

Schienenseitige Detektion von Flachstellen an Straßenbahnrädern mittels Sensorarrays und Methoden des Maschinellen Lernens

Christoph Stammwitz, Jonas Egeler, Christine Huth

Möhler+Partner Ingenieure GmbH, 86153 Augsburg, E-Mail: christoph.stammwitz@mopa.de

Zielstellung

Flachstellen an Straßen- und Eisenbahnrädern stellen Defekte dar, die beim Abrollen zu einer erheblichen Lärmbelastigung und erhöhtem Verschleiß an Rad und Schiene führen. Im Rahmen einer Masterarbeit bei der Firma Möhler+Partner wurde auf Basis von Messdaten, die in Kooperation mit den Stadtwerken Augsburg erhoben wurden, ein Detektionsalgorithmus entwickelt, der diese Raddefekte mit hoher Zuverlässigkeit radgenau bestimmt.

Ausgangssituation

Bereits im Vorfeld hat die Möhler+Partner GmbH einen Machine-Learning-Algorithmus entwickelt, der auf Basis von akustischen Signalen eine zuverlässige Erkennung hörbarer Flachstellen ermöglicht [1]. Problematisch gestaltet sich dabei jedoch die genaue Bestimmung des betroffenen Rads. Die Lokalisierungsgenauigkeit ist auf etwa 1 s begrenzt.

Ein von Gabriel Krummenacher et al. [2] veröffentlichter Ansatz zur Flachstellendetektion nutzt die von Dehnungsmessstreifen (DMS) gemessene Kraft, die das Rad auf die Schiene verursacht. Die dadurch gemessenen Signale dienen als Grundlage für eine Auswertung über Maschinelles Lernen. Die Ergebnisse überzeugen, weshalb die Ansätze und Methoden für das eigene Forschungsvorhaben übernommen wurden.

Im Unterschied zu [2] werden jedoch zusätzlich noch Beschleunigungssignale der Schiene genutzt. Zudem lag der Fokus auf Flachstellenerkennung bei Straßenbahnen anstatt von Zügen.

Messungen und Datengrundlage

Der Messaufbau umfasste ein Array aus jeweils 3 DMS und Beschleunigungssensoren je Schiene, welche zwischen den Schienenschwellen positioniert waren. Die DMS wurden dabei auf dem Schienensteg und die Beschleunigungsaufnehmer auf dem Schienenfuß platziert. Die dadurch abgedeckte Schienenlänge betrug 2,1 m, welche den Radumfang von bis zu 1,9 m leicht übersteigt. Zusätzlich kamen Mikrofone zum Einsatz, um die Vorbeifahrten akustisch aufzuzeichnen. Diese Messsignale erhielten jedoch keine Verwendung im Detektionsalgorithmus, sondern wurden lediglich für die Messdatenauswertung bzw. das Labelling genutzt.

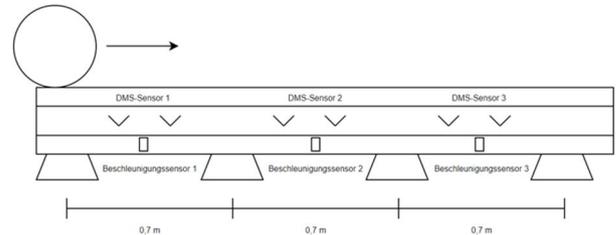


Abbildung 1: Messaufbau zur Flachstellenerkennung. Das Sensorarray deckt eine Radumdrehung ab und besteht aus zwischen den Schienenschwellen auf die Schiene angebrachten DMS und Beschleunigungsaufnehmern.

Nachteilig gestaltete sich die Auswertung der Messdaten. Für das Training eines ML-Algorithmus werden Labels benötigt, die den Datensatz in verschiedene Klassen einteilen, nach denen das Modell anschließend unterscheiden kann. In diesem Fall stellt dies das Attribut „Flachstelle“ bzw. „keine Flachstelle“ dar.

Ursprünglich war es angedacht, über die Instandhaltung der SWA genaue Informationen zum Radzustand auffälliger Straßenbahnen zu erhalten, als Grundwahrheit für das spätere Labelling des Trainingsdatensatzes. Dies gestaltete sich in der Praxis allerdings als äußerst schwierig, da die betroffenen Straßenbahnen nicht zeitnah in die Werkstatt umgeleitet und auf der Unterflurdrehbank untersucht werden konnten. Daher gab es entgegen der ursprünglichen Erwartung kein Feedback seitens der Werkstatt über den genauen Radzustand, weshalb dieser anhand des DMS-Signalverlaufs und des akustischen Klangcharakters ermittelt werden musste.

