

Aspekte einer datengetriebenen, zustandsabhängigen Instandhaltung

(Teil 2) Vom Merkmal zur Fehlerdetektion

René Schenkendorf
Thomas Böhm

Motivation

Beabsichtigt ein Infrastrukturbetreiber ein weit verteiltes Netz zustandsorientiert instand zu halten, kann nur eine sensorunterstützte Überwachung den Anlagenzustand kontinuierlich erfassen. Manuelle Inspektionen wären hier hochgradig unwirtschaftlich. Gleichwohl muss die anfallende Menge an Daten ebenfalls automatisch ausgewertet werden. Zum einen, weil sie für die manuelle Interpretation zu umfangreich ist. Zum anderen fehlen meist die Experten, die die Daten im richtigen Zusammenhang mit dem Anlagenverschleiß interpretieren können. Ging es im Teil 1 „Informativ Merkmalsextraktion als Basis einer zuverlässigen Zustandsdiagnose“ [1] um das Grundverständnis und das prinzipielle Vorgehen bei der Umsetzung einer datengetriebenen, zustandsabhängigen Instandhaltung, wird im vorliegenden Beitrag der Schritt von der Merkmalsbildung zur eigentlichen Fehlerdetektion vollzogen. Somit erweitert sich die betrachtete Wirkungskette beginnend von der Sensorik, den Daten, der Merkmalsextraktion hin zur automatisierten Fehlerdetektion der überwachten Infrastrukturelemente. Aus den Sensordaten abgeleitete, informative Merkmale bilden hierbei erneut die Grundlage. Darauf aufbauend wird ge-

zeigt, dass gerade die Auswertung einer Vielzahl von informativen Merkmalen und deren Wechselwirkung eine zuverlässigere Fehlererkennung ermöglicht. Da bereits im ersten Teil die vorgestellten Algorithmen anhand der Stromdaten eines Weichenantriebs illustriert wurden, dienen diese erneut, um die Theorie im praktischen Einsatz zu demonstrieren.

Merkmalsextraktion


Die Merkmalsextraktion ist essenziell für die Umsetzung einer datengetriebenen Fehlerdetektion von Infrastrukturelementen im Bereich des Eisenbahnwesens [1]. Zwar sind die ursprünglichen Sensordaten (z. B. Stromstärke, Vibration, Temperatur) die Grundvoraussetzung einer automatisierten Zustandsüberwachung, jedoch ermöglichen erst die aus den Rohdaten extrahierten informativen Merkmale eine sichere automatische Erkennung von sich anbahnenden Fehlzuständen bzw. Systemausfällen über einen längeren Betrachtungszeitraum hinweg. Ebenfalls wurde im ersten Teil gezeigt, dass unterschiedliche Merkmale sich deutlich in ihrem Informationsgehalt zum Zweck der Zustandsüberwachung unterscheiden. Für eine zuverlässige Fehlerdetektion sind insbesondere solche Merkmale relevant, die sich signifikant mit dem einhergehenden Verschleiß der überwachten Elemente ändern. In der praktischen Anwendung ist es üblich, nicht ausschließlich

ein einziges Merkmal zu analysieren. Das informativste/beste Merkmal gibt es in der Regel nicht. Erst die Auswertung von mehreren sinnvollen Merkmalen (Merkmale, die das Abnutzungsverhalten der überwachten Infrastrukturelemente widerspiegeln) führt in der Praxis zum gewünschten Ziel – eine zuverlässige, praxistaugliche, datengetriebene Fehlerdetektion. Für das Beispiel des Weichenantriebs bedeutet dies unter anderem, dass die Algorithmen verlässlich zwischen natürlichen Schwankungen der Stromumlaufdaten (Abb. 1(a)) und Anlagenfehlern (Abb. 1(b)) unterscheiden können. Die algorithmische Auswertung einer Vielzahl von Merkmalen bis einschließlich der automatisierten Erkennung von sich andeutenden Fehlern/Systemausfällen sind Schwerpunkte des vorliegenden Beitrags und werden in den nachstehenden Abschnitten näher beschrieben.

