

Erkennung typischer Gleisfehler durch Trägheitsmessungen an einem Modell

In bisherigen Ansätzen wurden Gleisfehler nur anhand von Vertikalbeschleunigungen erkannt und nun wird angestrebt, diesen Ansatz mit Gyro Winkelgeschwindigkeiten zu ergänzen, um die Erkennungsrate von Gleisfehlern im frühen Zustand, insbesondere bei punktuellen Instabilitäten signifikant zu erhöhen, da dies in der Praxis gegenwärtig noch als besondere Herausforderung zu betrachten ist.



In der Vergangenheit wurden bereits verschiedene Methoden und Messsysteme eingesetzt, um den Zustand der Gleise zu bewerten, und um zu verhindern, dass der Bahnbetrieb durch Infrastrukturmängel unterbrochen wird oder es im schlimmsten Fall zu Unfällen aufgrund verschiedener typischer Gleisfehler kommt. Eine angemessene Instandhaltung ist deshalb sehr wichtig; aber u.a. auch aufgrund der angestrebten hohen Belegung der Gleise im Regelbetrieb ist es schwierig, diese regelmäßig mit einer entsprechenden Häufigkeit durchzuführen, so dass man auf neue Methoden zurückgreifen muss.

Das Institut für Eisenbahn- und Verkehrswesen der Universität Stuttgart hat sich in den letzten Jahren mit diesem Thema beschäftigt und ein Fahrzeug-Fahrwegmodell im Maßstab 1:87 erstellt, das einen Zustand mit mehreren unterschiedlichen

Gleisfehlern in verschiedenen Zuständen simuliert, die von einem Fahrzeug mit einer Sensorik zur Messung der Vertikalbeschleunigungen überfahren werden. Mit diesem Modell führt man bereits vielfältige Untersuchungen durch, z. B. [1], [2], [5]. In diesen früheren Untersuchungen wurden Vertikalbeschleunigungen analysiert, was zwar die erfolgreiche Erkennung von installierten Gleisfehlern, hauptsächlich punktuellen Instabilitäten, ermöglichte, aber die Genauigkeit zur Erkennung dieser Gleisfehler im frühen Zustand, war noch eingeschränkt.

In diesem Artikel wird eine Weiterentwicklung der Methodik [6] beschrieben, die sowohl die Beschleunigungen in drei Achsen als auch die Gyro Winkelgeschwindigkeiten berücksichtigt, wodurch zusätzliche wertvolle Informationen gewonnen werden, deren Analyse die Gleisfehlererkennung aufbauend auf [5] bzw. [2] mit Hilfe



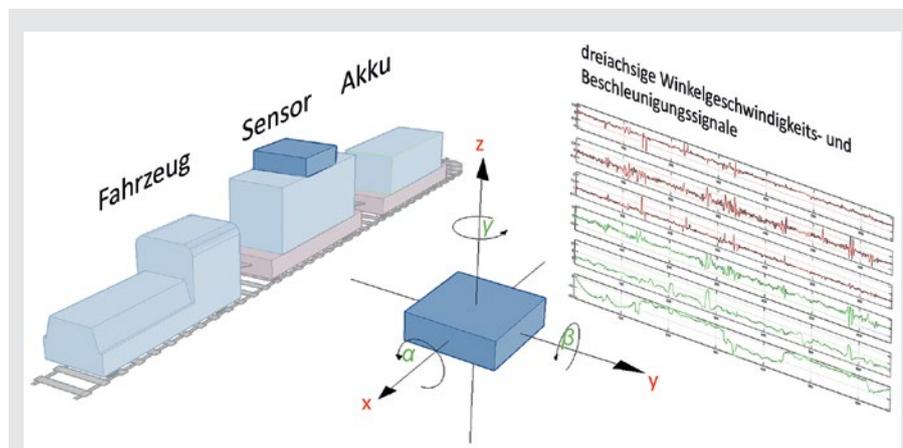
Sebastian Bahamon-Blanco, M.Sc.
Akademischer Mitarbeiter am Institut für Eisenbahn- und Verkehrswesen, Universität Stuttgart
bahamonsebastian@hotmail.com



