

Einsatz Künstlicher Intelligenz für die Instandhaltung von Stopfmaschinen

Das Monitoring der Arbeitsqualität von Stopfmaschinen mit Methoden maschineller Intelligenz ist eine bedeutende Erweiterung des üblichen Zustandsmonitorings.

BERNHARD LICHTBERGER

Zuverlässige hochqualitativ arbeitende Instandhaltungsmaschinen sind eine der Grundlagen für eine hohe Verfügbarkeit der Gleise für den Eisenbahnbetrieb. Prädiktives Zustandsmonitoring der Komponenten und Aggregate ist Stand der Technik bei Stopfrobotern der Fa. System7 rail GmbH (System7). Mithilfe eines trainierten unsupervised KI-Programms (KI, Künstliche Intelligenz) kann auf Basis vorhandener Korrekturwerte eines zu stopfenden Gleises der Verlauf der Restfehler nach der Arbeit vorhergesagt werden. Das erlaubt die Überprüfung der Arbeitsqualität des Stopfroboters durch Vergleich mit der Vorhersage des KI-Programms und ggf. frühzeitiges Eingreifen.

Zustandsmonitoring von Stopfmaschinen

Die Zustandsüberwachung reduziert den Bedarf an menschlichen Inspektionen durch automatisierte Überwachung, verringert den Wartungsaufwand durch die Erkennung von Fehlern, ehe sie eskalieren, und verbessert die Verfügbarkeit und Zuverlässigkeit [1].

Es gibt verschiedene Instandhaltungsstrategien. Die reaktive Form der Instandhaltung behebt den Fehler eines Bauteils oder einer Anlage erst nach dem Versagen. Dies führt zu unerwarteten und zeitlich schwer abzuschätzenden Ausfällen. Die Methode ist teuer und mit den hohen betrieblichen Anforderungen der Eisenbahn unvereinbar.

Abb. 1 zeigt die gängigen Instandhaltungsmethoden. Der Unterschied zwischen der reaktiven und der vorbeugenden Strategie liegt in der Planung der Wartungsaktivitäten.

Die präventive Instandhaltung beruht auf einer Abschätzung. Sie greift auf betriebliche Erfahrungen zu und nutzt die Kenntnis der Dauer und Belastung einer Komponente sowie der dadurch erzeugten Abnutzung. Sie gibt den Zeitpunkt von Wartung oder Austausch des Bauteils an. Nachteilig ist, dass die Bauteile u.U. zu früh getauscht werden oder die Wartung zu häufig durchgeführt wird. Sie wird bei der Eisenbahn immer noch dort angewendet (zyklische Inspektion), wo der Zustand des Bauteils oder der Komponenten messtechnisch nicht erfassbar ist oder diese messtechnische Beobachtung zu teuer ist (z. B. Puffer-Zughakensystem, Radverschleiß, Fahrwerkfederung etc.).

Die Nachteile der präventiven Instandhaltung werden durch die Überwachung des Zustands der Bauteile mittels Sensoren vermieden. Abhängig vom Zustand – die Grenz-

