gummiblöcken zwischen Radreifen und Radscheibe – befindet sich am Übertragungsweg zu den Sensoren. Das Mikrofon wurde in zentraler Position vor demselben Drehgestell montiert. Hierdurch werden zwar beide Gleisstränge gemeinsam bewertet und eine Unterscheidung zwischen rechter/linker Fahrzeugseite ist nicht möglich, jedoch hätte die harsche Einsatzumgebung in unmittelbarem Nahbereich zum Rad-Schiene-Kontaktpunkt voraussichtlich zu regelmäßigen Ausfällen des Mikrofons geführt.

Die Kombination beider Sensortypen ermöglicht die Untersuchung eines viel breiteren Frequenzbereichs, als dies mittels Schwingbeschleunigungs- oder Schallmessungen alleine möglich wäre. Der Emissionsproblematik kann somit umfassend begegnet werden und die Unterscheidbarkeit verschiedener Schienenkopffehler bzw. Gleiskörpereigenschaften als Kombination der Schall- und Vibrationsauswertungen untersucht werden [7].

Bis dato wurden in Summe etwa 15 000 km an vibroakustischen Messdaten mit dem Gleismesswagen aufgezeichnet. Die Datenbasis der im Folgenden beschriebenen KI-Verfahren bilden jeweils jene Messfahrten, die am zeitnächsten zur Erhebung der Trainingsdaten entlang der inspizierten Abschnitte stattfanden. Das Sensorkonzept des Gleismesswagens bildet darüber hinaus die Grundlage für die Instrumentierung von Regelfahrzeugen mittels eines eigens entwickelten Sensorsystems.

### 2.1.2 Instrumentierung von Regelfahrzeugen

Die Interaktion zwischen Rad und Schiene bei fahrenden Garnituren ist abhängig vom Masse-Feder-Dämpfersystem des jeweiligen Fahrzeuges und der Beschaffenheit des befahrenen Oberbaus. Unterschiedliche Fahrzeugtypen weisen aufgrund ihrer Massen und Steifigkeiten individuelle Schwingungsverhalten auf und wirken entsprechend anders auf die Gleise ein. Die am Gleismesswagen ermittelten Modelle zur Emissionsbeurteilung sind daher primär auf die E1 Garnituren bezogen, die in Hochflurbauweise und mit Drehgestellen ausgeführt sind.

Aktuell besteht die Wiener Straßenbahnflotte zum größten Teil aus Niederflrfahrzeugen mit Portalfahrwerken und Losrädern (ohne Achsen bzw. Drehgestelle). Um zu überprüfen, ob eine Störstellendetektion auch auf Basis der Onboard-Daten moderner Garnituren möglich ist, wurden zwei Fahrzeuge im Sommer 2020

temporär mit Schwingbeschleunigungssensoren und Mikrofonen bestückt und ausgewählte Routen im Netz mehrmals befahren. Als Sensoren wurden platzsparende und kostengünstige MEMS-Sensoren verwendet, wobei nur Sensoren mit integrierter Analog-Digital-Wandlung verwendet wurden und besonderes Augenmerk auf eine robuste Übertragung der digitalen Signale gelegt wurde. Dabei wurden die jeweils erste und letzte Achse mit jeweils zwei Sensoren für die linke und rechte Seite instrumentiert.

Mit einem Messbereich bis 130 dB SPL (Sound Pressure Level), einem Dynamikumfang von 105 dB und einem Frequenzbereich von 28 Hz bis 15 kHz sind die verwendeten MEMS-Mikrofone in der Lage, auch die lautesten auftretenden akustischen Ereignisse in hoher Qualität aufzuzeichnen. Die Abtastrate betrug 48 kHz. Im Gegensatz zur Instrumentierung des Gleismesswagens wurden die Mikrofone bei der Instrumentierung der Regelfahrzeuge in der Nähe des Rad-Schiene-Kontakts platziert, da die Erfahrungen mit dem instrumentierten Gleismesswagen gezeigt haben, dass eine stärkere Isolation der Schallemission des Rad-Schiene-Kontakts wünschenswert ist sowie eine Trennung von rechter und linker Seite explizit gewünscht war. Weiterhin sind die Hardwarekosten eines Mikrofons gegenwärtig im Bereich von 10 EUR anzusiedeln, wodurch auch ein stärkerer Verschleiß durch erhöhte Verschmutzung akzeptabel erscheint.

Die verwendeten triaxialen Beschleunigungssensoren haben einen Messbereich bis 40 g und einen Frequenzbereich von 0 Hz bis 1 kHz bei einer Abtastrate von 4 kHz. Der hohe Dynamikumfang bis 40 dB in Kombination mit der hohen Abtastrate kann hierbei transiente Stöße präzise erfassen. Die Beschleunigungssensoren wurden ebenso wie bei der Instrumentierung des Gleismesswagens in der Nähe der Achslager auf der linken und rechten Seite befestigt.

Die Daten von jeweils einem Mikrofon und einem Beschleunigungssensor wurden von unter der Straßenbahn platzierten Einplatinencomputern ausgelesen und per Netzwerk an einen im Fahrgastraum befindlichen Laptop übertragen, der auch die Zeitsynchronisation der aufgezeichneten Daten mittels NTP Server (Network Time Protocol) übernahm. Zusätzlich war ein RTK (Real Time Kinematics) basierender GNSS-Empfänger zur präzisen Verortung an den Laptop angeschlossen. Prinzipiell ist jedoch auch ein autonomer Aufbau mittels eines Einplatinencomputers vorstellbar, der in der Lage ist, die Signale von einer Achse inklusive der GNSS-Signale aufzuzeichnen.

Der Softwaredienst am Einplatinencomputer ist in C++ implementiert und liest die Sensordatenströme über SPI Protokoll. Die Daten werden validiert und mittels ZeroMQ [8] über die Netzwerkverbindung weitergeleitet. Der Vorteil dieser Bibliothek ist die selbstständige Wiederherstellung der Verbindung bei Ausfällen.

