Homepageveröffentlichung unbefristet genehmigt für FCE-Frankfurt Consulting Engineers GmbH / Rechte für einzelne Downloads und Ausdrucke für Besucher der Seiten genehmigt von DVV Media Group, 2018.

Ausfallprognose als Baustein der Condition Based Maintenance im Instandhaltungssystem eines EMU

Das Feld der Datenanalyse hat im industriellen Maßstab in den letzten 15 Jahren massiv an Bedeutung gewonnen. Experten finden dabei immer stärker auch funktionale Anwendungen in der Instandhaltung. Eine naheliegende Anwendung aus der Sicht der Deutschen Bahn ist eine technisch abgesicherte Ausfallprognose für Komponenten, die als Baustein zur Integration in die Condition Based Maintenance (CBM) im Instandhaltungssystem (IH-System) dient.

1. WEITERENTWICKLUNG DER INSTANDHALTUNGSKONZEPTE

Die kontinuierliche Weiterentwicklung der heutigen Instandhaltung durch CBM-optimierte Eingriffszeitpunkte von IH-Maßnahmen für Systeme, Subsysteme und Komponenten zeigt wesentliche Vorteile gegenüber dem eingespielten Instandhaltungsmix aus präventiver und korrektiver Instandhaltung auf. Das Ausschöpfen der Abnutzungsvorräte und ein reduziertes Ausfallrisiko durch die Verzahnung im IH-System von Datenerhebung, Zustands-Monitoring, mathematischen Auswertungen, Ausfallprognose und daraus begründeten IH-Maßnahmen schaffen neue Optionen und Perspektiven für zeitliche und inhaltliche Planbarkeit innerhalb der Instandhaltung. Somit sind das Zustandsmonitoring und die Prognose aus in den Zustandsdaten erkannten Mustern ein wesentlicher Beitrag zur Steigerung von Verfügbarkeit und Qualität im Instandhaltungssystem bei verminderten Kosten.

Mit ersten Anwendungsuntersuchungen bei Instandhaltung von Schienenfahrzeugen wurde dabei 2013 die DB Systemtechnik GmbH beauftragt und hat zum Datamining die Fa. FCE Frankfurt Consulting Engineers eingebunden. Das Streben der Ingenieure und Instandhalter nach einer treffsicheren Früherkennung sich anbahnender Defekte an Zügen und Infrastruktur verspricht seit Mitte der 2000er Jahre Wirklichkeit zu werden. Es begannen sich schnelle Algorithmen zur Klassifikation hochdimensionaler Sensordaten (d. h. die Dimension der Parameter in statistischen Modellen ist größer als die Anzahl der Daten in der Stichprobe) in unterschiedlichen Industriebereichen durchzusetzen. Eines der in den Medien häufiger angeführten Beispiele sind die sogenannten Neuronalen Netze, mit denen es gelang, im Rahmen der Mustererkennung an zweidimensionalen Bildern Objekte zu identifizieren. Das Verfahren entstammt der Methodik des Maschinellen Lernens, bei der dem Rechner eine große Zahl von Mustern gleichzeitig mit dem zu identifizierten Objekt präsentiert werden, die es gestatten, Funktionen zu entwickeln, die bei Anwendung auf das Muster das wahrscheinlichste Objekt vorschlagen.

Das Ziel der zustandsorientierten Instandhaltung besteht in der frühzeitigen Vorhersage anomaler Zustände und dazu adäquater Instandhaltungsmaßnahmen. Dies ist die zentrale Herausforderung bei der Erzeugung relevanter Prognoseergebnisse von Verschleißerscheinungen bis hin zu Ad-Hoc-Ausfällen.

Der Komponentenverschleiß wird hierbei aus den Datenspeichern der Diagnosesysteme extrahiert, die entsprechenden Abnutzungsvorräte systemseitig erfasst und mit den definierten, qualitativ erforderlichen, technischen und betrieblichen Abnutzungsvorräten für den ungestörten Komponentenbetrieb verglichen. Dabei soll die Vorwarnzeit so groß sein, dass innerhalb dieser Zeit ein vorbeugender Eingriff in das System erfolgen kann, so dass ein tatsächlicher Komponentenausfall vermieden wird. Die Vorhersage kritischer Zustände und Ereignisse soll mit einer hohen gerechtfertigten Warnrate und geringen übersehenen Ereignissen getroffen werden. Die prognostizierte Vorwarnzeit muss entsprechend als zeitlicher Vorlauf (Reaktionszeit) für die Instandhaltungswerkstatt zur Disposition der Arbeitsaufträge angemessen sein [1].

