

Modellierung der Stromaufnahme von Weichenantrieben

Vergleich verschiedener Zeitreihenmodelle mit und ohne exogene Variable im Hinblick auf die Prädiktion von Weichenstörungen

DANIEL FÄSSLER | THORSTEN NEUMANN | DANIELA NAREZO GUZMÁN

Die Stromaufnahme eines Weichenmotors weist über die einzelnen Weichenumläufe hinweg ein stochastisches Verhalten auf und hängt von vielen verschiedenen Faktoren ab. Ziel des vorliegenden Beitrags ist die Modellierung der zeitlichen Veränderungen der Stromstärke beim Stellstrom mit Methoden der Zeitreihenanalyse unter Einbeziehung exogener Variablen wie z. B. der Lufttemperatur. Dies ermöglicht in der Folge die Erkennung und ggf. Prognose anormalen Anlagenverhaltens.

Einleitung

Eisenbahnweichen sind zentrale Elemente der Schieneninfrastruktur, deren einwandfreies Funktionieren ist wesentlich ist für einen reibungslosen und sicheren Bahnverkehr. Gleichzeitig sind Weichen aufgrund ihrer komplexen Bauweise bei zugleich hohen mechanischen Belastungen und umweltbedingten Einflüssen besonders anfällig für Störungen und Defekte. In der Praxis existieren daher bereits seit geraumer Zeit verschiedene Systeme zur Weichenüberwachung. Zu nennen sind hier z. B. das System Sidis W von Siemens [1] oder das System POSS¹ des niederländischen Unternehmens Strukton Rail [2]. Ziel ist dabei eine zuverlässige automatisierte Zustandserfassung bzw. Anomaliedetektion [3, 4] sowie eine darauf aufbauende (modellgestützte) Fehlerursachendiagnose [5, 6]. Unter Einbeziehung geeigneter Prognoseansätze [7, 8] ebnet dies schließlich den Weg hin zu einer Kosten einsparenden prädiktiven Instandhaltung der entsprechenden Elemente der Schieneninfrastruktur und erhöht damit die Verfügbarkeit im Bahnbetrieb.

Das Grundprinzip der zuvor exemplarisch genannten Systeme zur Weichenüberwachung besteht nun darin, dass sie während des Weichenumlafs quasi kontinuierlich (z. B. mit Abstraten um 50 Hz) die Stromaufnahme (Stromstärke) des Weichenmotors messen, die nicht zuletzt mit der benötigten Kraft zum Verstellen der Weichenzungen korreliert. Die dabei entstehenden Stromumlaufkurven (Abb. 1) lassen leicht erkennen, wie die Stromaufnahme über die

Dauer des Weichenumlafs variiert. Die höchste Stromaufnahme erfolgt in der Regel zu Beginn, d. h. beim Start des Motors und beim Lösen des Weichenverschlusses, während die eigentliche Bewegung der Zungen normalerweise eine weitgehend konstante bzw. über die Zeit leicht abnehmende Stromaufnahme auf mittlerem Niveau bewirkt. Mit dem Abschalten des Weichenmotors am Ende des Umlafs sinkt die gemessene Stromstärke sodann wieder auf 0 Ampere. Auffälligkeiten der Stromumlaufkurve können z. B. darin bestehen, dass während der eigentlichen Zungenbewegung eine erhöhte Stromstärke gemessen wird oder dass der Umlauf länger dauert als gewöhnlich (Abb. 1, Kurve (b)). Neben komplexeren Ansätzen zur Anomaliedetektion [3, 4] kann folglich in vielen Fällen das Integral der Stromumlaufkurve, d. h. die Fläche unterhalb der Kurve (Abb. 1) als Indikator für mögliche Störungen herangezogen werden [9]. Im Hinblick auf die Prädiktion von Weichenstörungen ist es ferner sinnvoll, wenn nicht sogar notwendig, den zeitlichen Verlauf der Integralwerte oder vergleichbarer, aus den Stromumlaufkurven abgeleiteter Merkmalsparameter, über die einzelnen Weichenumläufe hinweg mathematisch zu beschreiben, um anschließend modellbasiert weitere Werte vorherzusagen. Diese können dann im Sinne der Störungsprognose z. B. mit vorgegebenen Schwellenwerten (Alarmschwellen) verglichen werden. Abweichungen zwischen zuvor pro-