## 2.2 Automatische Erkennung mit maschinellem Lernen

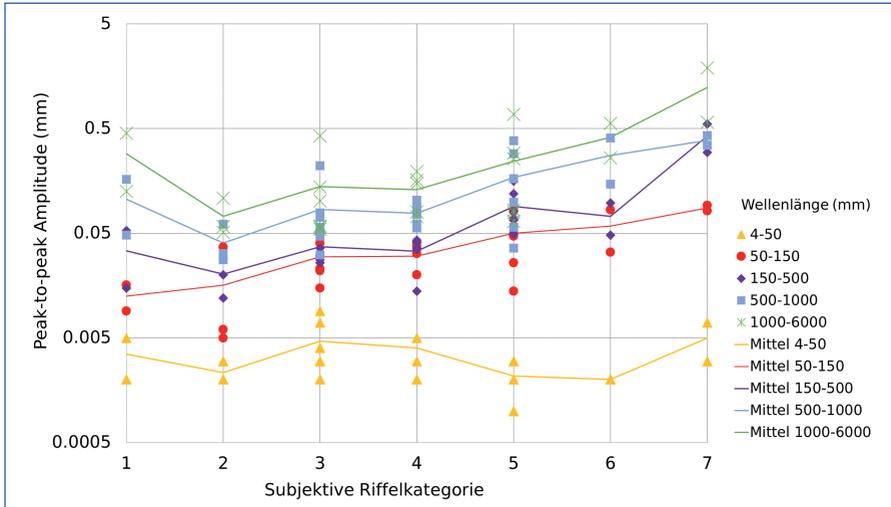
### 2.2.1 Pre-Processing

Die Identifikation des Gleiszustandes mittels Onboard-Messungen wird grundsätzlich in diskreten Gleissegmenten, sogenannten Bins, vorgenommen. Beim Binning werden die kontinuierlich aufgezeichneten Messdaten (im Fall der Vibroakustik mit konstanter zeitlicher Abtastfrequenz und nicht Distanz-getriggert) einem bestimmten Abschnitt zugeordnet, dessen Länge sich je nach Problemstellung frei definieren lässt. In den hierin beschriebenen Arbeiten wird eine Binlänge von 5 m verwendet, was sich aus einem Kompromiss zwischen Abtastrate und Maximalgeschwindigkeit (die Anzahl der Messwerte pro Gleisometer muss auch bei hohen Fahrzeuggeschwindigkeiten für die Feature-Extraktion geeignet sein) sowie zwischen Verortungsgenauigkeit und Instandsetzungsabschnitten ergibt (punktuelle Fehlstellen erfordern eine genauere Lokalisation als über mehrere Zehnermeter ausgedehnte Schäden, die großräumig z. B. durch Schienenschleifen behandelt werden).

Da immer ein gewisses Grundmaß an Unebenheiten – sowohl am Radkranz als auch am Fahrkopf – vorliegt, kommt es naturgemäß zu größeren dynamischen Kräften bei höheren Fahrzeuggeschwindigkeiten. Diese bilden sich in Form einer stärkeren Anregung und folglich erhöhten Emissionen mit steigender Geschwindigkeit aus. Die Onboard-Pegel werden daher in einem ersten Schritt als Funktion der Geschwindigkeit (und Fahrzeugtyp) über alle Bins hinweg bestimmt. Diese Funktion stellt einen Erwartungspegel dar, der selbst ohne Schadensbild in einem Bin bei einer bestimmten Geschwindigkeit zu erwarten ist. Die Regression beruht auf der Annahme, dass die überwiegende Mehrheit der Bins aus intaktem Gleis besteht und sich der dortige Oberbau hinreichend ähnlich ist, um eine gemeinsame Geschwindigkeitsfunktion zuzulassen (z. B. Schotteroberbau würde typischerweise eine andere Funktion aufweisen als eingebettetes Gleis).

### 2.2.2 Trainingsdaten

Als Features bezeichnet man im maschinellen Lernen jene Kennwerte oder Merkmale, die aus dem Zeitsignal der Onboard-Daten für einen Bin ermittelt werden. Jeder Bin wird somit durch einen Vektor an Features (multidimensionaler Raum) beschrieben, der als Grundlage für den Klassifikationsalgorithmus dient. Ziel der in Wien durchgeführten Studie war nicht nur die binäre (Ja/Nein) Detektion von Riffeln, sondern die Einstufung in Kategorien zur Bestimmung des Schweregrades. Zu diesem Zweck wurden im Rahmen von Begehungen knapp 11 km Gleise inspiziert und deren Riffelung in Klassen 1-7 eingestuft (1=keine Riffel, 7=starke Riffel). Gleichzeitig wurden punktuelle Längsprofilmessungen vorgenommen, um einen Zusammenhang zwischen subjektiver Riffelstärke und tatsächlicher Spitze-Spitze-Amplitude zu



**Abb. 1:** Gemessene Spitze-Spitze-Amplitude der Längsebenheit pro Riffelkategorie und Wellenlängenbereich

erhalten (Abb. 1). Hierin erkennt man, dass kurze Wellenlängen (4-50 mm) nicht mit der Riffelkategorie korrelieren, während erwartungsgemäß die Bereiche 50-150 mm sowie 150-500 mm einen positiven Zusammenhang mit der bewerteten Riffelstärke zeigen. Mittlere Spitze-Spitze-Amplituden pro Kategorie sind in der Grafik als durchgezogene Linien dargestellt.

Die feinstufige Unterteilung der subjektiv beurteilten Riffelstärke wurde im Zuge der Weiterverarbeitung in vier Kategorien aggregiert, um einerseits eine praktikablere Datenmenge pro Klasse für das Trainieren der KI-Modelle zu erhalten und andererseits eine Übereinstimmung mit den üblichen Bewertungsklassen des Oberbaus (A-D, A=keine Riffel und D=starke Riffel) zu erhalten. Die Häufigkeitsverteilung der hierdurch ermittelten Trainingsdaten ist in Tab. 1 dargestellt. Obwohl im Zuge der Begehungen gezielt Wert auf stark abgenutzte Schienenabschnitte gelegt wurde, lässt sich das Problem der ungleichmäßigen Verteilung der Riffelklassen erkennen (und der insgesamt starke Überhang der Kategorien mit keinen oder sehr schwachen Riffeln). Diese Unterrepräsentation schwerer Riffelung sollte im Zuge des Modelltrainings z. B. durch Resampling-Methoden berücksichtigt werden.