Diesbezüglich ist die Diagnose, d. h. das Erkennen von Ereignismustern oder anoma-

Dipl.-Ing. Patrick Linke
Senior Instandhaltungsspezialist
DB Systemtechnik GmbH
Arbeitsschwerpunkte: Projektmanagement F&E für CBM-Fahrzeuge/Infrastruktur sowie die rechtssichere und praktische Überführung in komplexe Instandhaltungssysteme/Prozesse
patrick.linke@deutschebahn.com

Dipl.-Math. Daniel Jaroszewski
Softwareentwickler und Anwendungsberater, FCE-Frankfurt Consulting Engineers GmbH
Arbeitsschwerpunkte: Entwicklung und Programmierung von angewandten mathematischen Algorithmen des maschinellen Lernens
daniel.jaroszewski@frankfurtconsultingengineers.de

Dipl.-Ing. Christian Hocke
Leiter Instandhaltung
DB Regio AG
Arbeitsschwerpunkte: Verantwortlich für die betriebsnahe Fahrzeuginstandhaltung der Region Nordost
christian.hocke@deutschebahn.com

Co-Autoren

Dipl. Ing. Olaf Möller
Leiter Instandhaltung Berlin
DB Regio AG
olaf.moeller@deutschebahn.com

Michael Regel
Fertigungsleiter Instandhaltungsteam Berlin
DB Regio AG
michael.regel@deutschebahn.com

M. Sc. Larissa Laumann
Softwarearchitektin
FCE Frankfurt Consulting Engineers GmbH
larissa.laumann@frankfurtconsultingengineers.de

Homepageveröffentlichung unbefristet genehmigt für FCE-Frankfurt Consulting Engineers GmbH / Rechte für einzelne Downloads und Ausdrucke für Besucher der Seiten genehmigt von DVV Media Group, 2018.

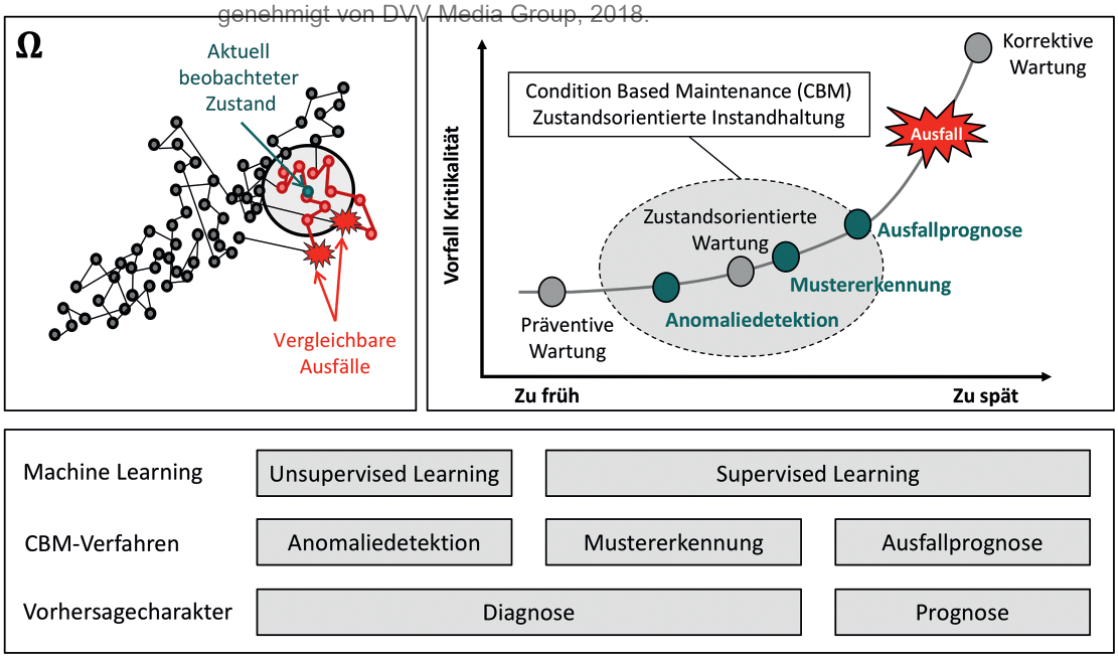

BILD 1: Die linke obere Grafik veranschaulicht das Erlernen von Mustern vor Ausfällen; die rechte obere Grafik zeigt Instandhaltungsstrategien in Abhängigkeit zur Vorfallkritikalität und der zeitlichen Einordnung als Basis für optimierte CBM Eingriffszeitpunkte; die untere Grafik kategorisiert die CBM-üblichen Verfahren

len Zuständen an überwachten Systemen, der Ansatz, die Vorhersage solcher Ausfälle mit relevantem zeitlichen Vorlauf (Prognose) durchzuführen. Diese gelingt dann, wenn man präkritische Zustände erkennen kann, aus denen Vorhersagen technischer Systemausfälle ableitbar sind.

2. DER BRÜCKENSCHLAG VON DER THEORIE ZUR PRAXIS

Die Überführung in den betrieblichen Instandhaltungsprozess wird anhand ausgewählter und verifiziert auffälliger Komponenten erprobt. Auf Basis von Flottendaten der BR 442 erfolgt der praktische Nachweis mit dem Ziel, kritische Zustände mit hoher Wahrscheinlichkeit zu prognostizieren, Muster in den Ereignisdaten zu identifizieren, präzise zu warnen und einen zeitlich geeigneten Vorwarnzeitraum für die Instandhaltung zu schaffen.