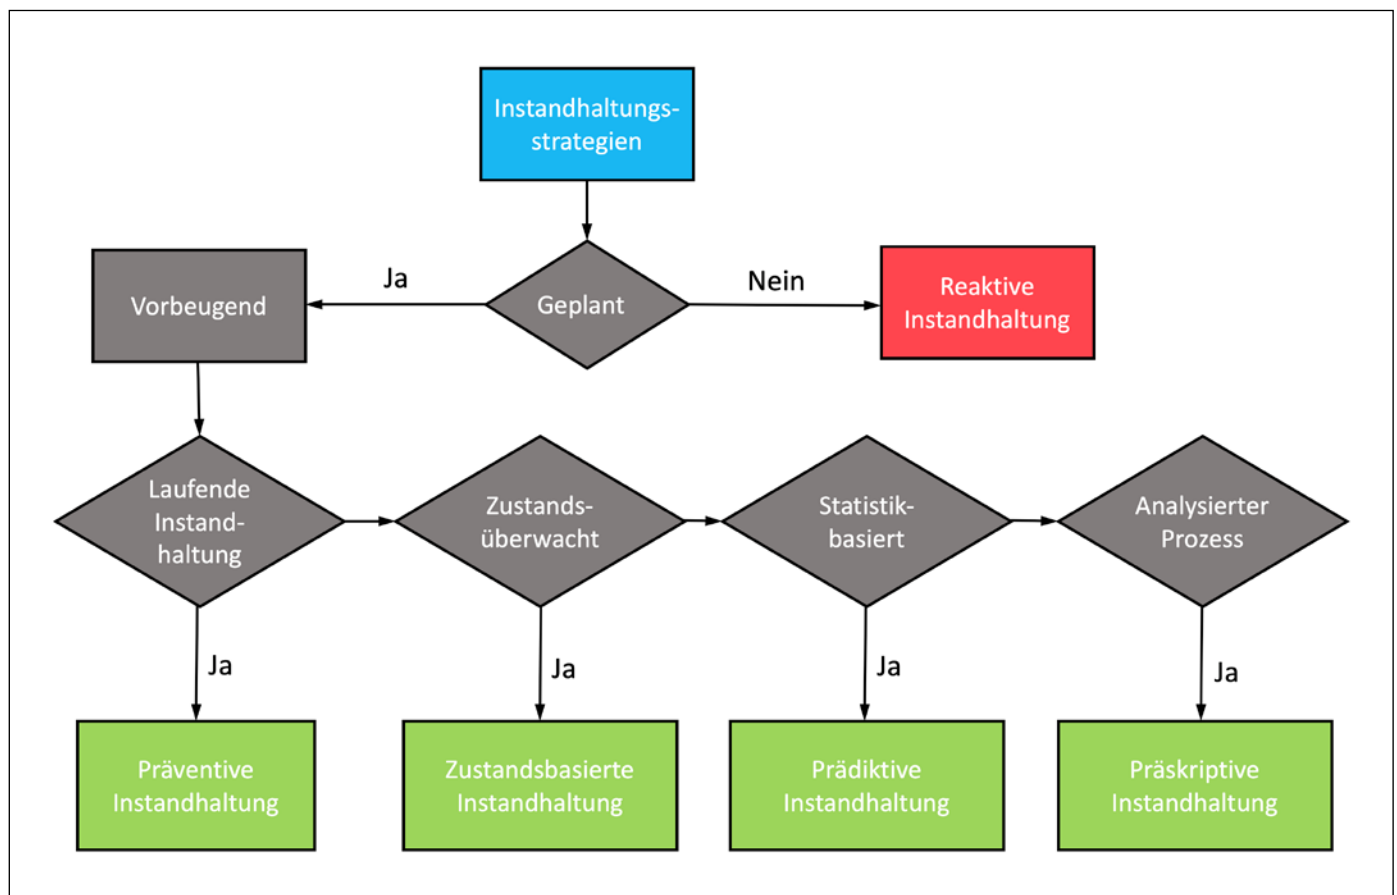


Abb. 1: Diagramm der Instandhaltungsstrategien

Quelle: [5]

werte werden nach Erfahrung festgelegt – wird die Instandhaltung durchgeführt.

Die prädiktive Instandhaltung konzentriert sich auf den Einsatz von statistischen Methoden mit etablierten Mess- und Verarbeitungstechniken. Der Verlauf der Verschlechterung bzw. Abnutzung der Komponenten wird gemessen, daraus wird statistisch ein Trend abgeleitet. Mithilfe des Trends werden Aussagen über einen bestimmten Zustand bzw. das Risiko eines Ausfalls getroffen. Das gibt dem Instandhaltungsverantwortlichen zeitlichen Spielraum, die Instandhaltung zu planen und zeitgerecht durchzuführen.

Die modernste der Strategien ist die präskriptive Wartung oder wissensbasierte Wartung [2]. Sie bezieht sich auf die Optimierung der Instandhaltung auf der Grundlage von Vorhersagen. Neben der Verwendung von historischen und Echtzeit-Datenanalysen zur Vorhersage des Zustands der benötigten Anlagen wird ein Aktionsplan erstellt. Dies führt von einem präventiven zu einem proaktiven und intelligenten Wartungsplan. Das Ziel ist, Service, Kosten und Sicherheit zu optimieren. Der Einsatz von Methoden der KI mit etablierten Mess- und Verarbeitungstechniken bildet ihre Basis [3].

Eine optimierte Instandhaltungsstrategie bringt die folgenden Vorteile mit sich:

- Verkürzte Ausfallzeiten
- Reduktion der Betriebsbehinderungen
- Kosteneinsparungen
- erhöhte Produktivität
- verlängerte Lebensdauer der Maschinen, Anlagen und Bauteile
- bessere Kundenbetreuung und Reputation
- Reduktion des Energieaufwands
- erhöhte Sicherheit
- klare strukturierte Instandhaltungsaufgaben
- vorausschauende Planung von Instandhaltungsaufgaben.

Bei den Stopfrobotern von System7 wird die prädiktive Instandhaltung genutzt. An der Umsetzung der präskriptiven Wartung wird kontinuierlich gearbeitet.

Die Web-Plattform RaVeM

Eine hohe Zuverlässigkeit und Verfügbarkeit von Gleisinstandhaltungsmaschinen erfordern funktionierende zuverlässige Systeme und Komponenten. Der Verschleiß- und Wartungszustand der für den Betrieb kritischen Komponenten ist daher zu verfolgen und zu dokumentieren. Durch die Messung und Auswertung des Zustandes kündigen sich Fehler an; die entsprechende Komponente wird rechtzeitig gewartet oder getauscht.