Kategorie	A	B	C	D	Gesamt
Bin Anzahl	1374	390	194	239	2197

**Tab. 1:** Anzahl der markierten 5-m-Bins pro Riffelkategorie

### 2.2.3 Feature-Definition

Bei der Überfahrt eines periodischen Schienenfehlers ist die Frequenz der Fahrzeuganregung abhängig von der Befahrungsgeschwindigkeit. Um Riffel erfolgreich in den Onboard-Signalen zu identifizieren, ist daher ein variabler Bandpass zielführend, dessen Eckfrequenzen pro Bin sich aus der Geschwindigkeit ergeben, um räumliche Wellenlängen von 5-15 cm herauszufiltern. Am Gleismesswagen wurden die vertikalen Schwingbeschleunigungskanäle am Radsatz und Drehgestell herangezogen, um folgende Features pro Bin zu ermitteln:

- Variabler Bandpasspegel L\_BP
- Gesamtenergie
- Intensitätsquotient (Verhältnis L\_BP zur Gesamtenergie)
- Kurtosis der Energie
- Terzbandpegel.

Das Zeitsignal der Mikrofone wurde in ein wegbasiertes Signal umgerechnet und pro Bin die Autokorrelation ermittelt. Auf Basis dessen wurden folgende Features berechnet:

- Anzahl an Nulldurchgängen der Autokorrelationsfunktion pro Meter
- Variabilität der Abstände zwischen den Nulldurchgängen: Differenz zwischen 20. und 80. Perzentil der Intervalle zwischen den Nulldurchgängen eines Bins.

Für alle Pegelberechnungen in Dezibel wurde, unabhängig von der Messgröße, ein Bezugswert von  $2e-5$  verwendet. Zusätzlich zu den Vibro-Akustiksignalen wurde die Temperatur einer Wetterstation im Umfeld der Messfahrt als Feature herangezogen, um eventuelle Witterungseinflüsse abzubilden (Anmerkung: Vorliegende Studien behandeln hauptsächlich den Einfluss von Nässe auf den Reibungskoeffizienten zwischen Rad und Schiene und folglich die Auswirkung auf Kurvenquietschen) [9, 10].

Vor dem Trainieren des KI-Modells wurden alle Features skaliert und einer Form von Gridsearch unterzogen, um ideale Meta-Kennwerte zu ermitteln. Hierbei ging es beispielsweise um die maximal zulässige Zeit zwischen Messfahrt und der In-situ-Bewertung, die Länge eines laufenden Mittelwerts über die Features und die entsprechende Bewertung des Abschnitts sowie die Verwendung markierter Daten aus den Bereichen der Wendeschleifen, wo meistens nur sehr geringe Befahrungsgeschwindigkeiten vorliegen. Anschließend erfolgte der eigentliche Gridsearch zur Optimierung der Hyperparameter des KI-Modells. Beim finalen Modell handelt es sich um eine Support Vector Regression (SVR). Beide Optimierungsstufen (Gridsearches) wurden jeweils anhand einer Wahrheitsmatrix bewertet, wodurch am Ende sechs maßgebende Features für die Klassifikation und die Standard-Hyperparameter der SVR das beste Ergebnis lieferten (Abb. 2).

Für eine stabile Detektion wurden die Daten anhand eines gleitenden Mittelwertfilters über 35 m (entspricht sieben Bins zu je 5 m) geglättet. Dadurch sind die einzelnen Bewertungsbins zueinander abhängig. Aufgrund der (unabhängigen) beschränkten Datenmenge und Verteilung der Riffelkategorien war es nicht möglich, einen Teil des Datensatzes zur Validierung außerhalb der Gridsearch-Optimierung vorzuhalten. Die Wahrheitsmatrix in Abb. 2 wurde daher mit dem Trainingsdatensatz erstellt. Durch die Beschränkung auf sechs (teils kollineare) Features ist nicht von einem starken Overfitting auszugehen.

	A	B	C	D
A	762	509	2	0
B	274	1 022	43	0
C	85	320	93	6
D	5	94	57	39

**Abb. 2:** Wahrheitsmatrix des SVR-Modells zur Klassifizierung von Riffeln

### 3 Industriebahnen

Seit 2015 betreibt das DLR im Rahmen von verschiedenen Forschungsprojekten prototypische Multi-Sensor-Systeme unterschiedlicher Konfiguration auf den beiden Rangierlokomotiven der Braunschweiger Hafenbahn [11, 12]. Die so in operativer Umgebung kontinuierlich erhobenen Messdaten dienen der Erforschung und Entwicklung von Analyseverfahren für die gleisgenaue Schienenfahrzeugortung [13] sowie die eingebettete Zustandsüberwachung der Gleisinfrastruktur [14]. Für die Fahrzeugortung werden neben den Signalen der globalen Satellitennavigationssysteme (GNSS) mittels einer Inertialmesseinheit (IMU) die Beschleunigungen und Drehraten des Fahrzeugs (in je drei Raumrichtungen mit 100 Hz) erfasst. Für die Zustandsüberwachung erfolgt die Messung der fahrdynamischen Reaktionen im Frequenzbereich von 0,8 Hz bis 8000 Hz (Abtastrate 20625 Hz) mittels zweier triaxialer Beschleunigungssensoren an den beiden Achslagern (auch Achslagerbeschleunigungen oder Axle-Box Accelerations, ABA) einer der beiden Achsen. Weiterhin wird die Strecke mit zwei Kameras aus einer der Fahrersicht ähnlichen Perspektive erfasst. Kernpunkt des bis November 2021 laufenden Projekts HavenZuG (Förderlinie IHATEC des BMVI, [15]) ist die Erforschung von Ansätzen zur großflächigen, kontinuierlichen Erfassung des Zustands der Gleisinfrastruktur im Hafen Braunschweig im Hinblick auf den Zustand

der Schienen (insb. Schienenlängsprofil) sowie bestimmter Gleislageparameter (insb. Spurweite). Im Folgenden werden zwei unterschiedliche Ansätze zur Gewinnung von Zustandsinformationen aus den Messungen der fahrdynamischen Reaktionen vorgestellt.