gnostiziertem Normalverhalten und tatsächlich gemessenen Werten können zudem zur Störungsdetektion verwendet werden, während ungewöhnliche Trends in den Prognosewerten auf sich allmählich anbahnende Defekte (Degradationseffekte) hindeuten können. Hinsichtlich der Beschreibung des Zeitreihenverlaufs der Stromaufnahme von Weichenmotoren bzw. daraus abgeleiteter statistischer Merkmale wurde hierzu in [10] exemplarisch eine Modellierung mittels eines klassischen ARIMA-Ansatzes [11] gewählt. García et al. [12] haben ferner die Dauer von Weichenumläufen mittels eines sogenannten VARMA-Modells [13] modelliert. Der vorliegende Beitrag untersucht und vergleicht nun verschiedene Zeitreihenmodelle für die Integralwerte der Stromumlaufkurven – genauer deren diskrete Version – in Bezug auf die Prognosequalität bei unterschiedlichen Prognosehorizonten. Eine detaillierte Darstellung der betrachteten Modellvarianten folgt im nächsten Abschnitt. Wie sich herausstellt, spielen dabei Umwelteinflüsse – d. h. vor allem die Temperatur – eine wichtige Rolle [4], weshalb neben herkömmlichen Zeitreihenmodellen (ARMA, VARMA) auch eines mit exogenen Variablen (VARMAX) verwendet wird.

Zeitreihenmodelle

Autoregressive Modelle (AR = „Auto-Regressive“) sowie Ansätze mit gleitendem Mittelwert (MA = „Moving Average“) bilden die Basis für viele An-

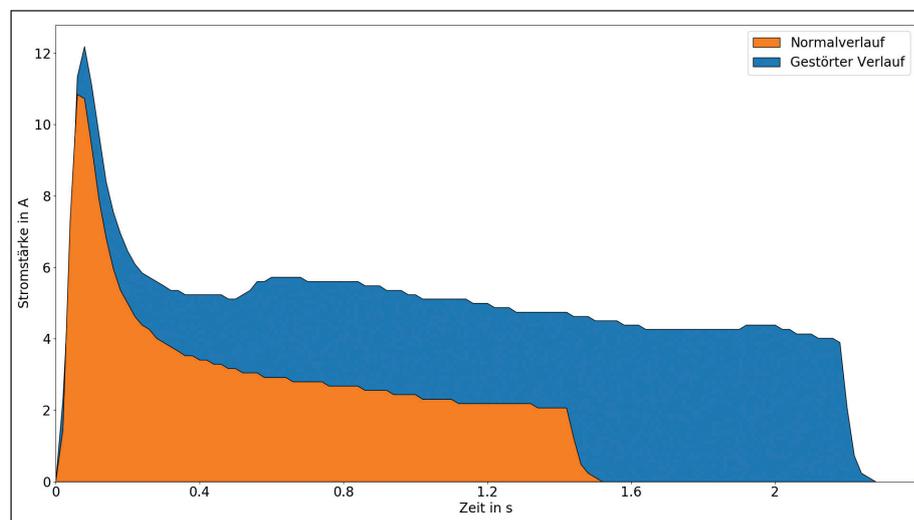


Abb. 1: Exemplarische Stromumlaufkurven. (a) Normalverlauf; (b) gestörter Verlauf mit erhöhter Stromstärke während der Zungenbewegung und erhöhter Umlaufdauer. Alle Abb.: eigene Darstellung

¹POSS ist eine eingetragene Marke der Strukton Rail.