Für diese Funktion steht bei System7 die Webplattform RaVeM (Railway Vehicle Monitoring)

zur Verfügung [4]. Die Zustandsdaten werden im Stunden- oder Tagesintervall, individuell je nach Bauteil, übertragen und gespeichert. RaVeM berechnet aus dem aktuellen Verlauf den Verschleißtrend und daraus den optimalen Zeitpunkt für einen Serviceeingriff. Automatisch informiert das System den Instandhaltungsverantwortlichen über Kurznachricht (SMS) oder E-Mail. Die Informationen der Webplattform RaVeM sind plattformunabhängig über Smartphone, Tablet oder Desktop zugänglich.

Derzeit werden Dieselmotor, Achsgetriebe, Verteilgetriebe, Hydraulikölfilter, Stopfaggregate, Hilfsgenerator, Bordnetz, optisches Messsystem, Hebe-Richt-Anlage, Antriebsmotoren, GNSS, GSM, WLAN, Computernetzwerk und inertiales Navigationsmesssystem überwacht. Achsgetriebe und Stopfaggregate werden (neben anderen Sensoren wie Temperatur, Druck etc.) über Beschleunigungsmessungen und elektronische Zustandsmodule monitort. Die elektronischen Zustandsmodule werten automatisch wichtige Zustandsgrößen, wie RMS-Hüllkurven der Beschleunigungen, Crest-Faktor, Kurtosis-Filter etc., aus. Damit sind Unwuchten, Gleit- und Wälzlager- oder Getriebeverschleiß in ihrer Entwicklung verfolgt- und voraussagbar. Die Eingriffs- und Warnschwellen werden anhand von Messun-