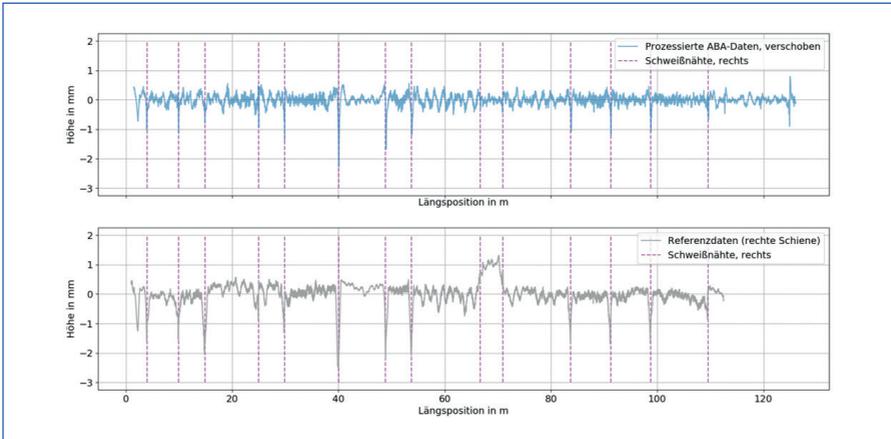
### 3.1 Schätzung des Schienenlängsprofils

Neben den oben beschriebenen Achslagerbeschleunigungen der Rangierlokomotive erfolgte im Hafen Braunschweig eine umfassende Erhebung von Zustandsinformationen zum Schienenlängsprofil und zur Gleisgeometrie mit etablierten Trolley-Messsystemen. Auf Basis von Messungen des tatsächlichen Schienenlängsprofils sowie einer systematischen Zustandserhebung durch Gleisbegehungen konnte ein Ansatz zur Ableitung des Schienenlängsprofils aus Achslagerbeschleunigungsdaten entwickelt werden [14], der im Folgenden vorgestellt wird.

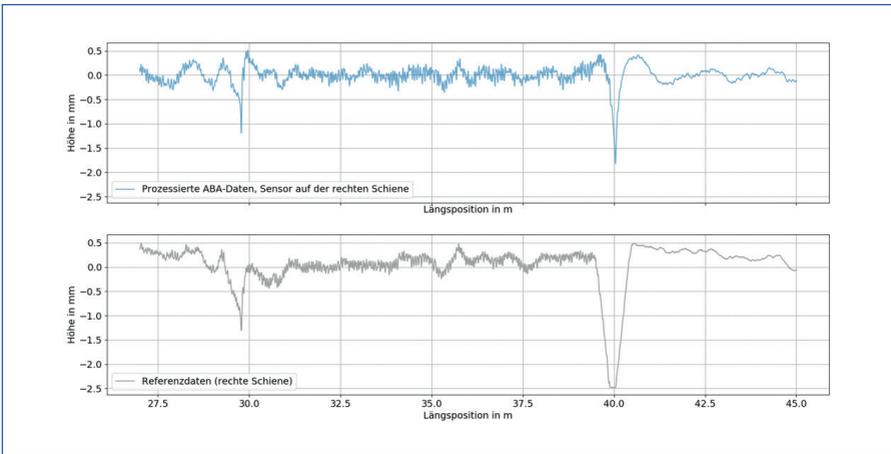
Für die Ableitung des Schienenlängsprofils wurde die vertikale Komponente der erfassten Achslagerbeschleunigungen genutzt. Der dafür gewählte und in diesem Anwendungsfall vielversprechende Ansatz ist die Prozessierung der Beschleunigungsdaten durch doppelte Integration. Dieser Ansatz wird beispielsweise auf Vollbahnen schon seit Längerem genutzt, um präzise Abschätzungen für die Gleisgeometrie (Längshöhe) zu erhalten (z.B. [16]). Aufgrund der geringeren Geschwindigkeiten (unter 7 m/s) im Rangierverkehr lässt sich dieser Ansatz erfolgreich auf die Erfassung des Schienenlängsprofils übertragen.

Um die Sensordaten in Verbindung mit den befahrenen Gleispositionen zu bringen, werden diese in einem ersten Schritt im Zuge einer kartengestützten Multi-Sensor-Fusion [13] von GNSS-Positionen, Fahrzeuggeschwindigkeit und Inertialmessungen georeferenziert und erhalten dabei sowohl geographische Koordinaten als auch Gleisidentifikations- und Längspositionsinformationen. Nach einer geeigneten Vorprozessierung wird eine doppelte Integration durchgeführt. Um variable Abweichungen in den Positions- und Geschwindigkeitsschätzungen zu kompensieren, werden die Daten im Nachgang im Distanzbereich mit den Referenzdaten synchronisiert. Das so erhaltene Längsprofil stellt bereits eine gute Näherung an das tatsächliche Längsprofil dar. Insbesondere Schweißnähte sind in der Regel klar zu erkennen (Abb. 3) und können aus dem abgeleiteten Längsprofil detektiert werden. Die erhaltenen Höhenunterschiede sind dabei nicht exakt abgebildet, jedoch in der Größenordnung der tatsächlichen Tiefen der Schweißnähte.