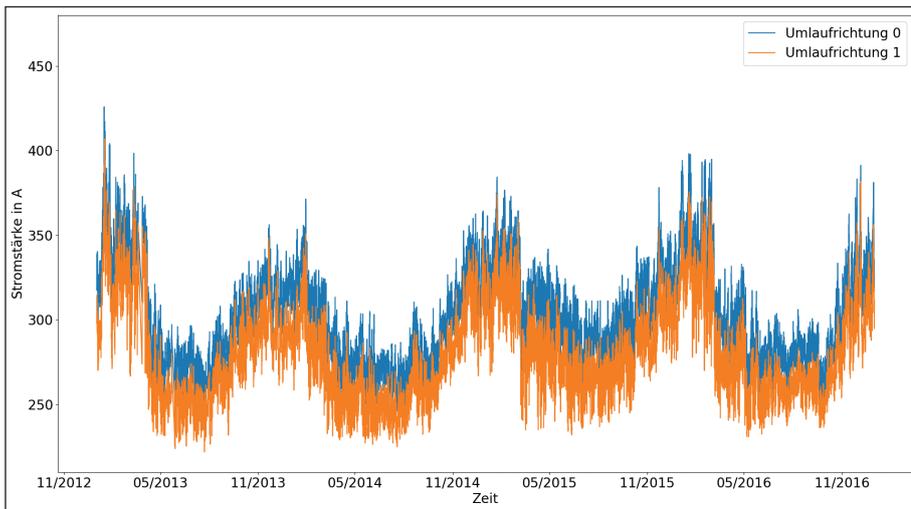


Abb. 2: Zeitreihe der gemessenen Stromstärken (d. h. Summenwerte pro Umlauf) differenziert nach Umlaufrichtung

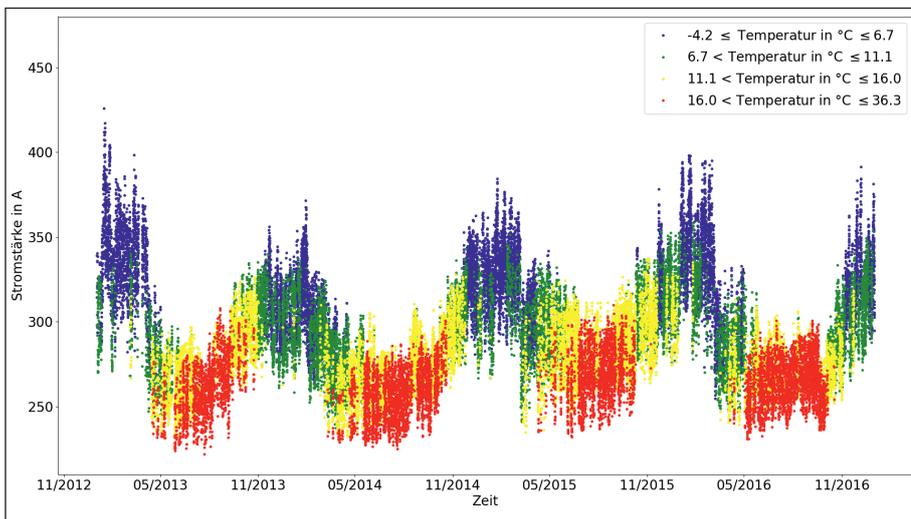


Abb. 3: Einfluss der Temperatur auf die gemessenen Stromstärken

wendungen im Bereich der Zeitreihenmodellierung und -prognose [11]. Die Kombination aus beiden Ansätzen, das sogenannte ARMA-Modell, gilt als eines der Standardmodelle für stationäre Zeitreihen mit bekannten Erweiterungen wie beispielsweise dem in [10] eingesetzten ARIMA-Modell, das auch (nicht-lineare) Trends in den Daten abbilden kann. Vergleiche mit anderen Methoden zur Prognose von Zeitreihendaten [14, 15] zeigen dabei, dass sich die genannten Ansätze eher für kurzfristige Prognosen eignen, während die Ergebnisse mit wachsendem Prognosehorizont tendenziell schlechter werden.

Das klassische ARMA-Modell beschreibt hierbei den Wert X_t einer (stationären) Zeitreihe zum Zeitpunkt t als Linearkombination aus vorherigen Werten (X_{t-1}, \dots, X_{t-p}) und stochastischen Fehlertermen Z_t für den aktuellen (t) sowie die vorangegangenen Zeitschritte $t-1, t-2, \dots, t-q$. Die Fehlerterme Z_t für $t=0, \pm 1, \pm 2, \dots$ werden dabei zumeist als weißes Rauschen modelliert. Die Grundgleichung des ARMA-Modells (mit Drift) lautet also:

$$X_t = c + \sum_{i=1}^p a_i X_{t-i} + Z_t + \sum_{j=1}^q b_j Z_{t-j}$$

mit entsprechend näher zu bestimmenden (reellen) Parametern c (Drift) sowie a_1, \dots, a_p für den „AR“-Teil und b_1, \dots, b_q für den „MA“-Teil. Die beiden Parameter p und q geben ferner an, wie weit in die Vergangenheit das Modell jeweils schaut, und bestimmen damit maßgeblich dessen Verhalten (z. B. bezüglich Periodizitäten). Man schreibt daher oft auch $ARMA(p, q)$, wenn man die Struktur (Ordnung) des Modells explizit angeben möchte.