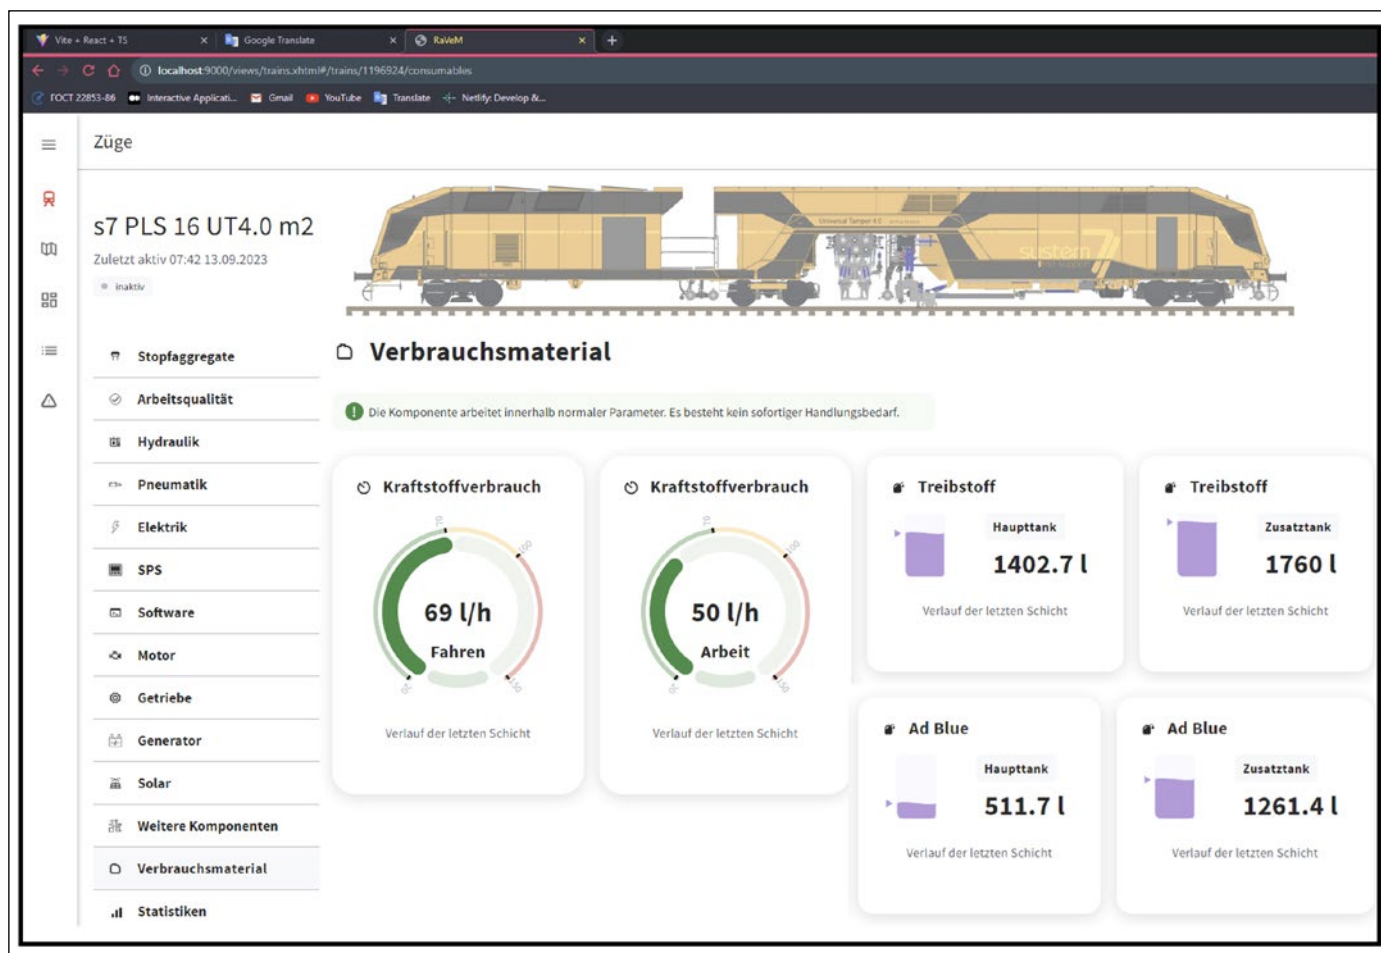


Abb. 2: Schirmbild des Railway Vehicle Monitoring Systems

Quelle: System7 rail GmbH

gen, auch hinsichtlich der Ausfallkritikalität des Gesamtsystems, gesetzt und modifiziert. An RaVeM werden Satellitenkoordinaten übertragen. Damit ist die exakte Position, der aktuelle Laufweg und die gesamte Laufleistung der Maschine bekannt und zu jedem Zeitpunkt nachverfolgbar. Der Zugang zur Webplattform ist geschützt, nur autorisierte Nutzer dürfen zugreifen. Die Zugriffe werden protokolliert. Die Datenübertragung von und zur Applikation ist verschlüsselt.

Abb. 2 zeigt beispielhaft das Schirmbild zur Abfrage des Verbrauchsmaterials der Stopfmaschine. Der durchschnittliche Kraftstoffverbrauch der letzten Schicht während der Überstellfahrt und während des Arbeitens wird dargestellt. Außerdem zeigt der Schirm die Füllstände von Diesel und AdBlue. Durch Anklicken der Items in der linksstehenden Liste kann der Nutzer Informationen über den Zustand der verschiedenen Anlagen und Komponenten einsehen.

Monitoring der Arbeitsqualität der Stopfmaschinen

Die wichtigste Aufgabe einer Stopfmaschine ist die Berichtigung geometrischer Gleisfehler. Je höher die Qualität dieser Arbeit, um so dauerhafter ist die Gleislage. Mit steigender Dauerhaftigkeit verlängert sich der Zeitpunkt bis zur nächsten Stopfung. Verlängert sich die Dauer zwischen Stopfeinsätzen, erniedrigen sich auch die Betriebsbehinderungen. Die Verfügbarkeit der Gleise steigt. Dies ist wegen der steigenden Anforderungen an die Bahnleistungen, als nachhaltigstem Verkehrsmittel im

Zeitalter der Klimakrise, ein wichtiger Baustein. Stand der Technik ist die Zustandsüberwachung von Komponenten, Anlagen und Aggregaten von Stopfmaschinen. System7 entwickelt als Ergänzung ein System zur Überwachung der Arbeitsqualität der Stopfmaschine in ihrer Gesamtheit. Als zielführende Methode wurde der Einsatz eines KI-Programms gewählt.

Anwendung eines unsupervised KI-Programms auf Stopfqualitätsdaten

Die Anwendung von KI-Modellen ist Stand der Technik [5]. Die angewandten KI-Modelle können in verschiedene Kategorien eingeteilt werden. KI-Modelle haben die Fähigkeit, komplexes Gleislageverschlechterungsverhalten nach Art, Lage, Ausdehnung und Wellenlänge von Gleislagefehlern mit hoher Genauigkeit abzubilden. KI-Modelle müssen mit Trainingsdatensätzen trainiert werden. Geprüft werden sie mit Testdatensätzen. In Abhängigkeit von der Zielsetzung der KI-Anwendung und der Beschaffenheit der zur Verfügung stehenden Daten werden überwachte (supervised), unüberwachte (unsupervised), bestärkende Lernverfahren (reinforcement learning) oder eine Kombination aus diesen Verfahren eingesetzt. Als „Generative KI“ werden KI-Systeme bezeichnet, die neue Inhalte oder Daten erstellen können.

Stopfroboter von System7 sind durch umfangreiche Datenerfassung und volle Digitalisierung gekennzeichnet [6]. Die erfassten Daten werden in eine Datenbank über Mobilfunk übertragen und auf einem Server gespei-

chert. Datenbank-Server verwalten die Daten zahlreicher Stopfroboter. Dadurch erweitert sich fortwährend der Datenbestand, der die Eingangsdaten einer Vielzahl von Stopfmaschinen in Verbindung mit den Ergebnissen der Gleisbearbeitung durch diese Maschinen abbildet. Die mit der Zeit entstehende Menge und die Beschaffenheit dieser Daten erlaubt den Einsatz maschineller Lernverfahren. Daraus werden statistische Modelle der Arbeitsweise von Stopfrobotern erzeugt. In weiterer Folge werden diese im Echtzeitbetrieb der Maschinen eingesetzt.