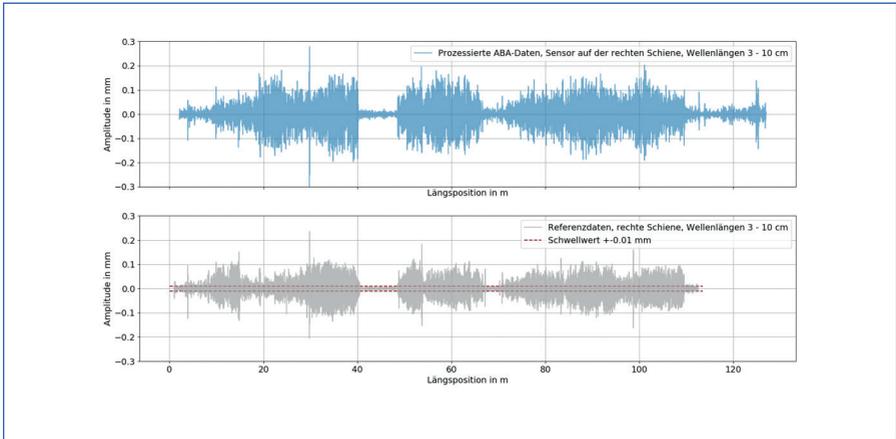
Das Längsprofil wird insbesondere zur Erkennung und Bewertung von Oberflächenfehlern verschiedener Wellenlängen verwendet. Das Gleis, dessen Längsprofil auf Abb. 3 zu sehen ist, ist in verschiedenen Bereichen stark von Riffeln betroffen. Die Riffel, im Längsprofil als periodisches Muster erkennbar (Abb. 4), sind auch aus den



**Abb. 3:** Längsprofil der rechten Schiene eines Gleises im Braunschweiger Hafen. 1) Abgeleitetes Längsprofil aus den Achslagerbeschleunigungsdaten nach Korrektur der Positionsinformation (oben) und 2) Gemessenes Längsprofil, Referenzdaten (unten). Vertikale, gestrichelte Linien markieren Schweißnähte, die bei einer visuellen Begehung protokolliert wurden.



**Abb. 4:** Durch doppelte Integration aus den vertikalen Achslagerbeschleunigungen abgeleitetes Längsprofil (oben) und gemessenes Längsprofil (unten) auf einem Teilstück eines Gleises im Braunschweiger Hafen. Durch Schweißungen klar begrenzte Abschnitte des Gleises weisen Riffel auf (z. B. bis Position 40 m, ab Position 49 m). Dies ist sowohl in den Referenzdaten als auch aus den Achslagerbeschleunigungsdaten klar zu erkennen.



**Abb. 5:** Unten: Längsprofil für den Wellenlängenbereich von 3 – 10 cm (Referenzdaten) der rechten Schiene des betrachteten Gleises. Der Schwellwert für diesen Wellenlängenbereich beträgt 0,01 mm (gestrichelte Linien). Oben: Entsprechendes Längsprofil aus Achslagerbeschleunigungen

verarbeiteten Sensordaten detektierbar. Abb. 4 zeigt eine Nahaufnahme des Längsprofils für einen Ausschnitt, auf dem ein Bereich mit Riffeln an einen Bereich ohne Riffel angrenzt.

Durch Filtern des Profils auf den entsprechenden Wellenlängenbereich (beispielsweise 3-10 cm) und Vergleich der Absolutwerte der Amplituden mit Schwellwerten kann eine Einteilung in verriffelte und intakte Bereiche vorgenommen werden. Ein mögliches Beurteilungsschema, welches beispielsweise von der Deutschen Bahn AG (DB) (Konzernrichtlinie 824) verwendet wird, besteht darin, Gleisabschnitte einer definierten Länge dann als fehlerhaft einzuordnen, wenn der Anteil der Absolutwerte der Amplituden für den betrachteten Wellenlängenbereich, die den (wellenlängenspezifischen) Schwellwert überschreiten, mehr als 5 % beträgt. Abb. 5 zeigt die Referenzdaten für das betrachtete Gleis und den Wellenlängenbereich 3 – 10 cm. Der Schwellwert für diesen Bereich liegt bei 0,01 mm. Wie auf Abb. 5 zu erkennen ist, gibt es auf dem gezeigten Gleis neben den verriffelten Bereichen zwei Abschnitte, die keine Riffel aufweisen.

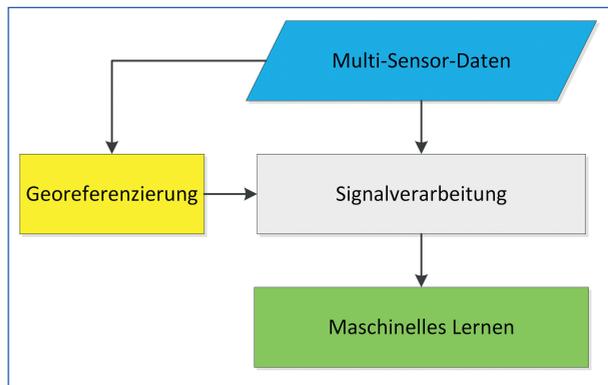
Um eine vergleichbare Beurteilung auf Basis der Achslagerbeschleunigungen zu erhalten, müssen die Schwellwerte, die für die Beschleunigungsdaten herangezogen werden, bestimmt werden. Dies kann durch die Maximierung der übereinstimmend durch Beschleunigungs- und Referenzdaten klassifizierten Abschnitte auf Basis weniger Fahrten erfolgen. Nach geeigneter Wahl des Schwellwerts ergibt sich so eine hohe Rate an korrekt identifizierten verriffelten Gleisabschnitten.

Nach ersten Erkenntnissen eignen sich der vorgestellte Ansatz und die Verwendung von im Rangier-Betrieb erfassten und entsprechend prozessierten Achslagerbeschleunigungsdaten als Näherung für das tatsächliche Schienenlängsprofil. Insbesondere können nach Anpassung von Schwellwerten diese Daten anhand weniger Fahrten auf wenigen verriffelten Gleisen für die Erkennung von Riffeln im gesamten Netzwerk genutzt werden.