Xiaoyue Chen, M.Sc.
Akademische Mitarbeiterin am Institut für Eisenbahn- und Verkehrswesen, Universität Stuttgart
xiaoyue.chen@ievwwi.uni-stuttgart.de



Prof. Dr.-Ing. Ullrich Martin
Direktor des Instituts für Eisenbahn- und Verkehrswesen, Universität Stuttgart
ullrich.martin@ievwwi.uni-stuttgart.de



1: Darstellung der fahrzeugintegrierten Messeinrichtung

Quelle: eigene Darstellung

einer kontinuierlichen Wavelet-Transformation und eines Bagged Trees Algorithmus signifikant verbessern.

Messsystem

Zur Messung von Beschleunigungen und Gyro Winkelgeschwindigkeiten wurde eine fahrzeugintegrierte Messeinrichtung [7] gebaut, die Beschleunigungen und Gyro Winkelgeschwindigkeiten triaxial gleichzeitig erfassen kann, um die gleiche Anzahl von Messpunkten zu gewährleisten.

Das Fahrzeug mit der in Bild 1 dargestellten Messeinrichtung erfasst die in Bild 2 gekennzeichneten 16 modellierten

Gleisfehler (vgl. auch Tabelle 1), darunter zwei punktuelle Instabilitäten im frühen Zustand und eine im finalen Zustand.

Beim Befahren des Modells können bei jeder Runde die Werte von sechs triaxialen Signalen, wie in Bild 3 dargestellt, für jeden der 16 Gleisfehler aufgezeichnet werden:

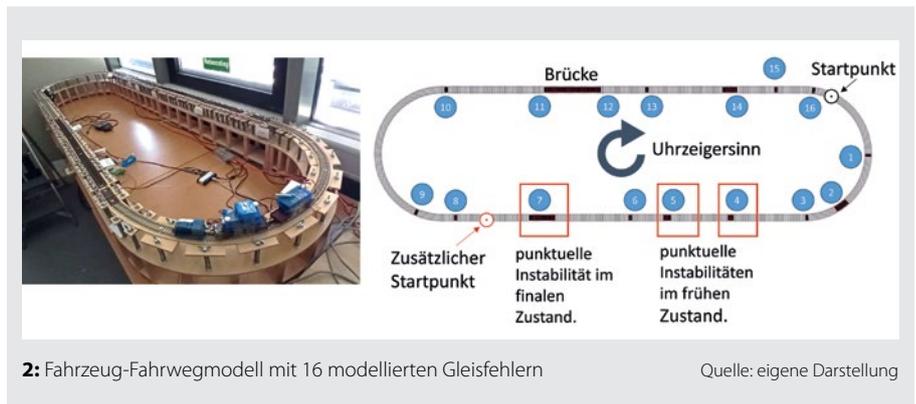
In diesem Bild ist deutlich zu sehen, dass die Gyro-Signale drei Spitzen genau dort aufweisen, wo die punktuellen Instabilitäten zu erwarten sind. Der Zustand dieser Instabilitäten wirkt sich eindeutig auf die Amplitude des Messwertes aus, so dass die Gleisfehler der Positionen 4 und 5 (punktuelle Instabilitäten im frühen Zustand) eine signifikant kleinere Amplitude als der Gleisfehler der Position 7 (punktuelle Instabilität im finalen Zustand) aufweisen.