Für die Vorbereitung der praktischen Pilotierung wurde der bestehende Prozess innerhalb der DB Regio Werkstatt Berlin Lichtenberg aufgenommen und in einen funktionalen Prozessablaufplan (PAP) überführt. Die Rollen und Verantwortlichkeiten sind diesbezüglich definiert und auch den einzelnen Prozessschritten im praktischen Werkstattdurchlauf innerhalb der Instandhaltung zugeordnet. Der avisierte Projektablauf und die Projektorganisation teilten sich somit in die grundsätzlichen Themenschwerpunkte auf:

- → Abstimmung von Randbedingungen für ein realisierbares „Integrationskonzept CBM“ in der Regio Werkstatt Berlin Lichtenberg (Aufstellung Bearbeitungsorganisation Pilot)
- → Absicherung des Datenflusses und der zeitnahen Datenbereitstellung neu generierter Betriebsdaten innerhalb der Flotte (Datenüberführung in den IH-Wissenskreislauf)
- → Analyse der Archivdaten für die Auswahl und Präzisierung der angewandten „Supervised Learning“-Verfahren (Analyse und Voruntersuchung als rückblickende „retrospektive Prognose“)
- → Organisation von Datenbereitstellung und IH-Datenfluss im Werkstattbereich, als Verifikationsgrundlage für die Prognose (Abgleich von IH-Aufträgen zur Ausfallerkennung)
- → Transparente und verständliche Darstellung der abgegebenen Prognose zur Anwendung und zusätzlichen Information innerhalb der Werkstatt (Entwicklung eines PDF-Reports mit vorausschauender „prospektiver Prognose“).

Zur praktischen Prognoseanwendung wurden seit dem Frühsommer 2017 Ereignisdaten an Triebzügen vom Typ BR 442 an Stromrichtern ausgewertet. Bekannte auffällige Ereignisse bei der BR 442 sind Defekte an Hilfsbetriebestromrichtern, Netzstromrichtern und Motorstromrichtern, bei denen Leistungshalbleiter degradieren und schließlich ausfallen. Im Vorfeld dieser Defekte wurde auch ein enger Zusammenhang zwischen den Defekten und Witterungsbedingungen vermutet [2].

Am Beispiel eines Stromrichters zeigt Bild 3, wie mit Hilfe von logistischer Regression gewisse Defekte gut vorhergesagt werden können: »

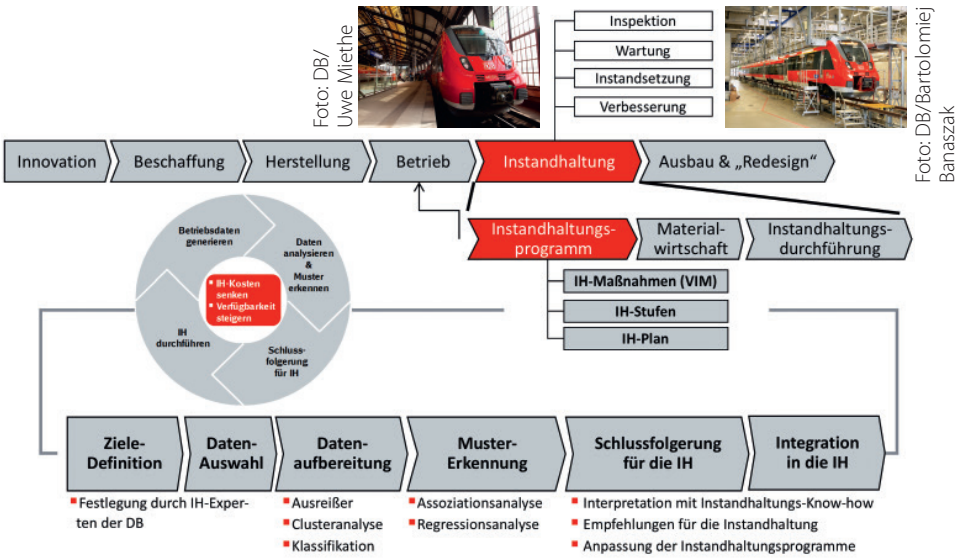

BILD 2: Überführung in den betrieblichen Instandhaltungsprozess

Homepageveröffentlichung unbefristet genehmigt für FCE-Frankfurt Consulting Engineers GmbH / Rechte für einzelne Downloads und Ausdrucke für Besucher der Seiten genehmigt von DVV Media Group, 2018.

