

Akustische Zustandsbewertung von Gleisen im Straßenbahnnetz

Reinhard Wehr¹, Andreas Fuchs¹, Werner Wehr²

¹ AIT Austrian Institute of Technology, 1210 Wien, Österreich, Email: reinhard.wehr@ait.ac.at, andreas.fuchs@ait.ac.at

² Wiener Linien, 1031 Wien, Österreich, Email: werner.wehr@wienerlinien.at

Einleitung

Mit 954 Millionen Fahrgästen jährlich sind die Wiener Linien ein integraler Bestandteil der Personenmobilität in Wien, wobei die eingesetzten Fahrzeuge täglich eine Entfernung von 212.000 Kilometern zurücklegen. Als Verkehrsmittel werden dabei 5 U-Bahn-Linien, 29 Straßenbahn- und 127 Buslinien eingesetzt.

Ein wichtiges Ziel des Infrastrukturunternehmens ist hier die Verfügbarkeit des Netzes sowie die allgemeine Sicherheit. Gerade in Bezug auf die Verfügbarkeit ist eine laufende Instandhaltung der Infrastruktur, insbesondere der Schieneninfrastruktur für die Verkehrsmittel U- und Straßenbahn, von hoher Bedeutung. Daneben sollen die Umweltauswirkungen, insbesondere der Lärm- und Erschütterungsschutz, berücksichtigt werden.

Alle diese Gesichtspunkte müssen unter finanziellen Aspekten betrachtet werden. Ebenfalls muss beachtet werden, dass Wartungs- und Instandhaltungsarbeiten nur in kurzen Zeitfenstern durchgeführt werden können. Ein hohes Ausmaß an Planbarkeit, das durch ein optimiertes Erhaltungsmanagement im Sinne von frühzeitigen Schadstellendetektionen unterstützt wird, ist daher gefordert.

Das vorliegende Paper möchte hier einen Zugang zur Infrastrukturüberwachung vorstellen. Dabei liegt der Fokus auf der Bewertung der Schienen im Straßenbahnnetz.

Gleisüberwachung im Wiener Straßenbahnnetz

Das Wiener Straßenbahnnetz umfasst insgesamt 29 verschiedene Linien mit einer Gleislänge von ca. 430 Kilometern (siehe Abbildung 1). Damit ist es eines der größten Straßenbahnnetze weltweit und trägt mit 300 Millionen Fahrgästen pro Jahr zu einem Drittel zum gesamten öffentlichen Personennahverkehr in Wien bei. Die Fahrzeugflotte umfasst hier mehr als 500 Fahrzeuge, die sich auf die Typen E₁, E₂ und ULF (Ultra Low Floor) verteilen.

Zur laufenden Infrastrukturüberwachung wird von den Wiener Linien im Straßenbahnnetz ein Gleismesswagen eingesetzt. Dabei handelt es sich um ein umgebautes Fahrzeug vom Typ E₁, das mit umfangreicher Sensorik ausgestattet ist. So wird die genaue Verortung im Netz durch Beschleunigungs- und Lagesensoren sichergestellt, wobei das gemessene Krümmungsmuster während der Messfahrt mit der bekannten Krümmungscharakteristik des Gleisnetzes abgeglichen wird. Ebenfalls sind Beschleunigungssensoren am Drehgestell des Fahrzeuges

montiert, mit denen auf die Krafteinbringung des Fahrzeuges auf den Fahrweg rückgeschlossen werden kann. Zusätzlich ist ein laserbasiertes System zur Schienoberflächenvermessung installiert, um den Höhen- und Seitenverschleiß des Gleises zu überwachen. Ziel der laufenden Gleisüberwachung ist es, die Planbarkeit in der Infrastrukturerhaltung zu optimieren und dadurch ein kosteneffizientes Erhaltungsmanagement zu ermöglichen.

Im Zuge eines gemeinsamen Forschungsprojektes wurde angestrebt, die Sensorik des Gleismesswagens dahingehend zu erweitern, neben den bisherigen Parametern auf weitere Schadensbilder rückschließen zu können. Dabei wurde vor allem erhofft, lärmschutzrelevante Parameter wie vor allem im Winter oft auftretendes Kurvenkreischen sowie beginnende Riffelbildungen auf der Schienoberfläche zu detektieren. Daher wurde der Messwagen mit einem On-Board-Mikrofon weiter ausgerüstet. Das Mikrofon wurde in zentraler Position vor dem zweiten Drehgestell montiert. Aufgrund der harschen Einsatzumgebung wurde die genaue Installationsposition in erster Linie durch die Umgebungsbedingungen vorgegeben, eine Positionierung in der Nähe des Rad/Schiene-Kontaktes hätte voraussichtlich zu regelmäßigen Ausfällen des Mikrophons geführt. Die zentrale Position hat zur Folge, dass beide Gleisstränge gemeinsam bewertet werden.