Eine vektorwertige Variante des oben beschriebenen ARMA-Modells für die n -dimensionale Zeitreihe $(X_t)_{t=0, \pm 1, \pm 2, \dots}$ mit $X_t = (X_t^{(1)}, \dots, X_t^{(n)})^T$ bildet das sogenannte VARMA-Modell mit der Gleichung

$$X_t = C + \sum_{i=1}^p A_i X_{t-i} + Z_t + \sum_{j=1}^q B_j Z_{t-j}$$

Der Driftparameter C ist in diesem Fall genau wie die Fehlerterme Z_t für $t=0, \pm 1, \pm 2, \dots$

ein n -dimensionaler Vektor, und A_1, \dots, A_p bzw. B_1, \dots, B_q sind geeignete $n \times n$ -Matrizen. VARMA(p, q)-Modelle der Dimension n entsprechen demnach n miteinander verschränkten eindimensionalen ARMA(p, q)-Zeitreihen.

Von besonderer Bedeutung für den im weiteren Verlauf betrachteten Anwendungsfall der Eisenbahnweiche sind ferner Modelle, die zusätzlich sogenannte exogene Variablen U_t (hier insbesondere die Temperatur) in die Betrachtung mit einbeziehen. Die entsprechende Erweiterung des VARMA-Modells lautet

$$X_t = C + \sum_{i=1}^p A_i X_{t-i} + \sum_{k=0}^{r-1} E_k U_{t-k} + Z_t + \sum_{j=1}^q B_j Z_{t-j}$$

und wird als VARMAX bezeichnet [16]. Ist hierbei $U_t = (U_t^{(1)}, \dots, U_t^{(m)})^T$ für $t=0, \pm 1, \pm 2, \dots$ jeweils ein m -dimensionaler Vektor, so sind die zusätzlichen Koeffizienten $E_0, \dots, E_{(r-1)}$ in kanonischer Weise $n \times m$ -Matrizen.

Es sei noch darauf hingewiesen, dass in den weiteren Abschnitten ausschließlich der Fall $r=1$ betrachtet wird. Die zuvor angegebene Gleichung des VARMAX-Modells vereinfacht sich damit zu

$$X_t = C + \sum_{i=1}^p A_i X_{t-i} + E U_t + Z_t + \sum_{j=1}^q B_j Z_{t-j}$$

mit einer geeigneten $n \times m$ -Matrix E .

Auswertung und Analyse

Datengrundlage

Als Datengrundlage für die folgenden Untersuchungen dienen die Stromumlaufkurven einer Eisenbahnweiche bei Groningen in den Niederlanden, welche mit dem Überwachungssystem POSS des Infrastrukturbetreibers Strukton Rail in den Jahren von 2012 bis Anfang 2018 erfasst wurden. Insgesamt liegen 66 797 Umlaufkurven vor, die nach Umlaufrichtung der Weiche differenziert werden können. Abb. 2 zeigt exemplarisch die Summen der Einzelmesswerte pro Umlaufkurve, d. h. der mit 50 Hz abgetasteten Stromstärken am Weichenmotor, für den Zeitraum 1. Januar 2013 bis 31. Dezember 2016 farblich unterschieden nach Umlaufrichtung. Die dargestellten Summenwerte entsprechen dabei sinngemäß dem Integral der jeweiligen Umlaufkurve.

Man erkennt leicht den Versatz beim Niveau der Stromstärken, der mutmaßlich auf einen richtungsabhängig unterschiedlichen Kraftaufwand beim Verstellen der Weichen hindeutet. Auffällig ist ferner der jahreszeitlich periodische Verlauf mit eher höheren Stromstärken im Winter und niedrigeren Stromstärken im Sommer. Offensichtlich liegen hier starke Abhängigkeiten von externen Umweltbedingungen wie der Temperatur vor [4]. Noch deutlicher wird dieser Effekt zum Beispiel in der Darstellung von Abb. 3. Die angegebenen Temperaturwerte entsprechen dabei der Lufttemperatur in ca. 150 m Entfernung von der betrachteten Weiche.