Von der Merkmalsvielfalt zur zuverlässigen Fehlerdetektion

Je nach Anwendungsfall ergibt sich eine Vielzahl von möglichen, sinnvollen Merkmalen, die aus den zur Verfügung stehenden Sensorrohdaten extrahiert werden können [1]. Zwar ist es erstrebenswert, die für die angedachte Fehlerdetektion ungeeignetsten Merkmale auszuschließen, jedoch bleibt in vielen Fällen eine hohe Anzahl von potenziellen, informativen Merkmalen übrig. Oftmals werden weit mehr als zehn verschie-

Abb. 1: Fehlerdetektion am Beispiel eines Weichenantriebs und den dazugehörigen Stromumlaufdaten



Einbeziehen der Korrelationseigenschaft




Abb. 2: Gegenüberstellung der individuellen Merkmalsbetrachtung und der Korrelationseigenschaft

dene Merkmale zeitgleich bestimmt. Der Umgang mit dieser Merkmalsvielfalt kann sowohl bei der Interpretation/Auswertung als auch bei der Visualisierung/Darstellung/Speicherung zu Schwierigkeiten führen. Eine Reduktion der beschriebenen Merkmalskomplexität kann hierbei Abhilfe schaffen. Prinzipiell können hierzu verschiedene Ansätze umgesetzt werden, beispielsweise die Multidimensionale Skalierung (Multi Dimensional Scaling – MDS), die Faktorenanalyse oder die Hauptkomponentenanalyse (Principle Component Analysis – PCA) [2]. Im vorliegenden Beitrag wird jedoch ausschließlich PCA angewandt. Sie nutzt die Korrelation zwischen den berechneten Merkmalen aus und hat sich in einer Vielzahl von Anwendungen im Bereich der Zustandsüberwachung bewährt.

Korrelationseffekt

Der Korrelationseffekt ist ein zusätzlicher, wichtiger Informationsträger für die angedachte Fehlerdetektion und kann mit Methoden der Multivariaten Datenanalyse, also dem Betrachten der Merkmalsänderungen in ihrer Gesamtheit, berücksichtigt werden. Ein Ziel der Multivariaten Datenanalyse innerhalb der Fehlerdetektion ist es, Verletzungen der Korrelationseigenschaften festzustellen [3]. Wenn beispielsweise ein Anstieg des Merkmals A immer mit einem Anstieg des Merkmals B einhergeht und plötzlich das Gegenteil zu beobachten ist, kann dies auf einen sich anbahnenden Fehler hindeuten – mindestens jedoch ist eine Auffälligkeit zu attestieren, welche intensiver untersucht werden muss (Abb. 2). Zusammenfassend betrachtet, liefert die Multivariate Datenanalyse zuverlässigere Fehlergrenzwerte im Vergleich zu den Grenzwerten, die auf individuellen Merkmalsbetrachtungen basieren. Da weitere Einflussfaktoren, wie Umweltfaktoren

(z. B. Temperatur) als auch betriebliche Parameter (z. B. Liegedauer, Achslast), in die Multivariate Datenanalyse als Merkmale berücksichtigt werden können, ergeben sich robustere Grenzwerte und folglich eine Reduktion von Falschmeldungen – das Vertrauen der Anwender wird gestärkt. Werden auch statische Eigenschaften der Elemente (z. B. Bauartausführung) mit einbezogen, kann zudem die Interpretation der Fehlerbilder individueller und ursachenbezogener gestaltet werden.

Dimensionsreduktion via Hauptkomponentenanalyse

Das Ziel der Hauptkomponentenanalyse ist es, die hohe Anzahl von informativen Merkmalen auf wenige Ersatzgrößen, die sogenannten Hauptkomponenten, zu reduzieren, ohne jedoch den Informationsgehalt wesentlich zu mindern. Da sich beispielsweise die Entwicklung von mehreren betrachteten Merkmalen ähneln kann – die Merkmale sind miteinander korreliert –, ist es möglich, den generellen Verlauf dieser Merkmale mithilfe einer einzigen Ersatzgröße zu beschreiben. Die mathematischen Grundlagen sind in der einschlägigen Literatur zu finden [4, 5]. In vielen Anwendungen genügen drei bis fünf Ersatzgrößen/Hauptkomponenten, um den ursprünglichen Informationsgehalt adäquat wiederzugeben. Eine sinnvolle Repräsentation und Interpretation der Daten wird somit in der Regel erst möglich. Wie gut sich eine hohe Anzahl von Merkmalen durch nur wenige Ersatzgrößen repräsentieren lässt, hängt entscheidend von der Korrelation der verwendeten Merkmale ab. Hierbei gilt, je stärker die Merkmale untereinander korreliert sind, desto weniger Ersatzgrößen/Hauptkomponenten werden benötigt. Prinzipiell ließe sich eine Fehlerdetektion allein anhand der weiteren Aus-

wertung der Ersatzgrößen realisieren [6, 7], nachfolgend wird andererseits gezeigt, wie eine zusätzliche Reduktion der Informationsträger zu einem weit verbreiteten Ansatz der Zustandsüberwachung führt.