Kontinuierliche Wavelet-Transformation

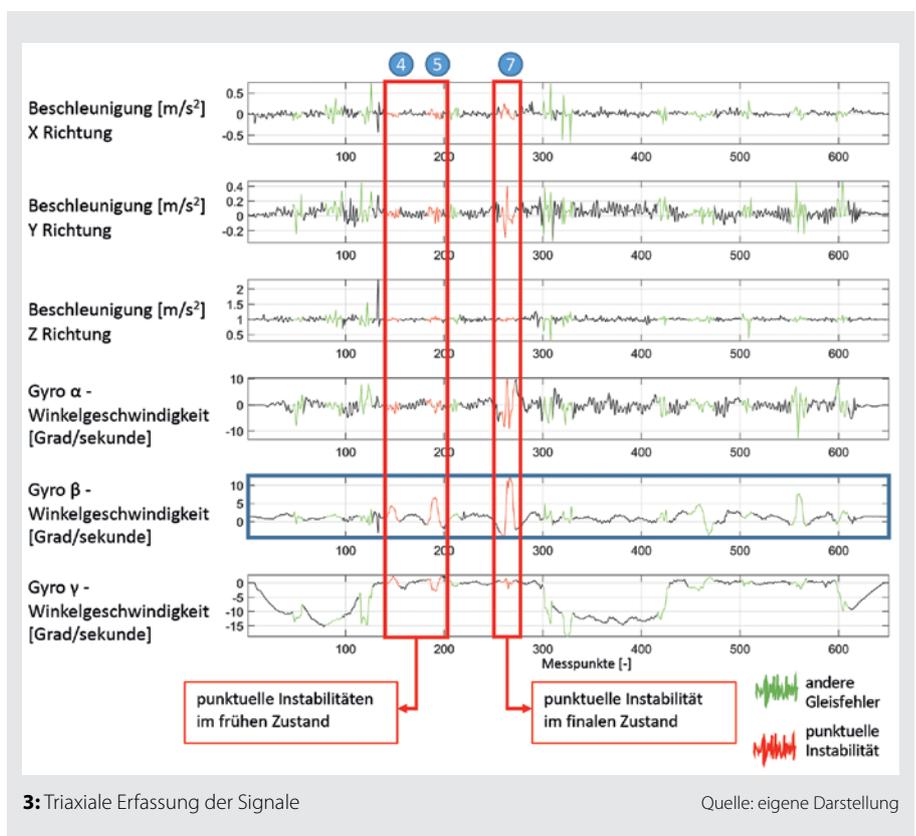
Da die Gyro β -Winkelgeschwindigkeit die bisher repräsentativsten Messwerte, insbesondere auch im Vergleich zu der bislang verwendeten Vertikalbeschleunigung, liefert, wird dieser Messwert primär für die weitere Analyse mit einer kontinuierlichen Wavelet-Transformation verwendet. Zu diesem Zweck wurden zunächst die Muster der punktuellen Instabilitäten analysiert.

Aufgrund der Form des Musters der aus den Messwerten für punktuelle Instabilitäten entstehenden Kurven (Bild 4) bietet sich an, für die kontinuierliche Wavelet-Transformation ein sog. Mexikanischer Hut Wavelet [3] zu nutzen.

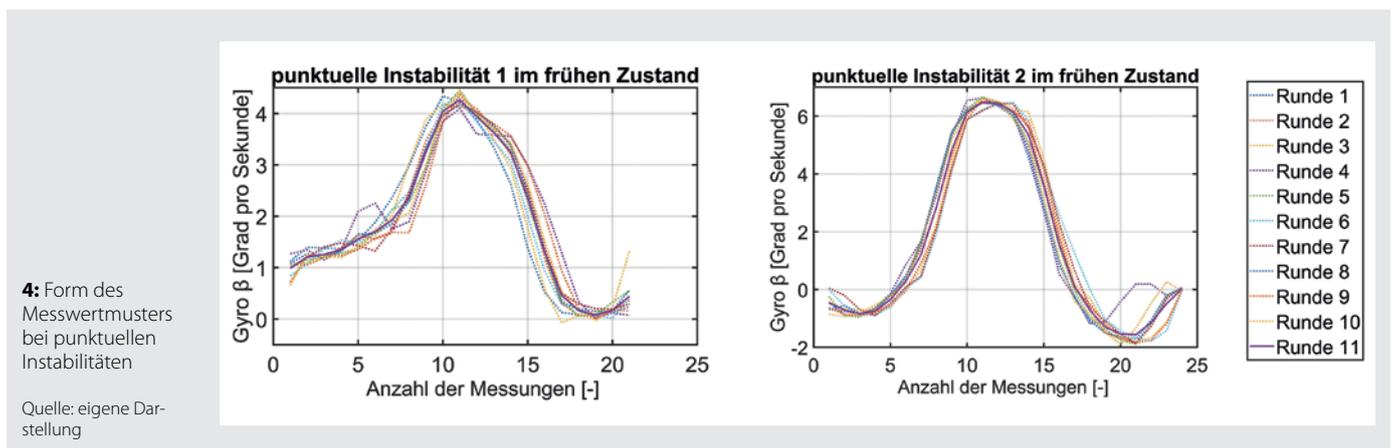
Die kontinuierliche Wavelet-Transformation (CWT) ist ein Werkzeug, das eine überproportionale Darstellung eines Signals ermöglicht, indem die Translations- und Skalierungsparameter des Wavelets