Unüberwachten Lernverfahren stehen durch menschliche Experten interpretierte und bewertete Trainingsdatensätze nicht zur Verfügung. KI-Algorithmen dieser Kategorie finden autonom, ohne menschliches Zutun, in einer großen Datenmenge versteckte Muster und Assoziationen. Eingangsdaten der Stopfmaschine über den Stopfprozess und die Gleisinfrastruktur werden gruppiert und in Cluster unterteilt. Die resultierenden Cluster zeigen Zusammenhänge in den Daten auf, die für einen menschlichen Experten a priori kaum erkennbar sind. Eine Korrelationsanalyse stellt den Einfluss spezifischer Eingangsparameter, wie Hebewert, Richtkorrektur, Verdichtkraft, Beistellzeit und Beistellgeschwindigkeit der Stopfaggregate, auf die Gleislagequalität fest. Generative KI-Systeme, wie beispielsweise Generative Adversarial Networks (GAN), transformieren diese Eingangsdaten iterativ, wodurch neue, korrigierte Abbilder der zu erwartenden Gleislage bzw. der jeweiligen Zielparame- ter nach Bearbeitung entstehen.

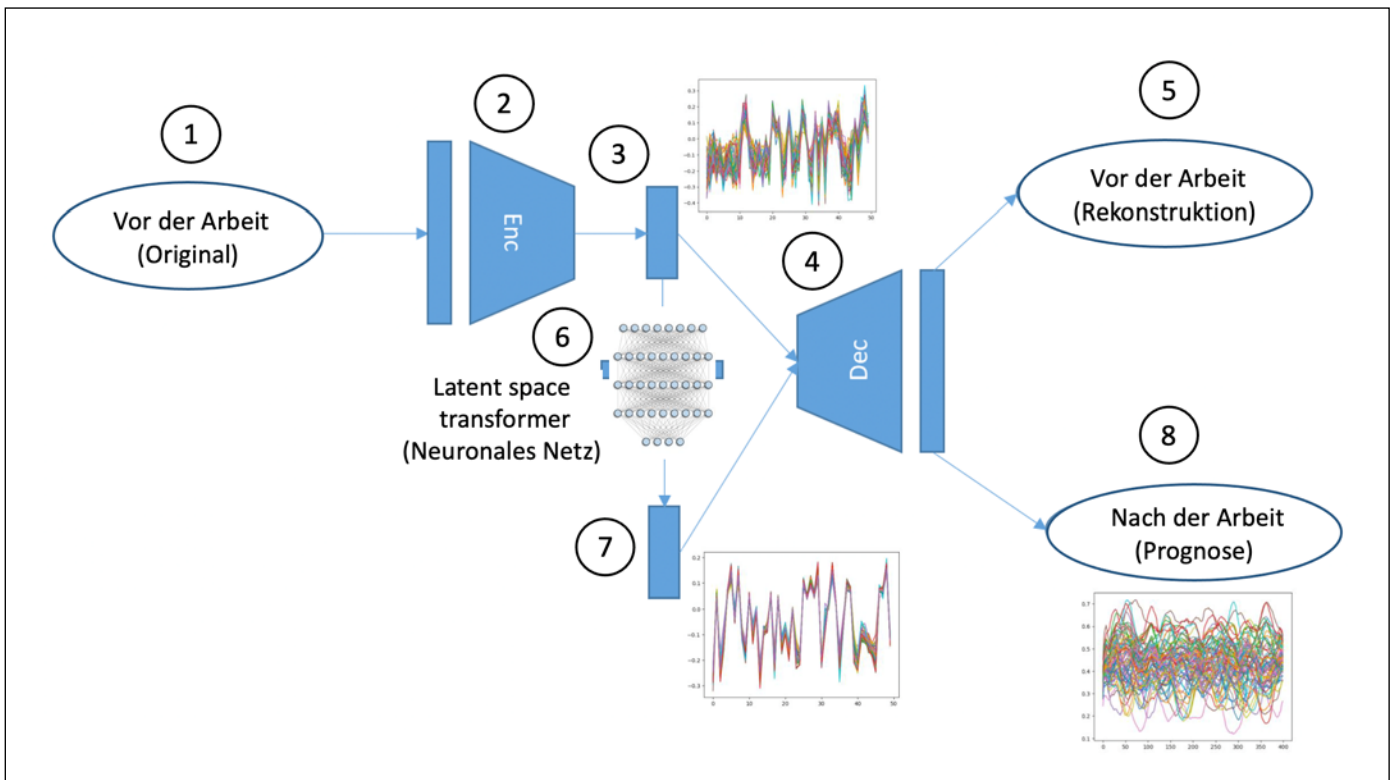


Abb. 3: Unsupervised KI-Programm zur Vorhersage von Arbeitsergebnissen des Stopfroboters