Parameterbestimmung

Gemäß der zuvor beschriebenen Modellgleichungen der im Weiteren verwendeten Zeitreihenansätze (d.h. ARMA, VARMA und VARMAX) sind bei der Modellierung zum einen die Strukturparameter p und q sowie zum anderen die jeweils auftretenden Koeffizienten(matrizen) zu bestimmen. Hierzu wurden verschiedene Zeitausschnitte mit jeweils 100 aufeinanderfolgend gemessenen Umlaufkurven im verfügbaren Datensatz ausgewählt, mit denen die betrachteten Modelle i.S. einer geschichteten Optimierung trainiert wurden. Die Bestimmung der Koeffizienten – unter Annahme bekannter Parameter p und q – erfolgte dabei mit einer Kombination aus Maximum-Likelihood-Schätzung und Kalman-Filter [17]. Für die Strukturparameter selbst wurden ganzzahlige Werte zwischen 0 und 4 angenommen, wobei die optimale Lösung für p und q durch systematisches Durchprobieren aller Kombinationen („Grid Search“) ermittelt wurde. Als Gütemaß für die Optimierung diente dabei das sogenannte Akaike-Informationskriterium (AIC) [17].

Ergebnisse

Mit den trainierten Modellen können sodann die nächsten k unmittelbar auf den gewählten Trainingszeitraum folgenden Weichenumläufe (Testdaten) prognostiziert werden. Die Qualität der Prognose wird dabei im Folgenden über die Wurzel des mittleren quadratischen Fehlers (RMSE=Root-Mean-Square-Error), d.h.

$$RMSE = \sqrt{\frac{1}{k} \sum_{i=1}^k (Y_i - \hat{Y}_i)^2}$$

mit den prognostizierten Werten \hat{Y}_i und den tatsächlich gemessenen Werten Y_i bewertet.

Abb. 4 zeigt exemplarisch für den Zeitraum 16. bis 24. Juli 2013 die tatsächliche und prognostizierte Zeitreihe bei Verwendung des ARMA-Ansatzes. Man erkennt sofort das charakteristische, periodische Zickzackmuster (Periode 2), welches sich aufgrund der sich im Zeitverlauf notwendigerweise abwechselnden Umlaufrichtungen unmittelbar aus den unterschiedlichen Stromstärkeniveaus pro Umlaufrichtung (Abb. 2) ergibt. Insofern überrascht es nicht, dass die optimalen Parameter $p=4$ und $q=2$ für das hier gezeigte ARMA-Modell Vielfache von 2 sind. Die RMSE-Werte für einen Prognosehorizont von 1, 10 bzw. 50 Weichenumläufen sind in Tab. 1 dargestellt.

Offensichtlich ist das ARMA-Modell trotz korrekter Wiedergabe der Zickzackstruktur der Zeitreihe nicht in der Lage, die zeitlichen Variationen im Testdatensatz adäquat abzubilden, und neigt eher zu konstanten Prognosewerten pro Umlaufrichtung (Abb. 4).

Eine Möglichkeit, das oben genannte periodische Muster der Zeitreihe aus Abb. 4 bei der Modellierung zu durchbrechen, besteht in der Verwendung eines zweidimensionalen VARMA-Modells anstelle von ARMA. Die