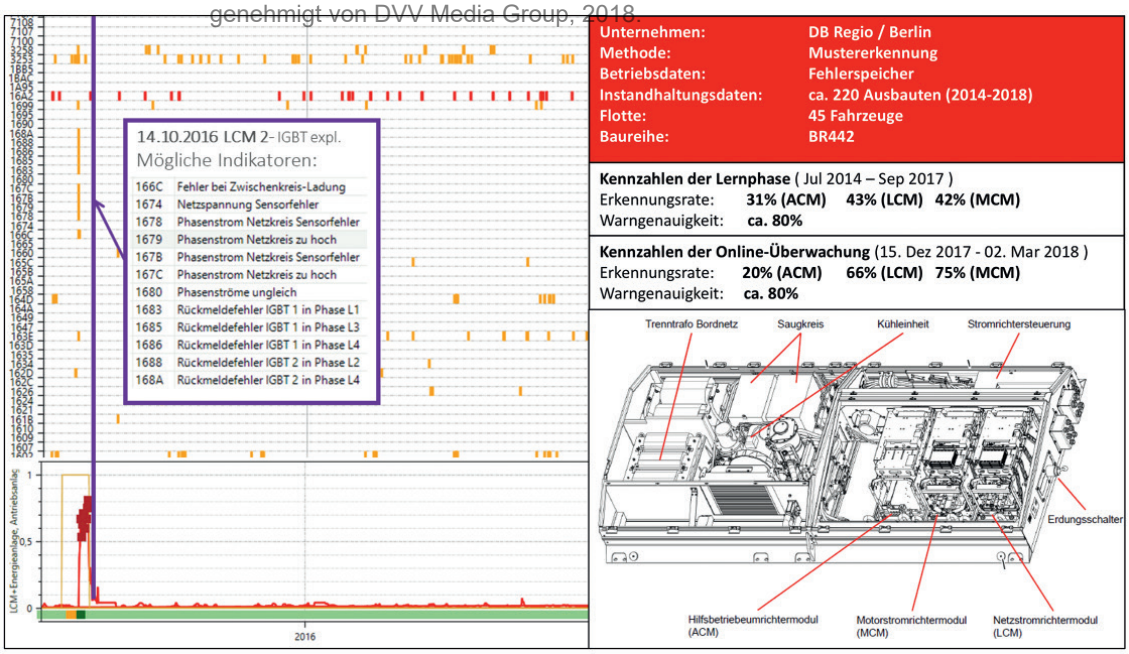

BILD 3: Die linke Grafik zeigt die Stromrichterausfallvorhersage mit Hilfe der logistischen Regression; die rechte Grafik enthält die Kennzahlen aus diesem Projekt (retrospektiv und prospektiv)

3. PROGNOSEGÜTE ALS ZIEL FÜR DIE VORBEUGENDE INSTANDHALTUNG

Das Ziel der zustandsbasierten Instandhaltung mit Ausfallprognose besteht in der frühzeitigen Vorhersage kritischer Ereignisse, zumeist Komponentendefekt und -ausfall. Dabei sollte die Vorwarnzeit so groß sein, dass innerhalb dieser Zeit ein vorbeugender Eingriff in das System so erfolgen kann, dass ein größerer Schaden, der einen Systemstillstand verursachen könnte vermieden wird.

Wahrscheinlichkeitsaussagen lassen sich treffend über zwei gegenläufige Kennzahlen bewerten. Der sogenannte Fehler erster Art gibt die Wahrscheinlichkeit dafür an, ein kritisches Ereignis vorherzusagen, das im Verlauf der Vorwarnzeit nicht eintritt. Der Fehler zweiter Art gibt die Wahrscheinlichkeit für einen übersehenen Defekt an. Der Fehler erster Art lässt sich nur zu Lasten des Fehlers zweiter Art reduzieren und umgekehrt; für die jeweilige Komponente und ihre Instandhaltung wird ein eigenes Optimum gefunden.

Das von der DB Systemtechnik GmbH im Jahre 2013 zusammen mit der Firma FCE Frankfurt Consulting Engineers gestartete Projekt unter dem Namen Zust-IH-Generik konzentrierte sich von Anfang an auf die Entwicklung von Algorithmen, die bei einer vorgegebenen, tolerablen maximalen Erkennungsrate (= 1-Fehler 2. Art) den Fehler erster Art minimieren [3] und [4].

Den Zusammenhang zwischen diesen Kenngrößen zeigt Bild 4.

Dabei können vier mögliche Fälle auftreten:

1. Richtig positiv: Die Komponente arbeitet fehlerhaft, und die Prognose hat dies richtig angezeigt
2. Falsch negativ: Die Komponente arbeitet fehlerhaft, aber die Prognose hat sie fälschlicherweise als korrekt arbeitend eingestuft
3. Falsch positiv: Die Komponente arbeitet korrekt, aber die Prognose hat sie fälschlicherweise als fehlerhaft arbeitend eingestuft
4. Richtig negativ: Die Komponente arbeitet korrekt, und die Prognose hat dies richtig angezeigt.