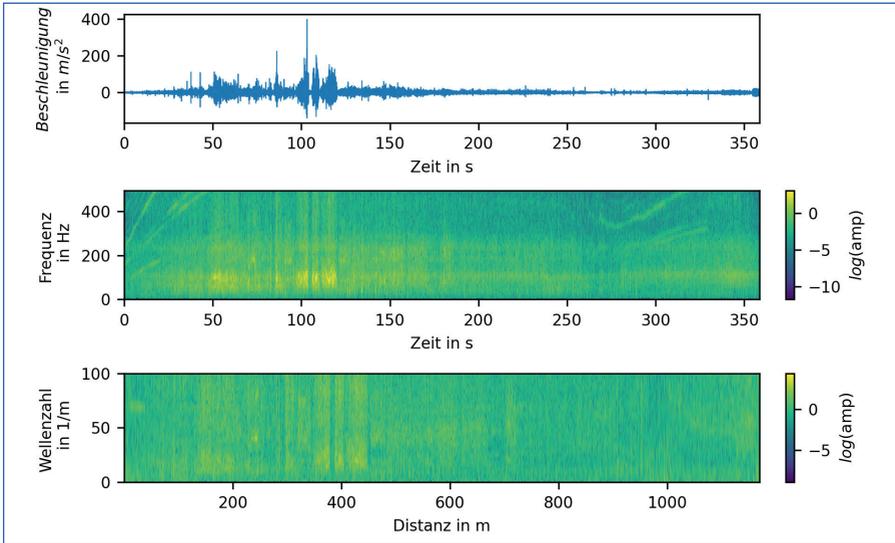
### 3.2 Unüberwachtes Lernen für die Kategorisierung von Schienenfehlern

Eine der Hauptaufgaben bei der Überwachung der Gleisinfrastruktur ist es, Auffälligkeiten zu erkennen und diese zu kategorisieren. Sind ausreichend Daten vorhanden, bieten sich für diese Aufgabe maschinelle Lernverfahren an. Hierbei steht man jedoch oftmals vor dem Problem, dass entsprechend annotierte Referenzdaten fehlen, sodass überwachte Lernverfahren wie oben in Abschnitt 2 beschrieben nicht zum Einsatz kommen können. Dem gegenüber stehen Methoden des unüberwachten Lernens (z. B. [17]). Diese Algorithmen erzeugen rein datenbasierte statistische Modelle, die es ermöglichen, Muster, Kategorien und Zusammenhänge in Daten zu erkennen, ohne dabei auf annotierte (gelabelte) Daten angewiesen zu sein. Prominente Vertreter solcher Methoden sind Clustering-Verfahren, die Daten in mehrere Kategorien einteilen, die sich durch charakteristische Muster voneinander unterscheiden. Weitere Verfahren zielen darauf ab, die beobachteten Daten in eine einfachere Repräsentation zu übersetzen, ohne dabei relevante Informationen zu verlieren. Zu diesen Methoden zählt das sogenannte „sparse dictionary learning“, welches hier exemplarisch verwendet wurde. Ziel ist es, charakteristische Wellenlängenbereiche aus den Daten zu extrahieren und etwaige Schienenfehler nach diesen zu kategorisieren.

Eine vereinfachte Darstellung der Datenprozessungskette ist in Abb. 6 dargestellt. Ausgangspunkt sind die gemessenen Achslagerbeschleunigungsdaten sowie IMU- und GNSS-Daten, die die Grundlage für die Georeferenzierung bilden. Im Signal-



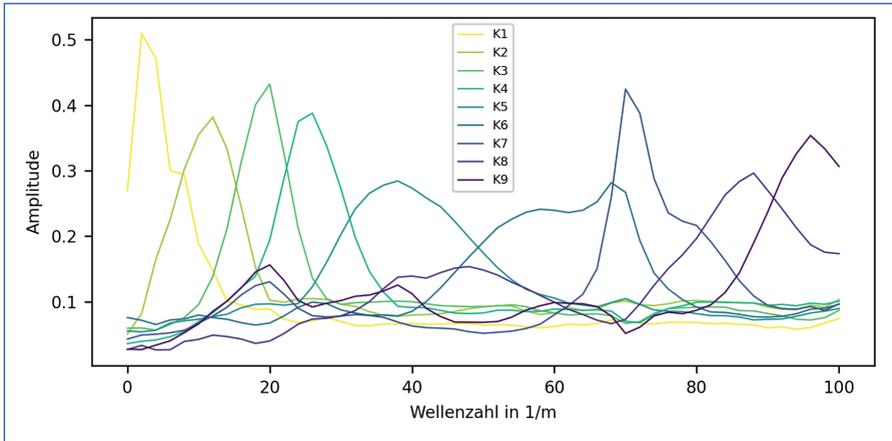
**Abb. 6:** Signalverarbeitungsschritte für die Kategorisierung von Schienenzuständen



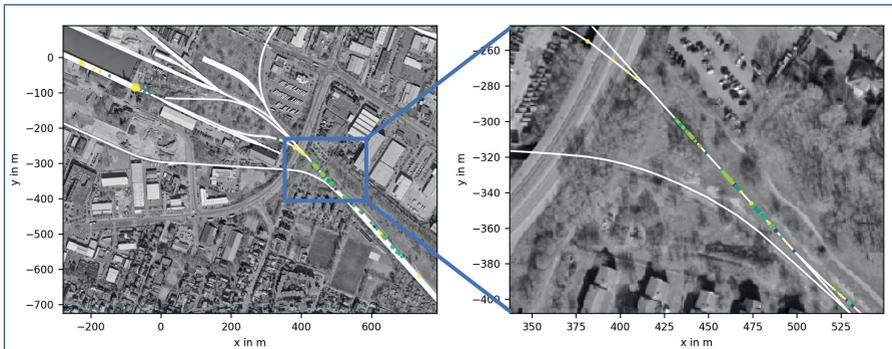
**Abb. 7:** (von oben nach unten): i) Unbearbeitete Zeitreihe der vertikalen Achslagerbeschleunigungsdaten; ii) Zeit-Frequenz-Darstellung der Achslagerbeschleunigungsdaten; iii) Wellenzahl-Distanz-Darstellung der Achslagerbeschleunigungsdaten

vorverarbeitungsschritt werden die Achslagerbeschleunigungsdaten zuerst in eine Zeit-Frequenz-Darstellung und von dort aus mithilfe der aus der Georeferenzierung gewonnenen Zuggeschwindigkeiten in eine Distanz-Wellenzahl-Darstellung überführt (Abb. 7). Anschließend wird ein sogenannter „Dictionary“ anhand dieser Wellenzahlspektren trainiert. Ziel ist es, eine Linearkombination von möglichst wenig charakteristischen Spektren zu finden, die die Eingangssignale möglichst genau wiedergeben.

