

erkennbar – sowohl bei Prominenz (Abb. 4, oben) als auch beim Anomaly-Score (Abb. 4, unten) – vermutlich verursacht durch die Änderungen, die die Instandhaltungsmaßnahme im Verhalten der Weiche verursacht hat. Im Sommer 2018 ist der Anteil der Anomalien wieder geringer, erhöht sich jedoch wieder kurz vor der Ende 2018 aufgetretenen Fehlfunktion. Die Arbeiten an der Weiche zur Behebung der Fehlfunktion führten dazu, dass das mit den Daten von 2016 trainierte Modell nahezu alle nachfolgend erfassten Kurven als anormal bewertet.

Anhand dieses Beispiels kann man erkennen, dass das AD-Modell Anomalien detektiert, wenn sich der Prominenzwert der Höcker in Bezug auf den Trainingsdatensatz zu ändern beginnt, d.h. die Ausgabe des AD-Modells ist ein allgemeines Maß für Änderung. Das Warnmodul sendet detaillierte Informationen bezüglich des Vorhandenseins von Höckern, selbst wenn diese das typische Verhalten dieser Weiche darstellen und daher nicht mit anormalem Verhalten in Bezug auf den verfügbaren Trainingszeitraum verbunden sind. Der WA kann fundierte Entscheidungen bezüglich der Wartung unter Berücksichtigung der Entwicklung der Variablen treffen, die mit dem Funktionszustand der Weiche verbunden sind.

Im Dialog mit den Experten

Für die Bewertung und Ableitung von Leistungskennzahlen für die oben beschriebene Methodik benötigt man zahlreiche mit dem tatsächlichen Zustand der Weichen annotierte Kurven (sog. Ground-Truth-Datensatz). Eine Validierung der Ergebnisse durch die WA ist notwendig, um z. B. bestimmte Parameter oder Schwellwerte im Arbeitsablauf anzupassen. Es ist wichtig, dass die WA nicht zu viele Warnungen bzw. Anomalien angezeigt bekommen, sondern die Ausgaben der Modelle an deren Kapazitäten angepasst sind, sodass die dringendsten Fehler identifiziert und behandelt werden können. Außerdem ist eine positive Bewertung der Zuverlässigkeit der Modelle durch die WA wichtig, um Vertrauen in die AD und die Warnungen zu gewinnen.

Eine erste umfassende Validierung der Methodik wird in naher Zukunft durchgeführt. Die WA interagieren dazu mit einer speziell für diesen Zweck programmierten GUI (Abb. 5), welche nacheinander und in randomisierter Reihenfolge eine Auswahl historischer Kurven präsentiert und verschiedene farbcodierte Bewertungsoptionen für die Kurve und ihre Segmente zur Auswahl stellt. Die Bewertung der WA wird dann mit der Ausgabe des AD-Modells verglichen und auf Übereinstimmung geprüft. Man kann erwarten, dass z. B. für Weichen, bei denen über einen langen Zeitraum Höcker auftraten (wie im Beispiel Abb. 3), die Einschätzung des WA nicht mit der Ausgabe des AD-Modells über-

einstimmen wird. Wenn die analysierte Kurve einen Höcker hat, wird der Analyst wahrscheinlich auswählen, dass das Segment oder die Segmente, über die sich der Höcker erstreckt, sowie die gesamte Kurve nicht o.k. sind. In diesem Beispiel sieht das AD-Modell das Vorhandensein von Höckern jedoch als normales Verhalten an, da es mit solchen Daten trainiert wurde. Weiterhin kann der Vergleich zwischen Warnungen und der Analytischeinschätzung hilfreich sein, um zu definieren, ob bzw. wie Schwellwerte angepasst werden müssen.

Langfristig soll die Bewertung von Kurven durch WA online und vergleichbar zu der hier vorgestellten, prototypischen Einbettung und GUI-Interaktion erfolgen. Einerseits sollen so die WA in ihrer täglichen Arbeit unterstützt werden: Die eingegebenen Informationen können dann im System gespeichert und zu einem späteren Zeitpunkt abgerufen und genutzt werden, was Wartungsentscheidungen durch die Möglichkeit zur Verwendung einer Bewertungshistorie unterstützt. Andererseits bietet eine langfristige Einbettung der Kurvenbewertung in den Alltag der WA die Möglichkeit, die vorgestellte Methodik und Weiterentwicklungen kontinuierlich zu validieren und zu verbessern.