Die Abkürzungen erklären sich wie folgt:

→ #TN = True negatives = 1 - Fehler 1. Art
Anzahl der Intervalle, in denen kein Ereignis innerhalb von einem Horizon h vorhergesagt wird und in denen auch keines eintritt

→ #TP = True positive = 1 - Fehler 2. Art
Anzahl der Intervalle, bei denen ein Ereignis innerhalb von einem Horizon h vorhergesagt wurde und bei denen auch eines eintritt

→ #FN = False negative = Fehler 2. Art
Anzahl der Intervalle, bei denen kein Ereignis innerhalb von einem Horizon h vorhergesagt wurde und bei denen trotzdem eines eintritt

→ #FP = False positive = Fehler 1. Art
Anzahl der Intervalle, bei einem Ereignis innerhalb von einem Horizon h vorhergesagt wurde und bei denen trotzdem keines eintritt

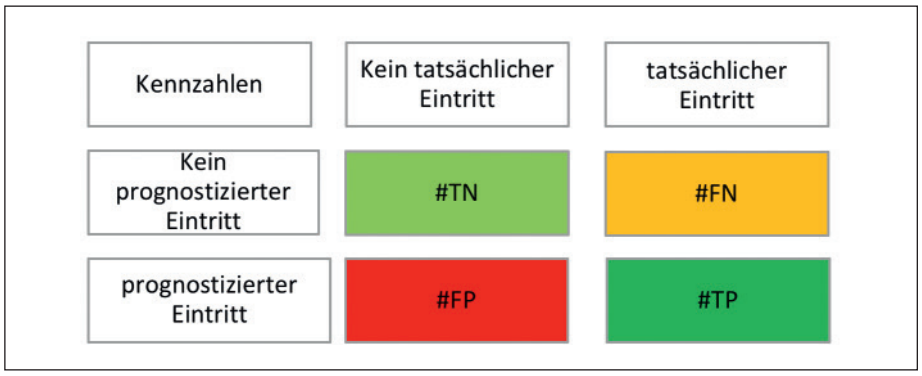

BILD 4: Wahrheitsmatrix als Grundlage für weitere Kennzahlen

Zur Veranschaulichung ein kleines Beispiel anhand der folgenden Skizze (Bild 5):

Unter zur Hilfenahme der Klassifikationsgrößen lassen sich statistische Kennzahlen zur Prognosegüte ableiten. Im weiteren Verlauf des Dokumentes werden häufig die Erkennungsrate und die Genauigkeit eines Modells in Erscheinung treten.

I. Erkennungsrate

$$\frac{\#\ \text{prognostizierte Ereignisse}}{\#\ \text{alle Ereignisse}}$$

Homepageveröffentlichung unbefristet genehmigt für FCE-Frankfurt Consulting Engineers GmbH / Rechte für einzelne Downloads und Ausdrucke für Besucher der Seiten genehmigt von DVV Media Group, 2018.

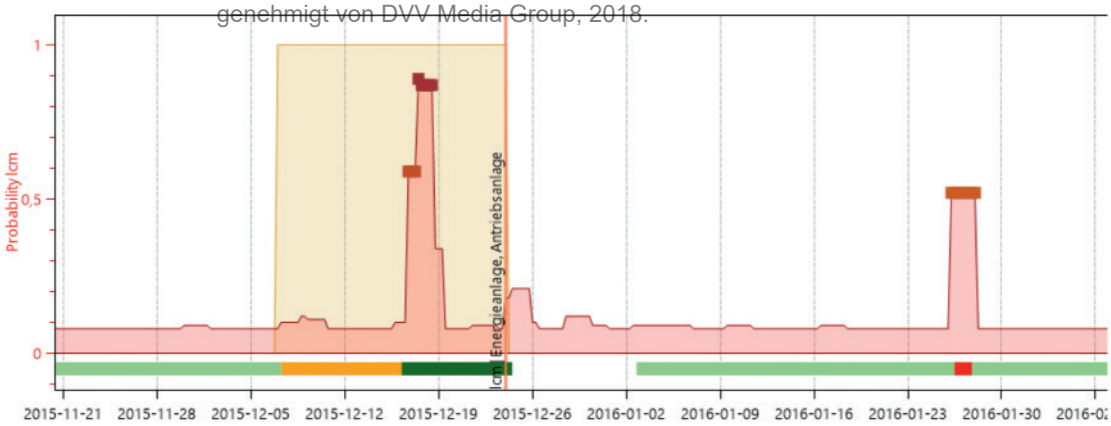

BILD 5: Jeder Auswertungszeitpunkt wird gemäß den oben definierten Klassifikationsgrößen bewertet.

II. Genauigkeit

$$\frac{\#\text{ erfolgreiche Warnungen}}{\#\text{ alle Warnungen}}$$

III. Fehler 2.Art „übersehener Defekt“

$$\frac{\#\text{ FN}}{\#\text{ FN} + \#\text{TP}}$$

IV. Fehler 1.Art „blinder Alarm“

$$\frac{\#\text{ FP}}{\#\text{ FP} + \#\text{TN}}$$

4. ANWENDUNG VON MATHEMATISCHEN PROGNOSEMETHODEN

Eine langjährige Entwicklungsarbeit an Prognosemethoden führte zur Verfahrensklasse, die man als Supervised Learning bezeichnet und die auch für Anwendungen in der Vorbeugenden Instandhaltung geeignet sind. Das Erlernen von anomalen Schadmustern kurz vor Komponentenausfällen, sowie das Erkennen von präkritischen Betriebszuständen fällt in diese Kategorie.