Detektion von Kurvenkreischen

Durch die komplexe Streckenführung im innerstädtischen Bereich mit geringen Kurvenradien kommt es im Straßenbahnnetz gerade im Winter häufig zu Kurvenkreischen. Dabei werden durch das seitliche Gleiten des Rades am Schienenkopf hochfrequente Schwingungen induziert, die zu einer kurzzeitigen hohen Lärmbelastigung




Abbildung 1: Übersicht über das Wiener Straßenbahnnetz; Kartenmaterial ©openstreetmap.org

führen [1, 2]. In Wien werden unter anderem stationäre Schmieranlagen zur Verringerung dieses Problems eingesetzt, vollständig kann das Auftreten aber dadurch nicht netzweit verhindert werden. Daher wird eine laufende Überwachung und Verortung angestrebt, die es gleichzeitig ermöglicht, Einflussparameter für das Auftreten des Kurvenkreischens zu identifizieren und vorbeugende Maßnahmen zu setzen.

Zu diesem Zweck wurde ein Algorithmus entwickelt, der es ermöglicht, während der Messfahrt auftretendes Kurvenkreischen zu detektieren und im Weiteren in einer Datenbank zu kennzeichnen. Basis für die Klassifizierung bildet ein Welch-Periodogramm, das mit einer Blocklänge von 0.5 s und einer spektralen Auflösung von 20 Hz die grundlegenden Prädiktoren für den Detektionsalgorithmus bereitstellt. Weitere in den Klassifizierer eingehende Daten sind die Geschwindigkeit sowie der durchfahrene Kurvenradius. Mithilfe manueller Markierungen eines Testdatensatzes kann nun ein Klassifizierungsalgorithmus trainiert werden, der aus dem mehrdimensionalen Raum der Prädiktoren eine eindimensionale Entscheidungsfunktion berechnet. Hier wurde die Leistungsfähigkeit verschiedener Klassifizierungsalgorithmen mit unterschiedlichen Parameterkonfigurationen mittels Cross-Validation analysiert und anhand Matthews' Korrelationskoeffizienten [3] bewertet. Als bester Klassifizierungsalgorithmus hat sich eine Kombination einer L1-basierten logistischen Regression zur Reduktion der bereits skalierten Prädiktoren mit einer linearen Diskriminanzanalyse [4] herausgestellt. Dies ergibt einen Matthews' Korrelationskoeffizienten von 0.80. Abbildung 2 zeigt die Wahrheitsmatrix für die Anwendung des Klassifizierungsalgorithmus auf markierte Stellen. Der Großteil der markierten Stellen für Kurvenkreischen wird richtig erkannt (86.36 %) und auch an einer überwiegend großen Zahl an Stellen ohne Kurvenkreischen stimmt die Vorhersage des Algorithmus. In 20 der 9786 betrachteten Abschnitte wird Kurvenkreischen vorhergesagt, obwohl keine Markierung vorhanden ist. Dies ist vor allem auf Randeffekte neben Markierungen zurückzuführen, da die Markierungen sehr konservativ gesetzt wurden, wie auch aus Abbildung 3 zu erkennen ist. Werte über 0 der Entscheidungsfunktion in Rot zeigen Bereiche, in denen der Algorithmus Kurvenkreischen vorhersagt.

| | | | |
|------------|-----------|-----------------|-----------------|
| True label | squeal | 57 86.36 % | 9 13.64 % |
| | no squeal | 20 0.21 % | 9700 99.79 % |
| | | squeal | no squeal |
| | | Predicted label | |

Abbildung 2: Wahrheitsmatrix der Kurvenkreischdetektion




Abbildung 3: Zeitverlauf der Entscheidungsfunktion der Kurvenkreischdetektion. Der Schwellwert wird bei 0 angesetzt, Überschreitungen bedeuten auftretendes Kurvenkreischen.