2: Fahrzeug-Fahrgewegmodell mit 16 modellierten Gleisfehlern Quelle: eigene Darstellung



3: Triaxiale Erfassung der Signale Quelle: eigene Darstellung



4: Form des Messwertmusters bei punktuellen Instabilitäten

Quelle: eigene Darstellung

Homepageveröffentlichung unbefristet genehmigt für Universität Stuttgart / Rechte für einzelne Downloads und Ausdrücke für Besucher der Seiten genehmigt / © DVV Media Group GmbH

kontinuierlich variiert werden [4]. In Bild 5 wird die Variation des CWT-Koeffizienten in Bezug auf die Verschiebung der x-Achse und den Skalierungsfaktor des Wavelets σ (y-Achse) dargestellt. Die CWT wird mit der Mexikanischen Hut Waveletfunktion ψ erzeugt, bei der x die Anzahl der Messungen und σ den Skalierungsfaktor des Wavelets repräsentieren:

$$\psi(x) = \frac{2}{\sqrt{3\sigma\pi}^{1/4}} \left(1 - \left(\frac{x}{\sigma}\right)^2 e^{-\frac{x^2}{2\sigma^2}} \right)$$

Die höchsten Werte kennzeichnen eine Ähnlichkeit mit dem Mutter-Wavelet, so dass sich die Position und die Häufigkeit

identifizieren lassen, in der die punktuellen Instabilitäten gefunden wurden.

Bagged Trees Algorithmus

Aus zurückliegenden Untersuchungen [5] ist bereits bekannt, dass die Auswertung mit einer Wavelet-Transformation zwar praktikable Ergebnisse liefert, bei der Genauigkeit der Erkennung von Gleisfehlern bzw. dem Grad von deren Erkennung durchaus noch ein erschließbares Verbesserungspotenzial vorhanden ist. Deshalb wurde der Modellansatz KI-basiert (KI – Künstliche Intelligenz) mit einem Bagged Trees Algorithmus erweitert [2]. Nach der Erfassung der Mess-

Tabelle 2: Erkennung unterschiedlicher Gleisfehler
Quelle: eigene Darstellung

Gleisfehler	Erkennung (%)
Schienenstoß	76,2
Schienenbruch	77,6
periodischer Längshöhenfehler	73,7
punktueller Instabilität im frühen Zustand 1	84,8
punktueller Instabilität im frühen Zustand 2	82,8
punktueller Instabilität im finalen Zustand	86,4
Brücke	88,4
Gleislagefehler	90,5