Im Begriff Supervised Learning [5] steckt das Wort „beaufsichtigt“ und dieses steht für eine spezifische Klassifizierung bestimmter Ausprägungen. Der Algorithmus lernt eine Funktion aus gegebenen Paaren von Ein- und Ausgangsdaten. Dabei stellt während des Lernens ein IH-Experte als „Lehrer“ den korrekten Funktionswert zu einer Eingabe bereit. Ziel beim überwachten Lernen ist, dass nach mehreren Rechengängen mit unterschiedlichen Ein- und Ausgaben die Fähigkeit antrainiert wird, Assoziationen herzustellen. Genau darin besteht bei der technischen Systemüberwachung die Herausforderung. Häufig sind Instandhaltungen am Fahrzeug nicht vollumfänglich und komplex detailliert registriert. Entsprechend sind sie auf einer zu allgemeinen Ebene oder zeitlich verschoben erfasst. Diese verfügbaren Informationen stehen beim Überwachten Lernen zur Verfügung, somit besteht eine unmittelbare Abhängigkeit zur Menge und Qualität der Daten. Mit diesen Unsicherheiten muss die entwickelte CBM-Lösung reproduzierbar umgehen können.

Besonders wichtig ist bei diesem Verfahren der zu analysierende Zustandsraum und dieses Wort bedarf selbstverständlich einer Erklärung. Die Überwachung auf Basis von Sensordaten (auch als Primär- oder Rohdaten bezeichnet, die eine Messgröße im Zeitverlauf abbilden) unterscheidet sich von der Überwachung von Diagnosedaten (auch als Sekundärdaten bezeichnet, die aus Primärdaten durch Modellierung und Verarbeitung hervorgehen) in Fehlerspeichern und der darauf angewandten Aggregierung. Ob man z. B. den Maximalwert eines Druckes im Sekundentakt betrachtet oder ob man ihn auf Minutenebene mittelt, führt im zeitlichen Verlauf des Signalwertes zu unterschiedlichen Zahlenwerten. Solche Einstellungsmöglichkeiten sollten mit einer möglichst einfachen und performanten Software realisierbar sein oder vom Algorithmus selbst optimiert gewählt werden können. Diese Phänomene bei der Analyse von Sensordaten gelten grundsätzlich auch für Fehlerspeicherdaten. Der Zustandsraum bei Fehlerspeichern hängt eher von der mehrdimensionalen Betrachtung aller systemrelevanten Diagnosecodes ab. Der gemeinsame Nenner beider Datenquellen ist jedoch die große Auswirkung der Datenvoraggregierung auf die Prognosegüte.

Erst nach diesem Schritt folgen Berechnungsalgorithmen, die unter dem Namen „Machine Learning“ oder dem Marketing-Ausdruck „Künstliche Intelligenz“ bekannt sind. Man könnte auch von dynamischen Klassifikations- und Regressionsverfahren sprechen. In unseren Berechnungen wurden folgende Algorithmen benutzt:

I. K-Nearest Regression (Closest mit K=1)
II. Kernel Regression [5] und [7]
III. Logistische Regression
IV. Neuronale Netze (RBFNN) [6]

Im Laufe der Jahre ist eine native und selbstprogrammierte NET-Bibliothek für nichtlineare Regressionsverfahren entstanden, welche den Kern der Prognosealgorithmen darstellt. Das Projekt hat sich auf die oben genannten Algorithmen konzentriert, da sich diese erfahrungsgemäß als sehr robust gegenüber Änderungen der Datenmenge und -qualität herausgestellt haben. Es werden parametrische und nicht-parametrische Regressionen in Abhängigkeit davon angewendet, ob die Daten normalverteilt sind oder nicht. Der wesentliche Unterschied ist, dass nicht-parametrische Verfahren alle Trainingsdatenpunkte in der Evaluierungsphase benötigen und dadurch aufwendiger sind.

Abschließend kann man wohl sagen, dass Algorithmen stark von der zu erlernenden Klassifikation abhängen, so dass Erfahrung und mathematisches „Fingerspitzengefühl“ einen hohen Stellenwert bei der Entwicklung des Prognosebausteins für die CBM haben. Die Erfassung und Auswertung von Instandhaltungsdaten beeinflusst die Vorhersagen maßgeblich und bestimmen die Aussagendefinition und -genauigkeit [8].