Quelle: System7 rail GmbH

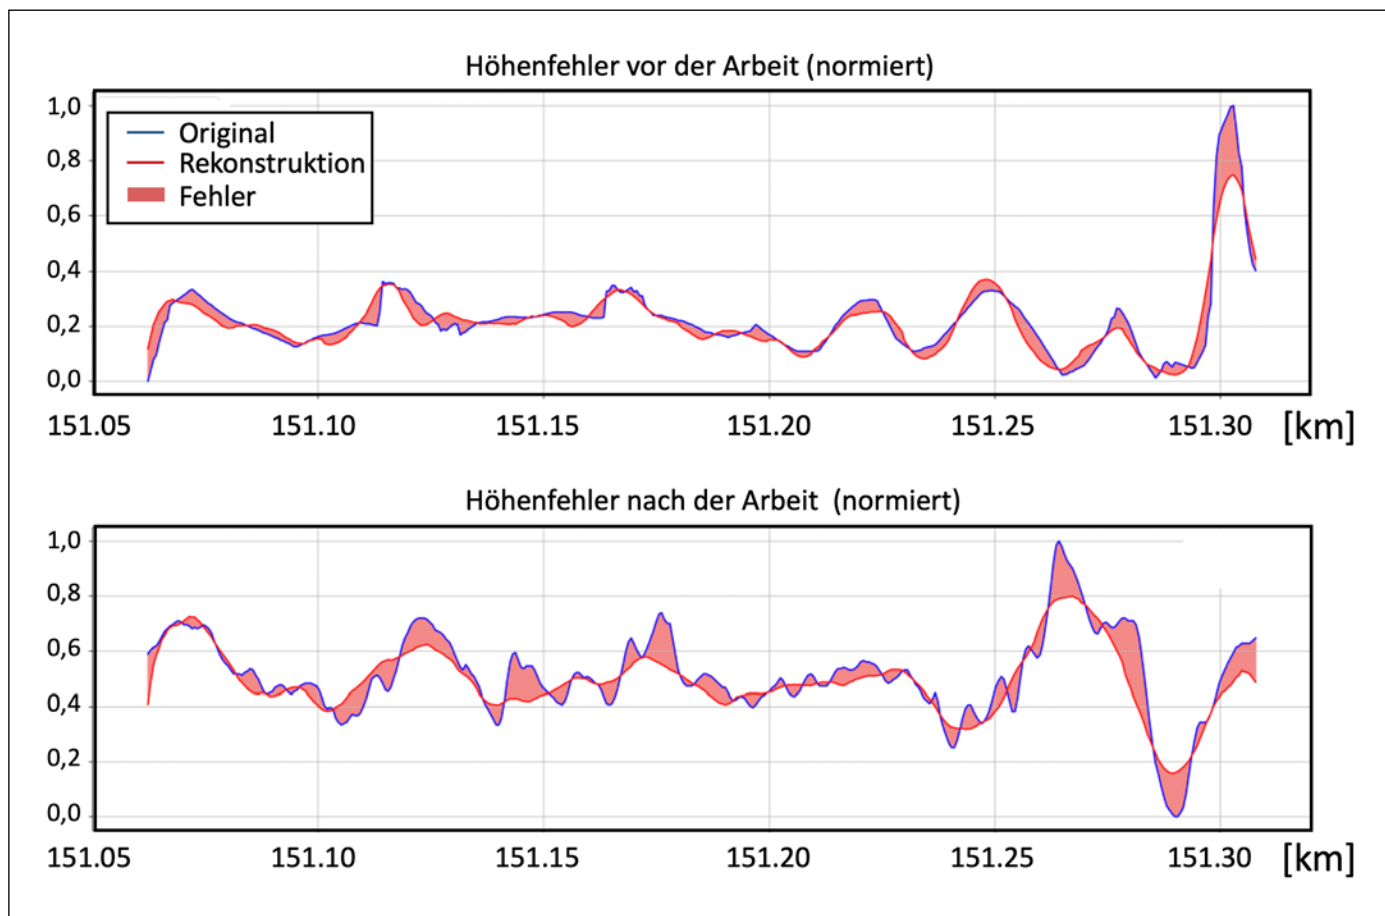


Abb. 4: Vorhersage des trainierten unsupervised KI-Programms der normierten Gleislagefehler nach der Arbeit

Quelle: System7 rail GmbH

Die Vorhersage des Korrekturergebnisses des Stopfroboters durch das trainierte KI-Programm zeigt die Genauigkeit dieses Verfahrens. Im Anschluss einer Stopfarbeit wird das Stopfergebnis dahingehend beurteilt, ob es innerhalb des vorhergesagten Ergebnisses mit Unschärfen des trainierten KI-Programms liegt. Damit wird die Arbeitsweise der Maschine überwacht, und es werden Hinweise gegeben, wenn sich das Arbeitsergebnis der Maschine im Lauf der Zeit verschlechtert. Gründe können sein: Fehlfunktionen oder Störungen an Hydraulikventilen, Störungen des Maschinenmesssystems, sich veränderndes Regelverhalten der Hebe-Richt-Anlage etc. Damit ist das Zustandsmonitoring der Gesamtmaschine hinsichtlich ihres Arbeitsverhaltens möglich. Schon eine Teststopfarbeit einer neuen Maschine während der Inbetriebnahmephase erlaubt mit dem trainierten Modell die Überprüfung, ob die Maschinenarbeit und damit deren Steuerungs- und Regelmechanismen der qualitativen Vorgabe entspricht. Damit ist eine Arbeitsvorbereitung durchzuführender Stopfarbeiten für ein optimales Ergebnis möglich.