In Abb. 8 ist ein trainierter „Dictionary“ bestehend aus neun Komponenten dargestellt. Jede Komponente beschreibt ein charakteristisches Wellenzahlspektrum, das häufig in den Daten angetroffen werden konnte. Die Gewichte dieser Komponenten bilden den sogenannten Kode und beschreiben, welche Komponenten wo und wie stark auftreten. Sie sind somit die charakteristischen Merkmale, die für weitere Analysen genutzt werden können. So können z.B. Auffälligkeiten am Gleis nach ihrem dominierenden Wellenzahl- bzw. Wellenlängenbereich kategorisiert und mithilfe der Georeferenzierung auf dem Gleis verortet werden. Der in Abb. 9 (rechts) dargestellte Streckenabschnitt weist bekannte Verriffelungen auf (siehe auch Abb. 4 und 5). Diese werden hauptsächlich durch die Komponenten K2-K4 wiedergegeben, welche in etwa einem Wellenlängenbereich von 30-100 mm entsprechen.



**Abb. 8:** Komponenten des trainierten Dictionary. Jede Kurve spiegelt einen charakteristischen Wellenlängenbereich wider.



**Abb. 9:** Gleisauffälligkeiten von einer Fahrt kategorisiert in verschiedene Wellenzahlkomponenten, die Farbe der Punkte entspricht den jeweiligen Komponenten des Dictionary (entsprechend Abb. 8), die Größe der Kreise entspricht der Stärke der Anomalie.

Der Vorteil der hier verwendeten Dictionary-Learning-Methode gegenüber anderen Merkmalsextraktionsverfahren ist die einfache Interpretierbarkeit. Die Komponenten des Dictionarys haben eine physikalische Entsprechung in dem Wellenzahl- bzw. Wellenlängenbereich, den sie abdecken, und der dazugehörige Code gibt die Wichtung der einzelnen Komponenten pro Datenssegment wieder. Die extrahierten Merkmale beschreiben also die Stärke des Signals in einem bestimmten Wellenlängenbereich. Anstatt diese Wellenlängenbereiche manuell und starr festzulegen, werden diese aus den Daten automatisch extrahiert. Unregelmäßigkeiten im Schie-

nenlängsprofil lassen sich somit in bestimmte Wellenlängenbereiche kategorisieren, die charakteristisch für das jeweilige Streckennetz sind. Die identifizierten und kategorisierten Unregelmäßigkeiten müssen dann im besten Fall nur noch exemplarisch manuell inspiziert werden. Dies würde den erforderlichen Inspektionsaufwand drastisch reduzieren.

## 4 Zusammenfassung

Die Erfassung der fahrdynamischen Reaktionen auf regulär verkehrenden Schienenfahrzeugen bietet insbesondere für die Betreiber kleinerer Schienennetze wie z. B. Straßenbahnen oder Industriebahnen großes Potenzial für eine kosteneffiziente und effektive Zustandsüberwachung der Infrastruktur. Für die Ausrüstung der Fahrzeuge stehen robuste und kostengünstige MEMS-Sensoren sowie entsprechende Messsysteme am Markt zur Verfügung. Große Herausforderungen bestehen nach wie vor bei der Gewinnung zuverlässiger und relevanter Informationen aus den erhobenen Datenmengen. Die große Dynamik und Variabilität der Achslagerbeschleunigungen in Abhängigkeit von zahlreichen Einflussfaktoren (Geschwindigkeit, Fahrzeugzustand, Streckenzustand, Umgebungsbedingungen etc.) stellen dabei hohe Anforderungen an die Datenanalyse. Aktuelle Lösungsansätze bestehen aus einer Kombination bewährter Techniken der Signalprozessierung für die Bestimmung relevanter Merkmale (Abschnitte 2.2.1 und 3.1) mit modernen maschinellen Lernverfahren (Abschnitte 2.2.2 und 3.2). Bezüglich der maschinellen Lernverfahren werden zwei grundlegende Ansätze verfolgt. Beim überwachten Lernen können anhand vorhandener Trainingsdaten (z. B. aus Inspektionsdaten oder Streckenbegehungsprotokollen) direkt Zustandsklassen für bestimmte Fehlzustände aus den fahrdynamischen Reaktionen abgeleitet werden (Abschnitt 2). Für die Erkennung ungewöhnlicher Fehlzustände oder bei fehlenden Trainingsdaten kommen unüberwachte maschinelle Lernverfahren zum Einsatz (Abschnitt 3.2). Diese Ansätze erlauben die Erkennung auffälliger und inspektionswürdiger Streckenabschnitte ohne jegliche Vorkenntnis alleine aus den erhobenen Sensormessdaten und können auch plötzlich eintretende Zustandsveränderungen (z. B. Schienenbrüche) aufdecken.

Mit zunehmender Verbreitung entsprechender Überwachungssysteme in der Praxis wird die Menge verfügbarer Daten rasch zunehmen. Um die Potenziale moderner KI-Verfahren voll auszuschöpfen sowie die Qualität und Aussagekraft der gewonnenen Informationen verbessern zu können, sind geeignete Trainingsdaten essenziell. Die gezielte Erzeugung und Bereitstellung entsprechender Datenbeispiele aus verschiedenen Einsatzszenarien wird in den kommenden Jahren entscheidend sein, um die Robustheit und Alltagstauglichkeit der vorhandenen Ansätze weiter zu verbessern.