Als praxistaugliche Handlungsempfehlung im Werkstattprozess ist eine spezifische Software zur Identifizierung von kritischen Bauteilen in Anwendung zu bringen. Die Zusammenführung von Prognosemodellierung, Daten-Monitoring, Ergebnisverwertung und die Visualisierung der Handlungsempfehlung für die Instandhaltung ist hierbei unverzichtbar [9].

5. AUSBLICK AUF WEITERE ZIELFÜHRENDE MATHEMATISCHE KONZEPTE

Eine weitere Möglichkeit ist die Anwendung von systemspezifischem Fachwissen und Instandhaltungs-Know-how. Die Platzierung von Markierungen zu Zeitpunkten von präkritischen Mustern kann nachfolgend mit den Mustererkennungsverfahren eingelernt werden. Dies bezeichnen wir als „intelligen- »

Homepageveröffentlichung unbefristet genehmigt für FCE-Frankfurt Consulting Engineers GmbH / Rechte für einzelne Downloads und Ausdrucke für Besucher der Seiten genehmigt von DVV Media Group, 2018.

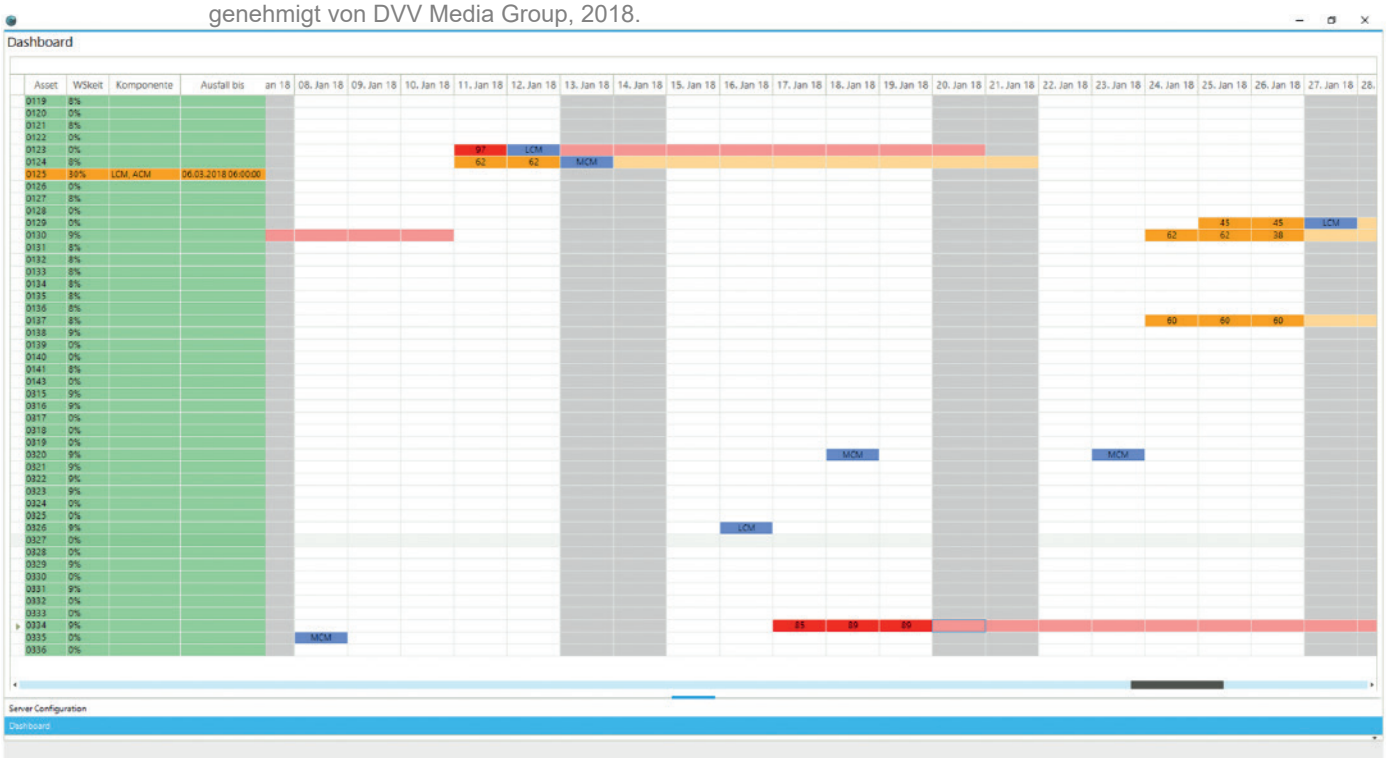

BILD 6: Operatives Dashboard zur historischen und zukünftigen Übersicht der Ausfallprognosen und der Instandhaltungen

te Zähler". Hierbei kann eine anschließende Häufigkeitsanalyse zur Identifizierung eines Verschleißprozesses genutzt werden. Anders als im Supervised Learning werden hier keine Komponentenausfälle als mathematische Lerngrundlage benötigt.