Abb. 3 zeigt das Prinzip des verwendeten unsupervised KI-Programms. Es nutzt den Höhenfehler eines bekannten Gleisabschnitts als Eingangssignal, bezeichnet als „Vor der Arbeit“ (1). Dieses Eingangssignal ist eine Überlagerung einer nicht bekannten Anzahl von peri-

odischen Gleisfehler-Wellensignalen, die den Gleishöhenfehlerverlauf darstellen. Das Encoder-Netz (2) analysiert das Eingangssignal und unterteilt es in Signalbestandteile, gewichtet nach deren Relevanz für das Gesamtsignal (3); auf dem Eingangssignal dominante Wellenlängen erhalten dabei eine höhere Gewichtung als Wellenlängen mit einem geringen Beitrag. Das durch mehrere Schichten des Encoder-Netzes encodierte Signal wird einerseits direkt an ein Decoder-Netz (4) und parallel dazu an ein weiteres, tiefes neuronales Netz (Deep Neural Network – DNN) (6) weitergeleitet.

Das Decoder-Netz (4) setzt die einzelnen Signalbestandteile nach deren Gewichtung wieder zusammen und errechnet ein Ausgabesignal. In Schritt (5) wird eine Ausgabe „vor der Arbeit“ generiert, die dem Eingangssignal „vor der Arbeit“ so gut wie möglich entsprechen soll. Je stärker diese Ausgabe von der ursprünglichen Eingabe abweicht, desto schlechter funktioniert die Encoder-Decoder-Pipeline (3). Dieser Vergleich wird durch eine Kostenfunktion bzw. Bewertungsfunktion abgebildet, die die Differenzen zwischen dem Eingangssignal „vor der Arbeit“ und dem Ausgangssignal „vor der Arbeit“ bildet. Mithilfe dieser Kostenfunktion und der vorab nicht bewerteten Trainingsdaten werden Encoder- und Decoder-Netz trainiert (unüberwachtes Lernen). Die Qualität des Gesamtsystems

hängt dabei von der Größe des zur Verfügung stehenden Trainingsdatensatzes ab.

Um eine Prognose des zu erwartenden Höhenfehlers für den gewählten Gleisabschnitt „nach der Arbeit“ zu erhalten, wird das Signal durch das DNN (6) transformiert, bevor es dem Decoder-Netz übergeben wird. In Schritt (7) entsteht eine abgewandelte Repräsentation der Daten, die in Folge an das Decoder-Netz (4) übergeben werden. Das Decoder-Netz errechnet die Prognose des Höhenfehlers „nach der Arbeit“ als Ausgangssignal (8). Das DNN (6) wird ebenfalls unüberwacht trainiert. Der Trainingsdatensatz besteht neben dem Höhenfehler „vor der Arbeit“ noch aus den ausgezeichneten Ergebnissen, also den Resthöhenfehlern „nach der Arbeit“. Aus den gesamten zur Verfügung stehenden Trainingsdatensätzen wird ein Teil (5 %-10 %) zur Validierung des DNN verwendet, diese spiegelt die Qualität der Prognose wider.

In der Praxis wird bei gegebener Höhenfehlerlage eines Gleisabschnitts das zu erwartende Ergebnis der Bearbeitung durch eine Stopfmaschine auf die geschilderte Weise vorab errechnet. Die Kenntnis der Gleislagefehler vor der Stopfarbeit resultiert aus der üblichen Vormessung. Die Diskrepanz des Ergebnisses der Bearbeitung zum prognostizierten Ergebnis deutet auf sich abzeichnende Probleme der Stopfmaschine hin.

Die Abb. 4 zeigt im oberen Diagramm einen vor der Stopfarbeit ermittelten Gleislagefehlerverlauf. Die blaue Linie ist der gemessene Originalfehler. Die rote Linie entspricht der Rekonstruktion des Gleislagefehlerverlaufes „Vor der Arbeit“ durch die KI. Das rote Band zeigt den Rekonstruktionsfehlerbereich, also die Vorhersagequalität der KI. Im unteren Diagramm sagt die KI den nach der Arbeit der Stopfmaschine erwartbaren normierten Restfehlerverlauf voraus. Im praktischen Einsatz wird das Ergebnis einer Stopfarbeit mit der Vorhersage der KI verglichen. Zeigen sich zu große Abweichungen, kann auf ein sich verschlechterndes Arbeitsverhalten der Maschine geschlossen werden. Der Kunde wird in diesem Fall informiert und die Überprüfung durch Servicepersonal empfohlen.