## Quellen

- [1] Han, J.; Xiao, X.; Wu, Y.; Wen, Z.; Zhao, G.: Effect of rail corrugation on metro interior noise and its control. In: *Applied Acoustics* 130 (2018), S. 63–70. URL <https://www.sciencedirect.com/science/article/pii/S0003682X17307119>
- [2] Kouroussis, G.; Pauwels, N.; Brux, P.; Conti, C.; Verlinden, O.: A numerical analysis of the influence of tram characteristics and rail profile on railway traffic ground-borne noise and vibration in the Brussels Region. In: *Science of The Total Environment* 482-483 (2014), S. 452–460. URL <https://www.sciencedirect.com/science/article/pii/S0048969713006347>
- [3] Fiala, P.; Degrande, G.; Augusztnovicz, F.: Numerical modelling of ground-borne noise and vibration in buildings due to surface rail traffic. In: *Journal of Sound and Vibration* 301 (2007), Nr. 3, S. 718–738. URL <https://www.sciencedirect.com/science/article/pii/S0022460X06008194>
- [4] Oberhauser, A.; Fischmeister, E.; Ossberger, M.; Ömer, B.; Mittermayr, P.; Schürz, J.; Miltner, K.: Aktuelle wissenschaftliche Erkenntnisse aus fünf Jahren Betrieb von Gleismesswagen im urbanen Nahverkehr. In: Tagungsband 10. Internationale Schienenfahrzeugtagung, 2009, S. 4
- [5] Ömer, B.: CUBAL – Krümmungsbasierte Verortung von Gleismessdaten in Urbanen Schienennetzen. In: *ÖVG Spezial - Prozessautomatisiertes zustandsbasiertes Instandhaltungsmanagement des Rad-Schiene-Systems* 72 (2006), S. 40–43
- [6] Wehr, R.; Fuchs, A.; Wehr, W.: Akustische Zustandsbewertung von Gleisen im Straßenbahnnetz. In: Tagungsband DAGA 2017 - 43. Jahrestagung für Akustik, 2017, S. 4
- [7] Alten, K.; Fuchs, A.; Wehr, W.; Wehr, R.: Vibroakustische Überwachung des Schienenzustandes durch Regelfahrzeuge im Straßenbahnnetz. In: *e & i Elektrotechnik und Informationstechnik* volume 138 (2021), Nr. 1, S. 190–196
- [8] ZeroMQ Open-source universal messaging library
- [9] Othman, Y. B.: *Kurvenquietschen: Untersuchung des Quietschvorgangs und Wege der Minderung*. Fakultät für Verkehrs- und Maschinensysteme, TU Berlin, 2009
- [10] Liu, X.; Meehan, P. A.: Investigation of the effect of relative humidity on lateral force in rolling contact and curve squeal. In: *Wear* 310 (2014), Nr. 1, S. 12–19. URL <https://www.sciencedirect.com/science/article/pii/S0043164813005899>
- [11] Baasch, B.; Heusel, J.; Groos, J.; Shankar, S.: Eingebettete Zustandsüberwachung der Gleisinfrastruktur: Entwicklung und Erprobung von eingebetteten Multi-Sensor-Systemen für die kontinuierliche Zustandsüberwachung der Gleisinfrastruktur im operativen Betrieb. In: *El - DER EISENBÄHNINGENIEUR* 12/2019, S. 6–8. URL <https://elib.dlr.de/129363/>
- [12] Groos, J. C.; Roth, M.; Havrila, P.: Zustandsüberwachung mit kostengünstigen Multi-Sensor-Systemen. In: *El - DER EISENBÄHNINGENIEUR*, 10/2017 S. 41–45
- [13] Roth, M.; Baasch, B.; Havrila, P.; Groos, J. C.: Map-Supported Positioning Enables In-Service Condition Monitoring of Railway Tracks. In: *International Conference on Information Fusion (FUSION)*, 2018, S. 2346–2353
- [14] 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: *17th International Conference on Condition Monitoring and Asset Management*, 14-18 June 2021, London
- [15] BMVI: Förderlinie Innovative Hafentechnologien (IHATEC). URL <https://www.innovativehafentechnologien.de/>. – Aktualisierungsdatum: 2021-07-02
- [16] Wolter, K. U.; Erhard, F.; Gabler, H.; Hempe, T.: Fahrzeugseitige Überwachung der Infrastruktur im Regelbetrieb: Kontinuierlich inspizieren – Instandsetzung gezielt planen – Qualität und Nachhaltigkeit prüfen. In: *Eisenbahntechnische Rundschau* 7+8/2014, S. 32–36
- [17] Niebling, J.; Baasch, B.; Kruspe, A.: Analysis of Railway Track Irregularities with Convolutional Autoencoders and Clustering Algorithms, Bd. 1279. In: Bernardi, S.; Vittorini, V.; Flammini, F.; Nardone, R.; Marrone, S.; Adler, R.; Schneider, D.; Schleiß, P.; Nostro, N.; Lövenstein Olsen, R.; Di Salle, A.; Masci, P. (Hrsg.): *Dependable Computing - EDCC 2020 Workshops*. Cham : Springer International Publishing, 2020 (Communications in Computer and Information Science), S. 78–89



**Mag. Karoline Alten**

Projektleiterin  
Center for Low-Emission Transport  
AIT Austrian Institute of Technology GmbH, AT-Wien  
karoline.alten@ait.ac.at



**DI Andreas Fuchs**

Wissenschaftlicher Mitarbeiter  
Center for Low-Emission Transport  
AIT Austrian Institute of Technology GmbH, AT-Wien  
andreas.fuchs@ait.ac.at



**DI Jan Struhar**

Wissenschaftlicher Mitarbeiter  
Center for Low-Emission Transport  
AIT Austrian Institute of Technology GmbH, AT-Wien  
jan.struhar@ait.ac.at



**Dr. Benjamin Baasch**

Wissenschaftlicher Mitarbeiter  
Institut für Verkehrssystemtechnik  
Deutsches Zentrum für Luft- und Raumfahrt DLR e.V., Braunschweig  
benjamin.baasch@dlr.de



**Dr. Judith Heusel**

Wissenschaftliche Mitarbeiterin  
Institut für Verkehrssystemtechnik  
Deutsches Zentrum für Luft- und Raumfahrt DLR e.V., Braunschweig  
judith.heusel@dlr.de



**Dr. Jörn C. Groos**

Gruppenleiter Asset Monitoring und Management  
Institut für Verkehrssystemtechnik  
Deutsches Zentrum für Luft- und Raumfahrt DLR e.V., Braunschweig  
joern.groos@dlr.de