Riffeldetektion

Als weiteres Ziel wurde versucht, auf Basis der akustischen Daten Riffelbildungen am Schienenkopf zu detektieren. Hier wurde ein akustisches Maß definiert, dass über eine lineare Regression mit der gefahrenen Geschwindigkeit die Stärke beginnender und auftretender Riffel zu beurteilen erlaubt. Basis dabei ist ein geschwindigkeitsadaptiver Bandpassfilter, der durch die Wellenlänge der Riffel (50 .. 150 mm) definiert wird:

$$f_{min} = \frac{v}{0.15} \quad \dots \quad f_{max} = \frac{v}{0.05} \quad (1)$$

Innerhalb dieses Bandpass-Frequenzbereiches wird der Pegel bestimmt und dieser über ein lineares Regressionsmodell vom Einfluss der Geschwindigkeit bereinigt. Hohe Pegel sind daraufhin ein Zeichen für Riffelbildungen in unterschiedlichem Ausmaß. Im Rahmen einer Begehung ausgesuchter Stellen im Straßenbahnnetz der Wiener Linien wurde die Qualität der Vorhersage überprüft. Während der Begehung wurde per Sichtkontrolle vor Ort durch Experten der Wiener Linien die Ausprägung von Riffeln anhand einer Farbskala nach Ampelfarben kategorisiert, wobei die Kategorie Rot starken Riffeln entsprach. Unter der Berücksichtigung der Sichtverhältnisse und subjektiven Eindrücke während der Begehung sowie Unsicherheiten in der exakten Lokalisation zeigt sich durchaus ein Zusammenhang zwischen der Vorhersage und beurteilten Ausprägung von Riffeln. Durch die Möglichkeit der Verortung können somit Riffel, genauso wie Kurvenkreischen und die vorhergesagten Schallemissionspegel Positionen im Gleisnetz zugeordnet werden.

Pegelanalysen

Um die aufgezeichneten Daten weiter zu nutzen, wird versucht, aus den aufgezeichneten Schalldruckpegeln einen Relativvergleich des akustischen Gesamtzustandes des Gleisnetzes abzuleiten. Dazu wird der relative Schalldruckpegel $D_{LA,s}$, der die Differenz des gemessenen Schalldruckpegels $L_{A,s}$ zum durchschnittlichen Schalldruckpe-

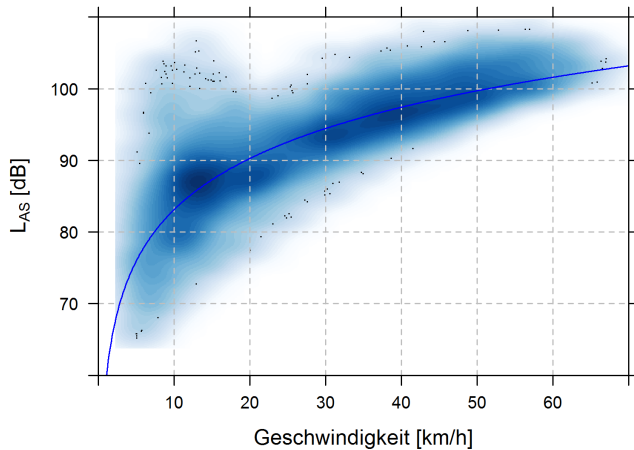


Abbildung 4: Regressionsmodell des On-Board-Emissionspegels und der gefahrenen Messgeschwindigkeit.

gel $L_{A,s}^M(v)$ bei der aktuellen Geschwindigkeit v angibt, berechnet:

$$D_{LA,s} = L_{A,s} - L_{A,s}^M(v) \quad (2)$$

Dabei wird der $L_{A,s}^M(v)$ als Auswertung des Regressionsmodells von auftretendem $L_{A,s}$ und logarithmischer Geschwindigkeit über alle in der Messfahrt anfallenden Daten gebildet (Abbildung 4). Somit gibt der Differenzpegel in (2) die Abweichung der gemessenen On-Board-Schallemission zum bei dieser Geschwindigkeit erwarteten Pegel an.

In diesem Modell wurden einige Restriktionen eingeführt, um Fehlvorhersagen so verhindern. So wurden beispielsweise Datensätze, die bei niedrigen Geschwindigkeiten aufgenommen wurden, aufgrund ihrer hohen Schwankungen aus dem Regressionsmodell entfernt. Ebenfalls wurde der befahrene Kurvenradius eingeschränkt, um in erster Linie eine Aussage über gerade Strecken zu erzielen. Eine Erweiterung des Modells auf diese und weitere Einflussparameter soll im weiteren Projektverlauf untersucht und implementiert werden.