Statistische Prozessüberwachung

Die Methoden der Statistischen Prozessüberwachung (Statistical Process Control – SPC) bauen auf den zuvor beschriebenen Konzepten der Multivariaten Datenanalyse und der Hauptkomponentenanalyse auf [8]. In der SPC wird die Merkmalsvielfalt auf ausschließlich zwei Kenngrößen reduziert. Die erste Kenngröße wird mithilfe der dominantesten Hauptkomponenten der PCA berechnet und in der Literatur als Hotelling-Parameter (T^2) bezeichnet. Die zweite Kenngröße, der Squared Prediction Error (SPE), ergibt sich aus den verbleibenden, weniger dominanten Hauptkomponenten der PCA. Es existieren zwar auch andere Wege und Verfahren, um eine datengetriebene, zustandsorientierte Instandhaltung zu realisieren. Gemeint sind hauptsächlich überwachte Lernverfahren der Mustererkennung (Pattern Recognition) [9, 10]. Aber die SPC ist besonders gut geeignet, wenn tatsächliche Zustandsreferenzen fehlen oder zu unsicher sind.

Die getrennte Betrachtung dieser zwei Größen hat einen entscheidenden Vorteil. Änderungen in den Merkmalen, welche nicht mit einem bekannten bzw. normalen Verhalten des betrachteten Infrastrukturelements erklärt werden können, führen zu starken Änderungen in den SPE-Werten. Eine Fehlerdetektion wird somit erleichtert. Stimmen die Merkmalsänderungen mit den bisher bekannten wesentlichen Verhaltenseigenschaften jedoch überein, sind diese Änderungen nicht zwangsläufig anhand der SPE-Werte erkennbar. Stattdessen führen sie zu starken Änderungen des Hotelling-Parameters. Eventuelle Grenzwertverletzungen des T^2 -Wertes deuten somit nicht automatisch auf einen Fehler hin. Vielmehr ist es wahrscheinlich, dass die Abweichungen in den Merkmalen durch sich verändernde Umwelt- bzw. Betriebsbedingungen hervorgerufen werden, die zuvor nicht Bestandteil der historischen Datenaufzeichnung waren und damit der Datenanalyse nicht bekannt sind. Nach einer Plausibilitätsprüfung mit Instandhalten zur möglichen Ursache ist in diesem Fall eine erneute Datenanalyse (PCA/SPC) mit einem erweiterten Datensatz durchzuführen.

Zum Zweck der Fehlerdetektion lassen sich für beide Kenngrößen Grenzwertüberschreitungen auswerten. Die jeweiligen Grenzwerte sind statistisch bestimmt und spiegeln die dazugehörigen multivariaten statistischen Eigenschaften wider. Eine statistisch abgesicherte Fehlerdetektion ist

somit für beide Kenngrößen gewährleistet – eine aufwändige händische Grenzwertfestlegung entfällt.

Zusammenfassend heißt dies, dass die ursprüngliche Merkmalsvielfalt auf zwei charakteristische Werte der statistischen Prozessüberwachung abgebildet wird. Eine Interpretation und Visualisierung des Infrastrukturzustandes ist somit leicht möglich. Darüber hinaus können Änderungen an der Sensorik (höhere Abtastrate, zusätzliche Messsensoren etc.) bzw. an der Merkmalsdefinition/-anzahl vorgenommen werden, ohne dass sich Änderungen auf der Seite der Dateninterpretation/-visualisierung ergeben. Die SPE- und T^2 -Werte bleiben die einzig auszuwertenden Kenngrößen.

Fehlerdetektion

Wie bereits erwähnt, lassen sich für alle Weichenumläufe eines historischen Datensatzes die Fehlergrenzwerte für die SPE- und T^2 -Werte bestimmen. Gewöhnlich basieren diese Grenzwerte auf statistischen Auswertungen. So lassen sich beispielsweise tolerierbare Schwankungsbereiche, sogenannte Konfidenzintervalle, bestimmen. Diese Konfidenzintervalle geben Bereiche an, in denen die SPE- bzw. T^2 -Werte mit einer bestimmten Wahrscheinlichkeit p erwartet werden. Treten Werte auf, die nicht innerhalb gewisser Konfidenzintervalle liegen, deutet dies auf einen möglichen Anlagenfehler hin. Eine Aussage über die Fehlerkritikalität ist ebenfalls möglich. Abhängig von der festgelegten Wahrscheinlichkeit ergeben sich unterschiedlich große Konfidenzintervalle (Abb. 3). Eine hohe Wahrscheinlichkeit geht mit einem großen Konfidenzgebiet einher. Somit ist ein Kennwert,