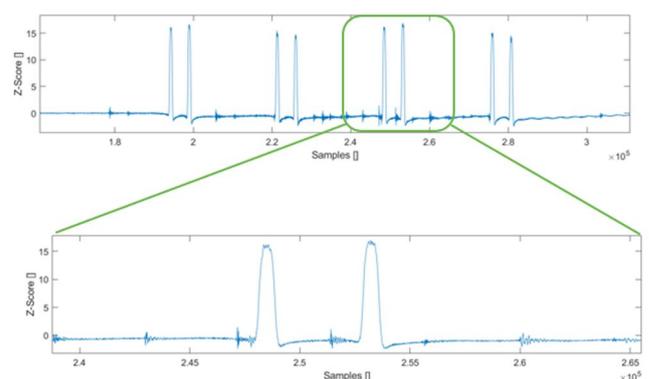


Abbildung 2: DMS-Signalverlauf der auf die Schiene übertragene Kraft mit erkennbaren, flachstellenähnlichen Ereignissen. Die 8 großen Peaks stellen die Radüberfahrten dar, die sich beim Überrollen des Rads über einen Sensor ereignen. Die hochfrequenten Peaks mit geringerer Amplitude stellen das Flachstelleneignis dar, das radperiodisch zwischen den Radüberfahrten auftritt.

Insgesamt wurden für 284 Straßenbahnvorbeifahrten 16 Flachstellen ermittelt. Diese Datengrundlage ist für das Training eines Detektionsmodells mit guter Generalisierung bei weitem nicht ausreichend. Um die Menge an verfügbaren

Daten künstlich zu erhöhen, wurde die Methode der Data Augmentation angewandt.

Die Datenerweiterung wurde auf Basis der 16 gelabelten Flachstellendefekte vorgenommen, indem die ursprünglichen Flachstellensignale modifiziert wurden. Dies geschah durch die Anwendung eines Highpassfilters, um die niederfrequenten Signale der Radüberfahrten aus den Messungen zu eliminieren. Nachfolgend wurden die hochfrequenten Flachstellensignale aus den Signalen extrahiert, wobei darauf geachtet wurde, das gesamte Flachstellensignal mit seinen ansteigenden und abfallenden Komponenten zu berücksichtigen. Die Radumlauf Frequenz und Amplitude des Signals wurden daraufhin durch Anwendung eines Zufallsfaktors beim Resampling und der Amplitudenskalierung augmentiert. Abschließend fand eine Aufaddierung des augmentierten Flachstellensignals auf einen Signalverlauf einer Überfahrt ohne Flachstellensignal statt.

Um sicherzustellen, dass die neu erstellten Daten keine künstlichen Einflüsse beinhalten, die durch die Synthetisierung bzw. Augmentierung entstanden sind (z. B. eventuelle Frequenzsprünge bei der Addition der Signale), die eine Detektion verfälschen würden, fand zusätzlich eine Überprüfung der neuen Daten statt. Dies beinhaltete hauptsächlich den Abgleich der synthetischen Flachstellensignale im Signalverlauf mit den originalen. Dabei wurden die Frequenzanteile in Powerspektren, Frequenzerlegungen und Scalogrammen der synthetischen den originalen Messungen gegenübergestellt. Erkennbare Unterschiede konnten lediglich in hohen Frequenzbereichen festgestellt werden, sodass in der nachfolgenden Featuregenerierung diese als Features kategorisch ausgeschlossen wurden.

Featuregenerierung

Als Detektionsalgorithmen dienten Feature-basierte Modelle, deren Eingangsgrößen skalare Kenngrößen (Features) sind.

Zur Umsetzung des radgenauen Ansatzes wurden die Signale um die Radüberfahrten gefenstert, sodass die für die Fenster berechneten Kenngrößen jeweils eine spezifische Radüberfahrt beschreiben. Diese Vorgehensweise wurde bereits in [2] erfolgreich umgesetzt.

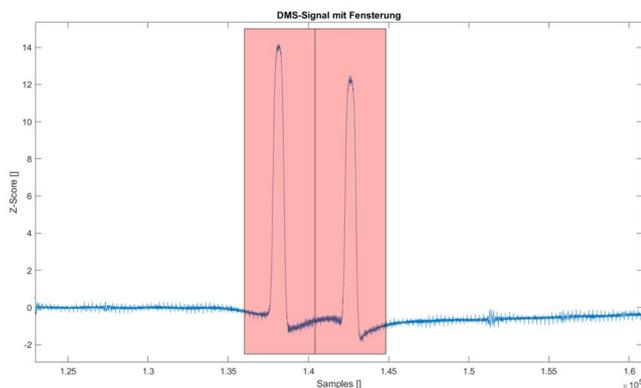


Abbildung 3: DMS-Signal mit um die Radereignisse gefensterten Bereiche

Diese definierten Zeitbereiche in den DMS- und Beschleunigungssignalen dienten als Grundlage zur Extrahierung der Features, die als Eingangsdaten in die Detektion einfließen.