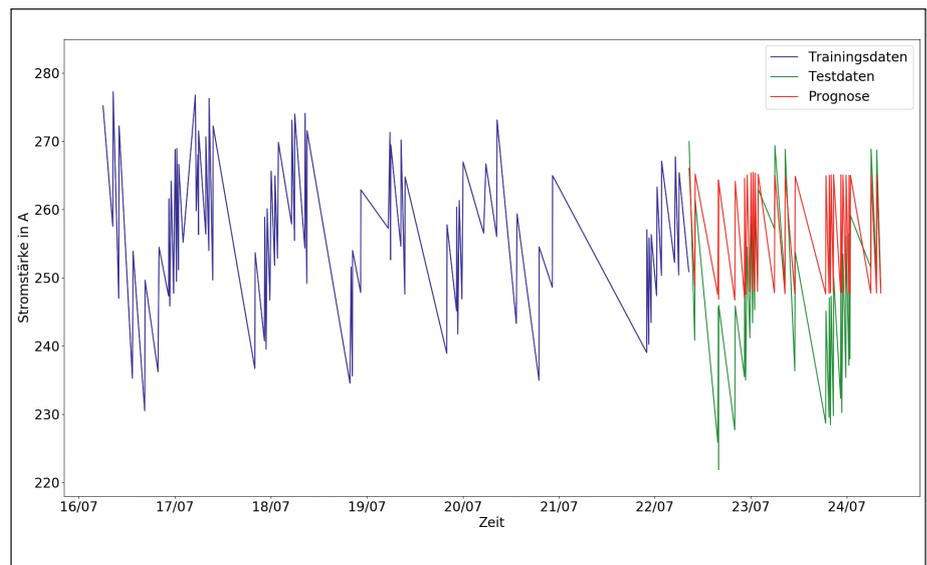


Abb. 4: ARMA(4,2)-Prognose

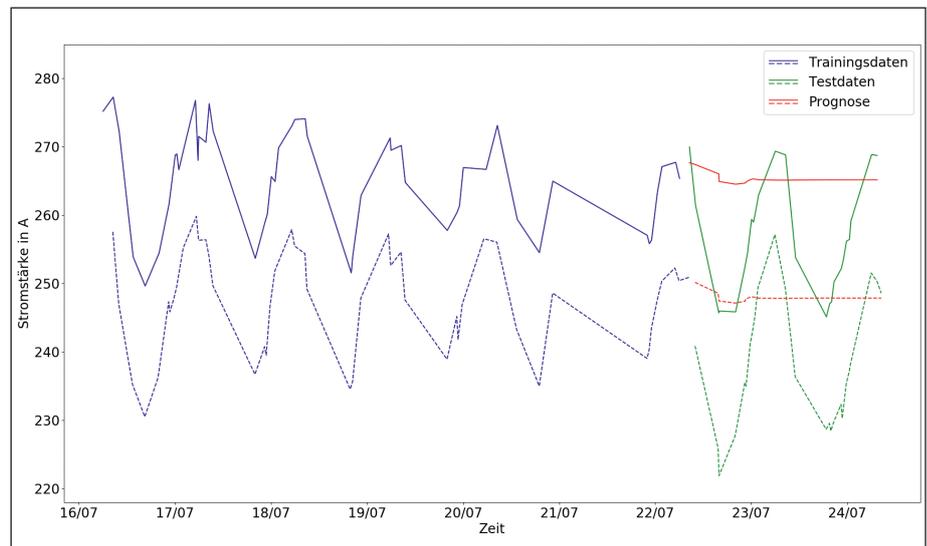


Abb. 5: VARMA(1,0)-Prognose

beiden Komponenten $X_t^{(1)}$ und $X_t^{(2)}$ des Zeitreihenvektors $X_t = (X_t^{(1)}, X_t^{(2)})^T$ entsprechen in diesem Fall den beiden Umlaufrichtungen (d.h. genauer den nach Umlaufrichtung differenzierten Stromstärkewerten) der Weiche. X_t enthält also stets als Paar die (aufsummierten) Stromstärkewerte für einen Umlauf in die eine Richtung und wieder zurück in die andere Richtung. Dabei kann zwischen den Umläufen in der Realität natürlich ein mehr oder weniger langes Zeitintervall liegen, sodass der einheitliche Zeitindex t bei $X_t^{(1)}$ und $X_t^{(2)}$ eigentlich nur als chronologische Nummerierung der zuvor genannten Umlaufpaare zu interpretieren ist.