Abb. 3: Visualisierung von Konfidenzintervallen am Beispiel einer Standardnormalverteilung

welcher das Konfidenzintervall der Wahrscheinlichkeit $p=0.68$ (1-Sigma-Bereich) überschreitet, anders zu bewerten als ein Kennwert, der das Konfidenzintervall der Wahrscheinlichkeit $p=0.99$ (3-Sigma-Bereich) verfehlt.

Die unterschiedliche Gewichtung von Grenzwertüberschreitung bzw. deren zeitlichen Verlauf kann ein Anwender selbst bestimmen. Hierzu können eigene Regeln definiert oder etablierte Ansätze aus anderen Anwendungsfeldern übernommen / adaptiert werden. So hat die Western Electric Company die Western Electric Rules für die automatisierte Fehlerdetektion definiert:

- Ein Punkt liegt außerhalb des $p=0.99$ Konfidenzintervalls (3-Sigma-Bereich).

- Zwei von drei aufeinanderfolgenden Punkte liegen außerhalb des $p=0.95$ Konfidenzintervalls (2-Sigma-Bereich).
- Vier von fünf aufeinanderfolgenden Punkte liegen außerhalb des $p=0.68$ Konfidenzintervalls (1-Sigma-Bereich).
- Acht aufeinanderfolgende Punkte liegen auf der gleichen Seite der Mittellinie.

Wichtig ist hier noch einmal zu betonen, dass die Regeln allein auf den T^2 - und SPE-Werten beruhen. Änderungen in der Datenverarbeitungskette, beispielsweise Hinzunahme neuer Sensoren bzw. Definition neuer Merkmale, haben keinen Einfluss auf die festgelegten Regeln. Erfahrungen und Verbesserungsvorschläge aus einem Praxistest können leicht eingearbeitet werden.



FEAM

Flächenmanagement | Ersatz- & Ausgleichsmaßnahmen für Infrastrukturprojekte der DB | Umweltbaubegleitung



Leistungen für die Deutsche Bahn beim projektbegleitenden Flächenmanagement – alles aus einer Hand:

Professionelles Kompensationsflächenmanagement beschleunigt die Projektgenehmigung.	DB-anerkanntes Vertrags- und Rechtsmanagement vermeidet Projektverzögerungen.	Standardisierte rechtssichere Abwicklungsverfahren sparen Kosten.	Umweltbaubegleitung (UBB) gem. AHO mit Baudokumentation gem. RIL 809 sichert Qualität.
GIS-Technologie mit ökologischen Spezialprogrammen steuert die Prozessabläufe.	Mündelsicheres Finanzkonzept für öffentliche Bauträger ermöglicht vorzeitigen Projektabschluss.	Mehr Infos: 	

FEAM GmbH • T: +49.4108.4169-39 • M: info@feam.de • feam.de

Zustandsdiagnose und -prognose: ZUDIapro




Abb. 4: Automatisierte Fehlerdetektion einer Testweiche basierend auf SPC

Auswertung Weichentestfeld

Nachdem die notwendigen Grundlagen der angestrebten, datengetriebenen Fehlerdetektion in den vorhergehenden Abschnitten beschrieben wurden, soll deren Praxis-tauglichkeit anhand eines Weichenantriebs illustriert werden. Zwar besitzt das Institut für Verkehrssystemtechnik eine langjährige Expertise auf dem Gebiet der datengetriebenen, zustandsorientierten Instandhaltung von Weichen, jedoch fehlte bisher der ungehinderte, eigene Zugang zum realen Objekt im Feld und den dazugehörigen Messdaten. Eine Erprobung und Validierung der entwickelten Datenanalysetools war somit nur eingeschränkt möglich. Eine Kooperation, die im Juli 2014 zwischen dem Deutschem Zentrum für Luft- und Raumfahrt (DLR) und DB Training beschlossen wurde, soll zukünftig hierbei Abhilfe schaffen. DB Training betreibt im Bereich des Berliner Ostbahnhofs ein Weichenfeld, um angehende Weichenmechaniker auszubilden und mit den diversen Weichenantrieben, Weichenverschlüssen und Bauformen vertraut zu machen. Um diese Infrastruktur als Testobjekt für das DLR nutzbar zu machen, wurde von Seiten des DLR entsprechende Sensorik an den Übungsweichen angeschlossen. Die erhobenen Messdaten sollen zukünftig vom DLR im Rahmen der Forschung zur zustands- und prognosebasierten Instandhaltung von Eisenbahninfrastrukturelementen ausgewertet werden. Erste Resultate zur Fehlerdetektion sind nachstehend zusammengefasst.