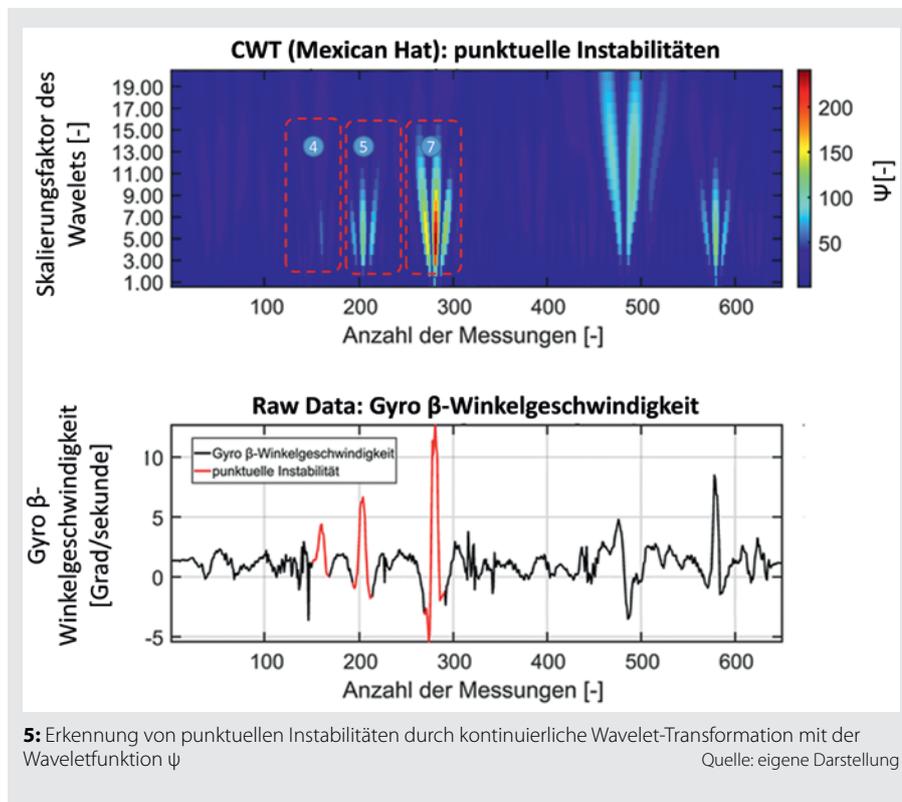


Tabelle 1: Klassifizierung der Gleisfehler zur Beschreibung für überwachtes Lernen; Quelle: eigene Darstellung

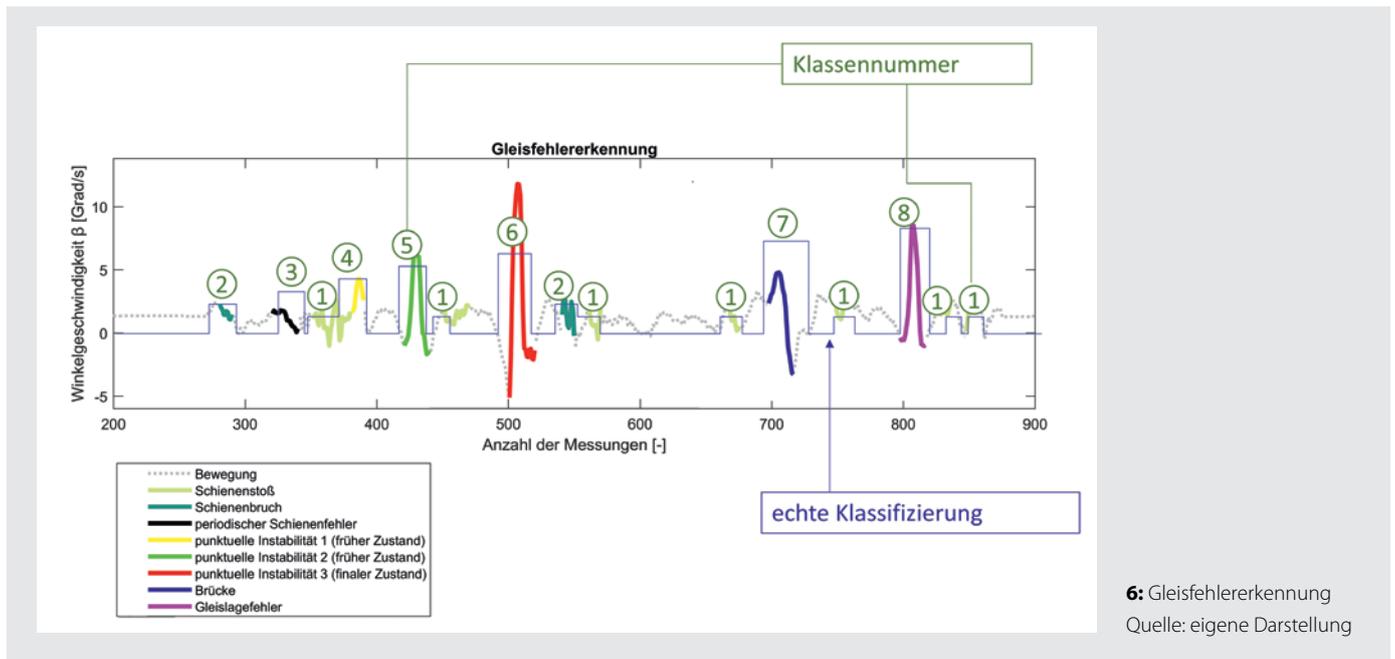
Klassennummer	Klassenname	Position des Gleisfehlers wie in Bild 2 dargestellt
0	Bewegung	-
1	Schienenstoß	3, 6, 9, 10, 13, 15, 16
2	Schienenbruch	1,8
3	periodischer Schienenfehler	2
4	punktueller Instabilität 1 (früher Zustand)	4
5	punktueller Instabilität 2 (früher Zustand)	5
6	punktueller Instabilität 3 (finaler Zustand)	7
7	Brücke	11,12
8	Gleislagefehler	14