Abb. 5 zeigt die Ergebnisse der VARMA-Prognose unter Verwendung desselben Datensatzes wie in Abb. 4. Durch die Trennung der beiden Umlaufrichtungen erkennt man sofort den bereits in Abb. 2 festgestellten Versatz der Stromstärken. Man sieht infolge

des Wegfalls des Zickzackmusters aus Abb. 4 aber auch, dass die betrachteten Zeitreihen neben den schon zuvor festgestellten jahreszeitlichen Schwankungen (Abb. 2) offensichtlich noch weitere periodische, in diesem Fall tageszeitliche Variationen aufweisen. Die Periodendauer liegt dabei jedoch deutlich über den im Rahmen der Optimierung zugelassenen Werten für die Strukturparameter p und q , weshalb eine korrekte Abbildung dieser Muster bei der Prognose offenbar nicht gelingt. Da zudem die Periodendauer bezogen auf den (Numerierungs-)Index t des VARMA-Modells variiert, ist auch eine Erhöhung der Modellordnung (d.h. größere Werte für p und q) nicht sinnvoll, zumal dies die Komplexität des Modells bzw. die Anzahl zu schätzender Koeffizienten unnötig erhöhen würde.

Insofern tendiert das VARMA- wie bereits das ARMA-Modell aus Abb. 4 zu eher konstanten

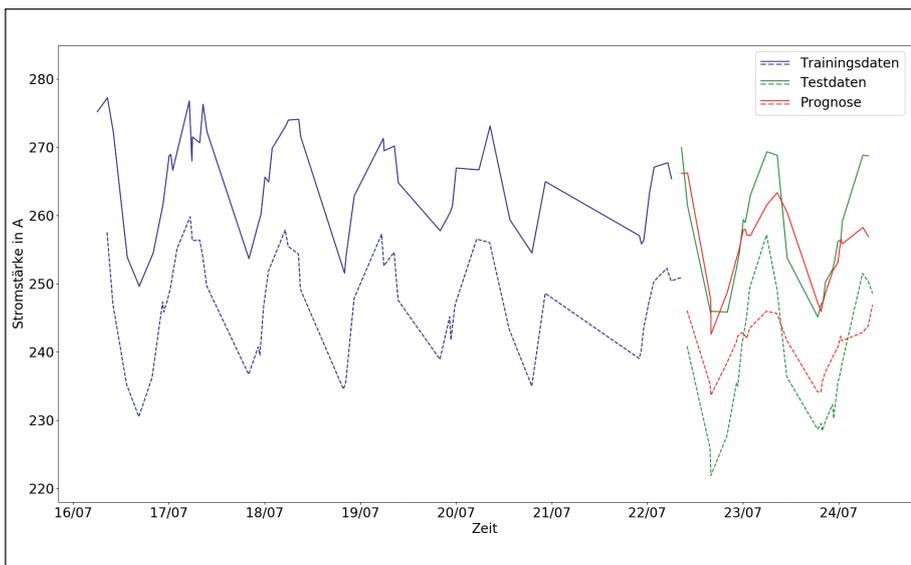


Abb. 6: VARMAX(1,0)-Prognose mit Temperatur als exogener Variable

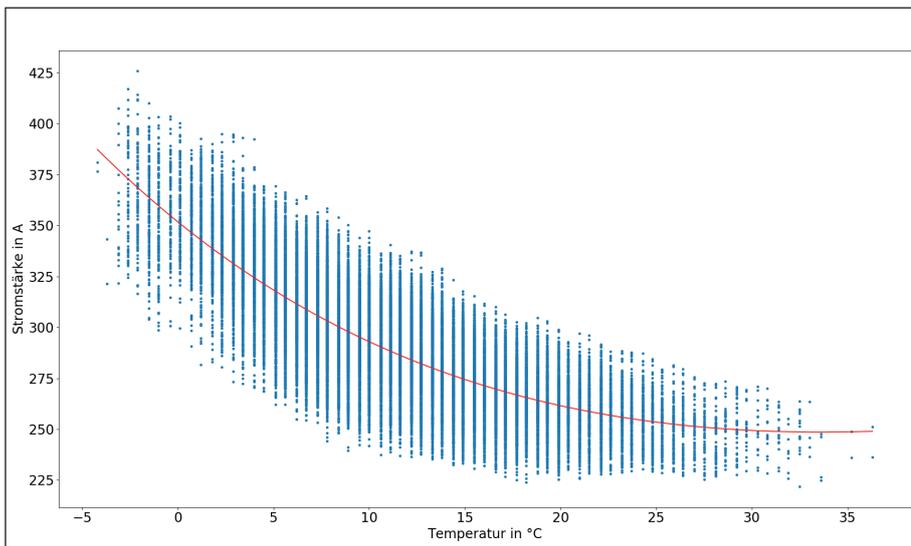


Abb. 7: Nicht-lineare Abhängigkeit zwischen Temperatur und gemessener Stromstärke