Zur Validierung der Aussagekraft der gemessenen On-Board-Pegel wurden in weiterer Folge kontrollierte Vorbeifahrtmessungen mit dem Gleismesswagen durchgeführt. In diesen wurde der Schallexpositionspegel L_{AE} bei verschiedenen Geschwindigkeiten an zwei Gleisen gemessen. Als Fahrzeuge kamen der Gleismesswagen als Vertreter der Regelfahrzeugtypen E_1 und E_2 und ein fabrikneuer ULF zum Einsatz. Durch die gleichzeitige Aufnahme des On-Board-Schalldruckpegels konnte nun für den Gleismesswagen die Korrelation zwischen dem mittleren On-Board-Schalldruckpegel $L_{A,s}$ zum Schallexpositionspegel L_{AE} der Vorbeifahrt bestimmt werden. Dafür wurde zuerst für jedes Gleis separat das geschwindigkeitsabhängige Regressionsmodell (Abbildung 5) aufgestellt, das deutlich eine Trennung der Schallemission der beiden Gleise zeigt.

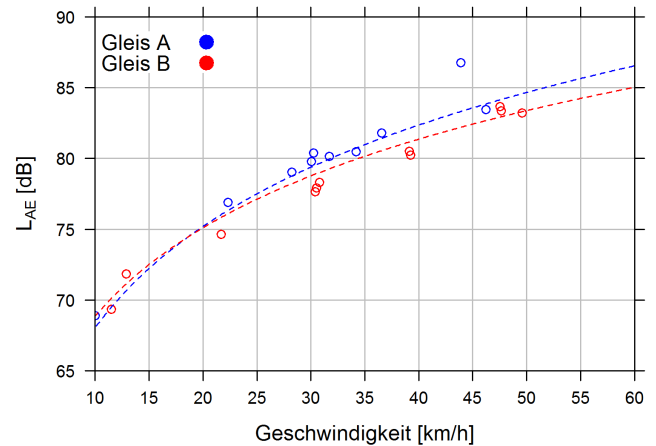


Abbildung 5: Regression der Schallexpositionspegel mit der Geschwindigkeit des Gleismesswagens.

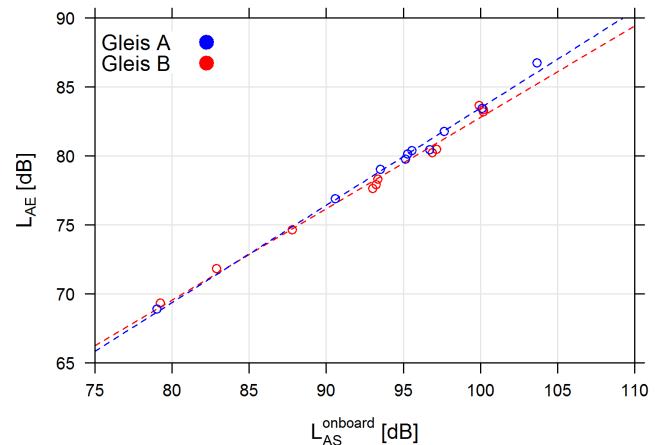


Abbildung 6: Regression der Schallexpositions- und der mittleren On-Board-Schalldruckpegel während einer Vorbeifahrt, getrennt für beide vermessene Gleise.

Anschließend wurde eine Regression der gemittelten On-Board-Schalldruckpegel der Vorbeifahrt mit den gemessenen Schallexpositionspegeln berechnet (Abbildung 6). Hier tritt die vorherige Trennung der beiden Gleise nicht mehr auf. Daraus kann geschlossen werden, dass das Regressionsmodell zwischen Schallexpositions- und mittlerem Vorbeifahrtspegel für unterschiedliche Gleiszustände die selbe Form aufweist und somit als allgemein gültig angenommen werden kann.

Da für das Regelfahrzeug vom Typ ULF keine On-Board-Daten verfügbar sind, kann der oben gezeigte Vergleich nicht direkt für diese Fahrzeugtype umgesetzt werden. Daher wird aktuell ein Transferpfadmodell zwischen den Gleismesswagendaten und den Vorbeifahrtmessungen mittels ULF erstellt.

Danksagung

Die in diesem Paper dargestellte Arbeit wurde im Zuge des Projektes "exSentric - Extending Sensor Technology for Rails in the City" im Rahmen der FTI-Initiative "Mobilität der Zukunft" gefördert.

Literatur

- [1] Rudd, M.J.. Wheel/rail noise - Part II: wheel squeal. *Journal of Sound and Vibration* 46 (3), 1976
- [2] Heckl, M., Abrahams, I.D.. Curve squeal of train wheels, Part I: mathematical model for its generation. *Journal of Sound and Vibration* 229 (3), 2000
- [3] Powers, M.. Evaluation: From precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*, Vol. 2, No. 1, 2011.
- [4] Hastie, T., Tibshirani, R., Friedman, J.. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd edition, Springer Series in Statistics, 2009.