werte aus 40 Runden im Fahrzeug-Fahrwegmodell wurden verschiedene statistische Merkmale der Gyro-Messwerte extrahiert (z.B. mit einer Principal component analysis, Spectral Power Features und Spectral Peaks, wie bereits auch in vorhergehenden Untersuchungen verwendet [2]). Zusätzlich wurde eine überwachte Klassifizierung unter Berücksichtigung der Klassifizierung in Tabelle 1 angewendet.

Auf der Grundlage des erstellten Bagged Trees Modells wurden neue Messungen klassifiziert, für die die im Fahrzeug-Fahrwegmodell gemessenen Gyro β -Winkelgeschwindigkeiten zugeordnet wurden. Das Bagged Trees Modell ist in der Lage, erfasste Signale erfolgreich zu klassifizieren, grafisch darzustellen und gemäß der vom KI-Modell zugewiesenen Klassifikationsnummer mit einer unverwechselbaren Farbe zu markieren (Bild 6). Zusätzlich wird dieses Ergebnis mit der tatsächlichen Klassifizierung der Realität (hier im Fahrzeug-Fahrwegmodell, vgl. Bild 2) verglichen, um festzustellen, wie genau die Gleisfehlererkennung ist.

In Bild 6 stimmt die tatsächliche Klassifizierung größtenteils mit den farbigen Abschnitten überein, und bei der Analyse von 219 Runden im Fahrzeug-Fahrwegmodell konnte das Bagged Trees-Modell verschiedene Gleisfehler erkennen:

Die Gleisfehler Schienenstoß, Schienenbruch und periodische Schienenfehler werden mit einer entsprechenden Erfolgswahrscheinlichkeit von 76,2, 77,6 bzw. 73,7% erkannt; diese Werte sind niedriger als die Erkennungswerte der anderen Gleisfehler, da, wie auch in Bild 3 gezeigt, die Gyro β -Winkelgeschwindigkeitsmuster für diese Gleisfehler nicht so eindeutig sind



und in diesem Fall die Beschleunigungen höhere Erkennungswerte ermöglichen.

Die Verwendung der drei Gyro Winkelgeschwindigkeiten als Eingangsparameter für die Analyse führte zu einer Erkennungsrate für punktuelle Instabilitäten sowohl im frühen – als auch im finalen Zustand zwischen 82,8 und 86,4%. Zudem konnte auf der Grundlage der Gyro β -Winkelgeschwindigkeit der Übergang im Brückenbereich mit einer Wahrscheinlichkeit von ca. 90% korrekt erkannt werden. Die hohen Erkennungswerte der Gleisfehler punktuelle Instabilitäten, Brücke und Gleislagefehler sind hauptsächlich auf die signifikante Zunahme der Gyro β -Winkelgeschwindigkeit zurückzuführen, die durch das Bagged Trees Modell sehr gut erkannt werden können.