Weiterführend stellt sich immer die Frage nach der Defektursache, welche durch eine Folge von Tests beantwortet werden kann. Bei redundanten Systemen gibt es die Besonderheit, dass die Wiederherstellung des Systems nicht nur durch Austausch der defektverursachenden Komponente geleistet werden kann. Vielmehr kann jedes Teil, das den defekten Funktionspfad überbrückt, das System wieder instandsetzen, wenn es selbst vor dem Defektverursacher ausgefallen war. Im Extremfall besteht ein Test darin, dass ein Kandidat vollkommen ausgetauscht wird und nachher ein Funktionstest durchgeführt wird.

Es seien Q_1 (t), Q_2 (t), Q_3 (t), …, die bedingten Wahrscheinlichkeiten dafür, dass die Komponenten 1,2,3, … den beobachteten Defekt verursacht haben. Des Weiteren seien $\tau^{(1)}, \tau^{(2)}, \tau^{(3)}, \ldots$, die Testdauern zur Verifikation bzw. Falsifikation der Defektvermutung. Die Komponenten seien nun so geordnet, dass

$$\frac{Q^{(1)}(t)}{\tau^{(1)}} \geq \frac{Q^{(2)}(t)}{\tau^{(2)}} \geq \frac{Q^{(3)}(t)}{\tau^{(3)}} \geq \ldots \qquad (1)$$

gilt. Man kann nun zeigen, dass genau diese Testreihenfolge die erwartete totale Testzeit bzw. die Testkosten minimiert. Zu beachten ist dabei, dass in der obigen Formel der Defektzeitpunkt t erscheint.

Dies bedeutet, dass es in der Regel keine Standardtestreihenfolge gibt, sondern dass man im Prinzip unter Zuhilfenahme von Formel (1) die optimale Reihenfolge jedes Mal neu berechnen müsste. Dies gilt allerdings dann nicht, wenn die Defektverursachungswahrscheinlichkeiten nur sehr schwach von t abhängen. Ist z. B. das betrachtete System eine logische Reihenschaltung aus Komponenten mit konstanten Ausfallraten , so kann man zeigen, dass die Formel (1) gleichbedeutend ist mit

$$\frac{\lambda^{(1)}}{\tau^{(1)}} \geq \frac{\lambda^{(2)}}{\tau^{(2)}} \geq \frac{\lambda^{(3)}}{\tau^{(3)}} \geq \ldots \qquad (2)$$

Im Falle einer Weibullverteilung muss man die Größen $Q^{(i)}(t)$ aus den Parametern der Weibullverteilung berechnen. Diese mathematischen Konzepte gilt es weiterführend für die Instandhaltung funktional nutzbar in die bestehende Prognosemethodik zu integrieren. ◀

Literatur

[1] Schulte Werning B.; Mösken H.; Linke P.; Hoksch V.; Uebel L.; Wolter K. U.: „Monitoring und Zustandsorientierte Instandhaltung von Schienenfahrzeugen und -fahrweg mittels Mustererkennung in Ereignisdaten", ZEVrail 140(2016), Tagungsband SFT Graz 2016, 214-223
[2] Linke P.; Jaroszewski D.; Regel M.: „Baustein Ausfallprognose zu CBM – Steigerung von Verfügbarkeit und Pünktlichkeit durch digitalisierte Ausfallprognose", 16. Internationale Schienenfahrzeugtagung, Tagungsband Rad Schiene Dresden, September 2018
[3] Mergenthaler W.; Käser H.: „Verfahren der Mustererkennung in der Instandhaltung von Schienenfahrzeugen", Schweizer Eisenbahn-Revue, Juni 2014
[4] Mergenthaler W.; Jaroszewski D.; Feller S.; Laumann L.: „A joint renewal process used to model event based data", Decision Analytics (2016) 3:2, DOI 10.1186/s40165-016-0019-9, SpringerOpen Journal, Februar 2016
[5] Hastie T.; Tibshirani R.; Friedman J.: „The Elements of Statistical Learning", Springer Second Edition, Stanford, 2008
[6] Kriesel D.: „Ein kleiner Überblick über neuronale Netze", Mai 2005 http://www.dkriesel.com/_media/science/neuronalenetze-de-zeta2-1col-dkrieselcom.pdf
[7] Kantz H.; Schreiber T.: „Nonlinear Time Series Analysis. Cambridge University Press", Dresden, 2004
[8] Jaroszewski D.; Laumann L.: „Vorbeugende Instandhaltung", fmpro service, April 2016
[9] Schulte-Werning B.: „On current Developments in Condition-Based Maintenance at DB", Conference The Rise of IoT & Big Data in Rail 2018, 29.05.2018, München

▶ SUMMARY

Failure forecast as a component of condition based maintenance in an EMU maintenance system

The field of data analysis on an industrial scale has greatly gained in importance in the last 15 years. So, experts find more and more functional applications in the maintenance service. From the point of view of the Deutsche Bahn, an obvious application is a technical secured failure forecast for components which will be integrated into the Condition Based Maintenance (CBM) being part of the maintenance system (IH) of the electrical multiple units.