Fazit

Unüberwachte Lernmethoden zur AD von Weichenzustands-Überwachungsdaten ermöglichen die Erfassung komplexer Zusammenhänge sowie unbekannter Fehler oder Fehlerkombinationen, die jedoch oftmals nur eingeschränkt interpretierbar sind. Vor diesem Hintergrund wurde von DLR und SR ein Arbeitsablauf entwickelt, welcher AD-Methoden mit einem Modul kombiniert, das Warnungen auf Basis der Identifikation von spezifischen, durch WA definierten Fehlersignaturen in Stromlaufkurven in realer Betriebsumgebung generiert. Hierdurch können die Interpretierbarkeit der Ergebnisse und die Zuverlässigkeit der Fehlererkennung erhöht werden.



Dr. Daniela Narezo Guzman

Wiss. Mitarbeiterin
Institut für Verkehrssystemtechnik
Deutsches Zentrum für Luft und
Raumfahrt e.V. (DLR), Berlin
daniela.narezoguzman@dlr.de



Dr. Norman Weik

Wiss. Mitarbeiter
Institut für Verkehrssystemtechnik
Deutsches Zentrum für Luft und
Raumfahrt e.V. (DLR), Braunschweig
norman.weik@dlr.de

Aktueller Fokus der Arbeiten ist die Verfeinerung der Merkmale von relevanten Signaturen (z. B. Höckern), welche auf von WA als hochrelevant eingestufte Fehlertypen hindeuten. Weiter wird gegenwärtig eine erste Validierung der Ergebnisse für ausgewählte Kurven von zehn Weichen aus einem Zeitraum von über zwei Jahren durchgeführt. Somit kann ein umfassenderes und für WA leichter interpretierbares Bild des Weichenzustands erreicht werden. ■

Danksagung

Dieses Projekt wurde durch das Shift2Rail Joint Undertaking (JU) finanziert (Grant Agreement No. 881574). Das JU erhält Unterstützung vom Forschungs- und Innovationsprogramm Horizon 2020 der Europäischen Union (EU) sowie weiteren Mitgliedern des JU Shift2Rail neben der EU.

QUELLEN

- [1] INNTRACK (2009): Deliverable 1.4.6 - A report providing detailed analysis of the key railway infrastructure problems and recommendations as to how appropriate existing cost categories are for future data collections
- [2] Deutsche Bahn AG (2020): Für bessere Pünktlichkeit...: <https://www.deutschebahn.com/resource/blob/6868306/00d5be4699441637ae4c19129e28ef99/Download-Smar-te-Weichen-Rahmenvertrag-data.pdf>
- [3] Kassa, E.; Saramota, J.; Skavhaug, A. (2021): Monitoring of Switches and Crossings/Tracks Using Smart Sensors. In: Galeazzi, R.; Kjartansson Danielsen, H.; Kjær Ersbøll, B. et al. (eds): Intelligent Quality Assessment of Railway Switches and Crossings. Springer Nature, pp 149–166
- [4] García Márquez, F. P.; Lewis, R. W.; Tobias, A. M. et al. (2008): Life cycle costs for railway condition monitoring. *Transportation Research Part E: Logistics and Transportation Review* 44: pp 1175–1187
- [5] INNTRACK (2009): Deliverable 3.3.2 - Available sensors for railway environments for condition monitoring
- [6] Narezo Guzman, D.; Heusel, J.; Weik, N. et al. (2022): Towards the automation of anomaly detection and integrated fault identification for railway switches in a real operational environment: (im Druck). In: *Proceedings World Congress on Railway Research 2022*
- [7] Narezo Guzman, D.; Hadzic, E.; Baasch, B. et al. (2020): Anomaly Detection and Forecasting Methods Applied to Point Machine Monitoring Data for Prevention of Railway Switch Failures. In: Ball, A.; Gelman, L.; Rao, B.K.N. (eds): *Advances in Asset Management and Condition Monitoring*, vol 166. Springer International Publishing, Cham, pp 307–318



Dr. Judith Heusel

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



Douwe Buursma

Datenanalytiker
Strukton Rail, NL-Maarssen
douwe.buursma@strukton.com