Zur Featuregenerierung wurde das gefensterte Signal in verschiedene Frequenzbereiche zerlegt, um anschließend statistische Kenngrößen aus dem Ursprungssignal und den Frequenzerlegungen abzuleiten. Dies waren im Wesentlichen ihre zentralen Momente (mittlere absolute Abweichung, Varianz, Schiefe, Wölbung) als auch der Maximalwert. Die Kurvenfläche des Powerspektrums sowie sein Durchschnittswert fanden ebenfalls als Feature Verwendung.

Als geeignet stellten sich insbesondere die Features der Frequenzerlegungen zwischen 400 bis 1600 Hz (DMS) und 200 bis 800 Hz (Beschleunigungssensoren) heraus. Ebenfalls positiv wurden die aus dem Powerspektrum abgeleitete Größen bewertet. Niedrigere Frequenzen der DMS (bis 400 Hz) und der Beschleunigungssensoren (bis 200 Hz) hingegen waren ungeeignet.

ML-Ansätze und Ergebnisse

Es kamen klassische ML-Modelle zum Einsatz, deren Input aus skalaren Eingangsgrößen besteht. Im Detail fand eine Betrachtung und Optimierung der Algorithmen Boosted Tree und Neural Net statt.

Die Ergebnisse dieses Datensatzes sind in nachfolgender Tabelle dargestellt.

Tabelle 1: Ergebnisse der ML-Detektion

Modell	Gesamtgenauigkeit [%]	Präzision [%]	Trefferquote [%]	F1-Score [%]
Boosted Tree	98,9	88,5	80,4	84,3
Neuronales Netz	98,3	73,6	79,7	76,5

Es zeigt sich eine hohe Gesamtgenauigkeit bei beiden Modellen, wobei diese bei einem Testdatensatz mit ungleichen Klassenverhältnissen wenig Aussagekraft besitzt. Geeigneter Parameter stellen in diesem Fall die Präzision und die Trefferquote dar, die durch den F1-Score harmonisch gemittelt sind.

Beide Modelle weisen einen hohen F1-Score auf, jedoch schneidet das Boosted-Tree-Modell grundsätzlich besser ab. Es lässt sich eine hohe Präzision erkennen. Das heißt, eine detektierte Flachstelle war nur mit einer Wahrscheinlichkeit von 11,5 % falsch positiv. Mit einer Trefferquote von 80,4 % wurden zudem nur ca. 20 % aller vorhandenen Flachstellen übersehen.

Generell lässt sich sagen, dass die Detektion insbesondere im Hinblick auf den Anspruch der Radgenauigkeit gut funktioniert. Hinsichtlich der Präzision und der Trefferquote

lässt sich zudem durch Veränderung von Schwellenwerten eine Optimierung in einer der beiden Bewertungsgrößen anstreben, sodass falsch positive Detektionen weiter verringert oder aber mehr Flachstellen erkannt werden können.

Fazit

Eine radgenaue Detektion konnte mit dem vorgestellten Ansatz mit einem F_1 -Score von 84,3 % erreicht werden. Es wurden dazu Vorbeifahrten von Straßenbahnen mittels DMS- und Beschleunigungssensorarrays gemessen und aus dessen Radsignalen frequenzbasierte Features generiert. Diese dienten anschließend als Eingangsgrößen für einen ML-basierten Detektionsansatz.

Für die richtige Einordnung der Ergebnisse muss beachtet werden, dass der Radzustand aufgrund fehlender Werkstattdaten anhand akustischer und optischer Signalverläufe abgeschätzt wurde. Zudem war eine künstliche Erweiterung der Datengrundlage notwendig, da die Messdaten nicht ausreichend Beispiele von Flachstellenvorbeifahrten enthielten.

Um die vorgestellten Detektionsergebnisse abschließend zu verifizieren, ist daher eine Überprüfung mit qualitativ (Label des Radzustands) besseren und quantitativ (Anzahl vorhandener Flachstellen) umfangreicheren Messdaten notwendig.

Literatur

- [1] Egeler, J., Huth, C., Liepert, M.: Studie zur Quantifizierung von Flachstellen auf dem deutschen Schienennetz, BMDV, 2023, https://bmdv.bund.de/SharedDocs/DE/Anlage/E/abschlussbericht-quantifizierung-flachstellen.pdf?__blob=publicationFile
- [2] G. Krummenacher, C. S. Ong, S. Koller, S. Kobayashi and J. M. Buhmann: Wheel Defect Detection With Machine Learning. IEEE Transactions on Intelligent Transportation Systems, vol. 19, no. 4, pp. 1176-1187, April 2018, doi: 10.1109/TITS.2017.2720721