Spezifische Überwachung der Arbeitsregelkreise

Durch den Einsatz der beschriebenen KI zur Vorhersage des Arbeitsergebnisses kann zwar eine sich anbahnende Fehl- oder Minderfunktion der Gesamtmaschine ermittelt werden. Allerdings ist die Angabe des spezifischen Grundes (noch) nicht möglich.

Der wesentlichste Einflussfaktor auf die Qualität der Gleislageberichtigung sind die Regelkreise,

die die Höhe und die Richtung des Gleises mithilfe des Hebe-Richt-Aggregates korrigieren. Die verwendeten Aktoren sind Hydraulikzylinder, die über Proportionalventile und PID-Regler geregelt werden. Unzureichende Regelgüten sind häufig auf Probleme mit den Hydraulikzylindern (mechanischer Verschleiß, Leckagen), verschmutzte Regelventile, Hard- oder Softwarefehler, Wechsel von Bauteilen ohne Überprüfen der Regelfunktionen, Ablagerungen im Ölkreislauf, Verschleiß der Hydraulikleitungen, Verstellung der Regelparameter oder das Auftreten neuer Störgrößen zurückzuführen. Zur Überwachung der Regler wird ein Überwachungsmodul eingesetzt, welches Kennzahlen zur Bewertung der Regelgüte liefert. Jedes der Proportionalventile der Regelkreise wird hinsichtlich seiner Funktion überwacht. Auch die einwandfreie Funktion der Regelventile der vollhydraulischen Stopfaggregate wird überwacht. Diese Überwachung der Arbeitsregelkreise erlaubt im Falle einer Abweichung der Arbeitsqualität der Stopfmaschine konkrete Rückschlüsse auf die Störeinflüsse. Der Mehrwert der Überwachung der Stopfergebnisse durch die KI besteht darin, dass sie schon frühzeitig Systemfehler erkennt, die dann mittels des Überwachungsmoduls gezielt lokalisiert werden können. ■

QUELLEN

- [1] Hodge, V. J.; O'Keefe, S.; Weeks, M.; Moulds, A.: Wireless Sensor Networks for Condition Monitoring in the Railway Industry: A Survey, IEEE Transactions on Intelligent Transportation Systems, Volume 16, No. 3, June 2015, pp. 1088-1106
- [2] Errandonena, I.; Beltrán, S.; Arrizabalaga, S.: Digital Twin for maintenance: A literature review, Computers in Industry, Volume 123, 2020
- [3] Falekas, G.; Karlis, A.: Digital Twin in Electrical Machine Control and Predictive Maintenance: State-of-the-Art and Future Prospects, Energies Volume 14, 5933, 2021
- [4] Lichtberger, B.: Bahnindustrie 4.0: Innovative Railway Vehicle Monitoring RaVeM in der Anwendung, ZEVrail 140, 5/2016, S. 179-187
- [5] Lichtberger, B.: Das Große Handbuch der Gleisinstandhaltung, Band 2, tredition Verlag GmbH, Hamburg, 2023
- [6] Lichtberger, B.: Auf dem Weg zum autonomen Arbeiten – der Universal Tamper 4.0, EIK – Eisenbahningenieur Kompendium, 2022, S. 15-40



Univ.-Doz. Dr. Bernhard Lichtberger

Technischer Direktor
System7 rail GmbH, AT-Laakirchen
bernhard.lichtberger@s7-rail.com

Wir sind dort, wo Ihre Kunden sind.

1. Halbjahr 2024

DER **EI**
EISENBahn
INGENIEUR

Heft Nr. 1/24

► 16.01. – 17.01.24
68. VDEI Eisenbahntechnische Fachtagung, Leipzig

Heft Nr. 3/24

► 12.03.2024
65. VDEI Oberbauaufschlagung, Darmstadt
► 20.03. – 21.03.2024
VDEI Tagung Flächenmanagement, Fulda

Heft Nr. 5/24

► 14.05. 16.05.24
IT-Trans, Karlsruhe
► 10.06. - 12.06.24
VDV-Jahrestagung, Düsseldorf

JANUAR
2024

FEBRUAR
2024

März
2024

APRIL
2024

MAI
2024

JUNI
2024

Heft Nr. 2/24

► 14.02. – 15.02.24
14. VDEI Tiefbau-Fachtagung, Radebeul
► 22.02. – 23.02.24
26. Jahresfachtagung der Eisenbahnsachverständigen, Fulda
► 06.03. – 07.03.24
8. Symposium Eisenbahnbrücken und KIB, München

Heft Nr. 4/24

► 17.04. – 18.04.24
Railway Diagnostic and Monitoring Conference, Köln

Heft Nr. 6/24

► 17.06. - 18.06.24
VDEI Eisenbahntage, Chemnitz
► 25.06.24
7.Eurailpress-Forum Alternative Antriebe im SPNV, Hamburg

Weitere Infos: Silke Härtel • Telefon: 040/237 14-227 • silke.haertel@dvvmedia.com

Änderungen vorbehalten.