Die Stromkurven einer Übungsweiche wurden pro Umschaltvorgang messtechnisch erfasst. Aus diesen Rohdaten wurden zunächst 20 informative Merkmale extrahiert, die Mehrzahl beruht auf AMT-Werten (Angle Measure Technik) unterschiedlicher Skalierung [1]. Nachfolgend wurden mithilfe der SPC die beiden charakteristischen Kenngrößen, SPE und T^2 , berechnet und die dazugehörigen Fehlergrenzen bestimmt. Abschließend wurden die Algorithmen genutzt, um den aktuellen Anlagenzustand zu beurteilen. In Abb. 4 (a) ist die entsprechende Auswertung zu sehen. Bei den ersten 85 Umläufen der Weiche ist kein Fehlverhalten / Verschleiß zu erkennen, vielmehr sieht man dort die natürliche Schwankung in den Messungen, verursacht durch Messungenauigkeiten. Erst bei den nachfolgenden Umläufen sind deutliche Änderungen in den SPE-Werten zu erkennen. Dies entspricht exakt dem Zeitpunkt, an dem die Zungenrollvorrichtung absichtlich verstellt wurde, um einen künstlichen Abnutzungseffekt zu simulieren. Werden zusätzlich die Western Electric Rules für die automatisierte Fehlermeldung angewandt, ergeben sich Fehlermeldungen, wie sie in der Abb. 4 (b) zu sehen sind. Der Vergleich mit den ursprünglichen Stromdaten (Abb. 4 (c)) zeigt deutlich, dass die so erzeugten Fehlermeldungen berechtigt sind und eine zeitnahe Inspektion der Weiche durchgeführt werden sollte.

Fazit

Infrastrukturelemente, die ihren aktuellen Anlagenzustand zuverlässig und selbstständig melden, würden das Instandhaltungsmanagement der Eisenbahninfrastrukturbetreiber signifikant verbessern. Weniger Kosten, eine gestiegene Verfügbarkeit und mehr Pünktlichkeit können durch eine intelligente, datengetriebene Instandhaltungsunterstützung erzielt werden – der Verkehrsträger Schiene würde nachhaltig gestärkt. Eine zentrale Komponente bei der datengetriebenen, zustandsabhängigen Instandhaltung ist die Fehlerdetektion, also das Feststellen von sich anbahnenden Störungen, bevor es zu einem Ausfall der überwachten Infrastrukturelemente kommt. Wie dies mithilfe der statistischen Prozessüberwachung umgesetzt werden kann, wurde näher beschrieben und anhand eines Weichenantriebs demonstriert. Um in der Praxis eine noch bessere Planbarkeit von Instandhaltungsmaßnahmen zu erreichen, können neben den Methoden der Zustandsdiagnose auch Verfahren der Zustandsprognose eingesetzt werden. Zusätzlich zu der aktuellen Bewertung des Anlagenzustands erfolgt bei der Zustandsprognose eine Vorhersage der zukünftigen Degradation und der zu erwartenden Restlebenszeit der Anlage. Wie dies zum Zweck einer prädiktiven, praxistauglichen Zustandsbeurteilung am sinnvollsten umgesetzt werden kann, wird Schwerpunkt eines zukünftigen Beitrags sein.

LITERATUR

- [1] Schenkendorf, R.; Böhm, T.: Aspekte einer datengetriebenen zustandsabhängigen Instandhaltung: (Teil 1) Informative Merkmalsextraktion als Basis einer zuverlässigen Zustandsdiagnose, EI – DER EISENBAHNINGENIEUR, 11|2014, S. 14 – 18
- [2] Maimon, O.; Rokach, L. (Hrsg.): Data Mining and Knowledge Discovery Handbook, 2. ed., Boston, Springer Science + Business Media LLC, 2010
- [3] Kourti, T.; MacGregor, J. F.: Process Analysis, Monitoring and Diagnosis, Using Multivariate Projection Methods, Chemometrics and Intelligent Laboratory Systems, no. 28, 1995
- [4] Shlens J.: A Tutorial on Principal Component Analysis,