Zusammenfassung

Dieser Artikel zeigt, dass die ergänzende Einbeziehung von Gyro-Messwerten zur Erkennung von Gleisfehlern wertvolle zusätzliche Informationen zur Erkennung nicht nur von punktuellen Instabilitäten im frühen Zustand liefern.

Nachdem festgestellt wurde, dass mit der Gyro β -Winkelgeschwindigkeit punktuelle Instabilitäten erheblich häufiger korrekt erkannt werden können, wurde eine kontinuierliche Wavelet-Transformation (CWT) mit einem Mexikanischen Hut Wavelet implementiert. Das damit generierte Spektrogramm ermöglicht eine sehr

hohe Erkennungsgenauigkeit für punktuelle Instabilitäten selbst in unterschiedlichen Zuständen.

Um den Grad der Erkennung von Gleisfehlern bzw. die Genauigkeit von deren Erkennung weiter zu verbessern, wurde zusätzlich ein Bagged Trees Algorithmus genutzt, der eine hohe Wahrscheinlichkeit für die Erkennung der unterschiedlichen Gleisfehlertypen im hier genutzten Fahrzeug-Fahrwegmodell sicherstellt.

Es kann durchaus sinnvoll sein, unterschiedliche, auf die Spezifik der jeweiligen Gleisfehler abgestimmte Eingangsparameter (z. B. Gyro Winkelgeschwindigkeiten, Beschleunigungen) für die Analyse zu verwenden.

In einem weiteren Schritt ist vorgesehen, diese Messungen unter realen Bedingungen im Regelbetrieb durchzuführen, um typische Gleisfehler, insbesondere auch punktuelle Instabilitäten im frühen Zustand, unmittelbar praxisbezogen zu erkennen. •

Literatur

- [1] Bahamon-Blanco, Sebastian; Rapp, Sebastian; Zhang, Yi; Liu, Jing; Martin, Ullrich: Recognition of Track Defects through Measured Acceleration Using a Recurrent Neural Network. In: CMEM – International Journal of Computational Methods and Experimental Measurements, Vol. 8, No. 3 (2020) 270–280.
[2] Bahamon, Sebastian; Rapp, Sebastian; Rupp, Christian; Liu, Jing; Martin, Ullrich: Recognition of track defects through measured acceleration Part 1 & Part 2, 7th International Conference of EACEF (European Asian Civil Engineering Forum): Stuttgart, 2019.

[3] Misi, Michel; Misi, Yves; Oppenheim, Georges; Poggi, Jean-Michel: Wavelet Toolbox User's Guide © COPYRIGHT 1997–2004 by The MathWorks, Inc.

[4] Mohammady, Somayeh: Wavelet theory. London: IntechOpen, 2021. Print.

[5] Rapp, Sebastian; Martin, Ullrich; Strähle, Marius; Scheffbuch, Moritz: Track-vehicle scale model for evaluating local track defects detection methods. Transportation Geotechnics 19, 2019.

[6] Ronao, Ann Ronao; Cho, Sung-Bae: Deep Convolutional Neural Networks for Human Activity Recognition with Smartphone Sensors. International Conference on Neural Information Processing (ICONIP 2015), Tel IV, Seite. 46–53, 2015. Springer International Publishing Schweiz 2016.

[7] Sander, Klaus: Bedienungsanleitung Sensorsystem, Sander electronic, Januar 2021

[8] Xu, Jianfeng; Zhang, Yuanjian; Miao, Duoqian: Three-way confusion matrix for classification: A measure driven view. Information Sciences 507 (2020) 772–794.

Summary

Recognizing typical track defects using inertial measurements on a model

This article describes the implementation including both acceleration and Gyro angular velocities in order to identify track defects in the vehicle-road model of the Institute for Railway and Transportation Engineering at Stuttgart University. In order to recognize track defects, suitable measure values are determined by means of a continuing wavelet transformation and an ai based algorithm.