3.01 ed., La Jolla, CA, USA, 2009

- [5] Strang, G.: Computational Science and Engineering, Wellesley-Cambridge Press, 2007
- [6] Bonissone, P. P.; Goebel, K.: When will it break? A hybrid soft computing model to predict time-to-break margins in paper machines, SPIE, 2002, S. 53 – 64
- [7] Fink, O.; Weidmann, U.: Predicting Potential Railway Operations Disruptions Caused by Critical Component Failure Using Echo State Neural Networks and Automatically Collected Data, Transportation Research Board (TRB) 92nd

Annual Meeting Compendium of Papers, vol. 92, S. 1 – 13, 2013

- [8] Montgomery, D. C.: Introduction to Statistical Quality Control, Wiley, 2005
- [9] Bishop, C. M.: Pattern Recognition and Machine Learning, Springer, 2006
- [10] Petersohn, H.: Data Mining: Verfahren, Prozesse, Anwendungsarchitektur, Oldenbourg Wissenschaftsverlag, 2005



Dr.-Ing. René Schenkendorf

rene.schenkendorf@dlr.de



Dipl.-Ing.-Inf. Thomas Böhm

Gruppenleiter
Life Cycle Management
thomas.boehm@dlr.de

beide Autoren
Deutsches Zentrum für
Luft- und Raumfahrt e.V.
Institut für Verkehrssystemtechnik
Abteilung Bahnsysteme,
Braunschweig

Zusammenfassung

Aspekte einer datengetriebenen, zustandsabhängigen Instandhaltung

Für eine zuverlässige, datengetriebene Zustandsbeurteilung von Infrastrukturelementen müssen mehrere informative Merkmale aus Sensordaten ausgewertet werden. Zum Zweck einer effizienten Analyse lassen sich die Merkmalsinformationen auf wenige charakteristische Kenngrößen reduzieren. Wie dies mittels Hauptkomponentenanalyse und der statistischen Prozessüberwachung geschehen kann, ist Schwerpunkt des vorliegenden Artikels. Die erfolgreiche, algorithmische Umsetzung einer solchen Fehlerdetektion wird am Beispiel eines Weichenantriebs gezeigt – ein erstes Resultat der Kooperation des Deutschen Zentrums für Luft- und Raumfahrt mit DB Training.

Summary

Aspects of data-driven condition-based maintenance

Several informative characteristic features from sensor data must be evaluated to achieve a reliable, data-driven condition assessment of infrastructure elements. For the purpose of an efficient analysis, the information on these features may be reduced to a few significant representative parameters. The present article focuses on how this can be achieved by the analysis of principle components and statistical process control. The successful implementation of such a fault detection method is shown up with a point machine taken as an example – a first result of the cooperation between the German Aerospace Center (DLR) and DB Training.

Gestaltung: www.moll-betonwerke.de

Leonhard Moll Betonwerke
Ein Unternehmen der Leonhard Moll AG



**WIR SIND
DABEI:**

3. RAILWAY FORUM
Berlin 2015

Spannbeton-, Gleis- und Weichenschwellen

An unseren modernen Produktionsstandorten entstehen Produkte für den innovativen Fahrweg, wie z.B. umweltverträgliche Rasengleissysteme, Flachschwellen, die Zwillingschwelle ZSX und Betonschwellen für den Nahverkehr.



- FS 150:** Die flache Schwelle von Leonhard Moll
- Als Ersatz von Holzschnellen oder Stahltrogschnellen
 - Besohlt oder unbesohlt lieferbar für Vmax von 160 km/h
 - EBA-Zulassung zur Betriebserprobung liegt vor
 - Alle Informationen zur FS 150 unter:
www.moll-betonwerke.de/de/pdf/FS150.pdf



- ZSX-Zwillingschwelle:** Die besondere Schwelle von Leonhard Moll
- Im Übergangsbereich Erdbauwerk/Kunstbauwerk
 - Für Strecken mit engen Radien und durchgehend verschweißten Schienen
 - Wegfall von Sicherungskapfen durch den Einsatz der ZSX
 - EBA-Zulassung zur Betriebserprobung
 - Alle Informationen zur ZSX-Zwillingschwelle unter:
www.moll-betonwerke.de/de/pdf/MollZSX.pdf

**Besuchen Sie uns
auf Stand 31**

Hannover | München | Laußig | info@moll-betonwerke.de | www.moll-betonwerke.de