Modell	p	q	Prognosehorizont		
			1 Umlauf	10 Umläufe	50 Umläufe
ARMA	4	2	3,9	16,4	12,5
VARMA	1	0	2,3	17,1	12,7
VARMAX	1	0	3,8	6,8	5,8

Tab. 1: Prognosegüte (RMSE) der untersuchten Zeitreihenmodelle

Prognosewerten (Abb. 5). Zu bemerken ist in diesem Zusammenhang aber die verglichen mit ARMA deutlich niedrigere Ordnung ($p=1$ und $q=0$) des VARMA-Modells bei ansonsten ähnlicher Prognosequalität (Tab. 1). Eine deutliche Verbesserung der Prognose (Tab. 1) bringt die Verwendung eines entsprechend optimal gewählten VARMAX-Modells, das wie das zuvor diskutierte VARMA-Modell mit $p=1$ und $q=0$ eine sehr niedrige Ordnung aufweist, zusätzlich aber die Temperatur als exogene Variable U_t einbezieht. Jedem Wei-

chenumlauf ist in diesem Zusammenhang in dem zur Verfügung stehenden Datensatz eine Temperaturmessung zugeordnet, sodass sich passend zum Zeitreihenvektor $X_t=(X_t^{(1)}, X_t^{(2)})^T$ ein Temperaturvektor $U_t=(U_t^{(1)}, U_t^{(2)})^T$ ergibt, wobei bezogen auf Matrixdimensionen in der weiter oben beschriebenen, allgemeinen Modellgleichung des VARMAX-Modells in diesem Fall $n=m=2$ gilt.

Abb. 6 zeigt erneut die tatsächlichen sowie die prognostizierten Zeitreihen für den Zeitraum 16. bis 24. Juli 2013, diesmal unter Ver-

wendung des beschriebenen VARMAX(1,0)-Modells, wobei die Temperaturwerte für den Prognosezeitraum als bekannt vorausgesetzt werden. Dies entspricht der Annahme einer verfügbaren, von der Weichenüberwachung unabhängigen Wetter- bzw. Temperaturvorhersage. Offensichtlich lassen sich damit wesentliche Merkmale der betrachteten Zeitreihen sehr gut abbilden, was mit ARMA und VARMA zuvor nicht möglich war.

Schlussfolgerungen

Die Analysen des vorangegangenen Abschnitts zeigen, dass sich die untersuchten Zeitreihendaten der Weichenüberwachung mit gängigen Zeitreihenmodellen prinzipiell abbilden lassen. Vor allem der VARMAX-Ansatz, bei dem die Temperatur als exogene Variable linear in das Modell eingeht, scheint hier geeignet.

Tatsächlich deuten weiterführende Betrachtungen der Relation zwischen Temperatur und Stromstärke bei dem hier analysierten Datensatz allerdings auf eine nicht-lineare Abhängigkeit zwischen den genannten Größen hin. Die mittels Kleinste-Quadrate-Schätzung berechnete Kurve in Abb. 7 hat beispielsweise die Form

$$f(x) = a - bx + c \cdot \exp(-dx)$$

mit geeigneten reellen Koeffizienten. Die explizite Berücksichtigung dieses nicht-linearen Zusammenhangs in einem geeigneten Zeitreihenmodell lässt demnach weitere Verbesserungen bei der Prognose erwarten.

Ein möglicher Schwachpunkt der im vorliegenden Beitrag verwendeten Art der Anwendung multivariater Zeitreihenmodelle besteht allerdings in der Paarung jeweils zweier Weichenumläufe pro Zeitreihenvektor. Da zwischen den beiden Umläufen eines solchen Paares naturgemäß unterschiedliche, mitunter längere Zeitintervalle liegen können (z.B. Abb. 4), kann es hier insbesondere im VARMAX-Fall durch die statische (d.h. nicht dynamisch angepasste) Matrix E zur unerwünschten Berücksichtigung veralteter Temperaturwerte pro Umlauf kommen. Ob bzw. in welchem Umfang sich dieser Effekt negativ auf die Prognosegüte auswirkt, bleibt zu prüfen.

Besondere Sorgfalt ist ferner erforderlich, falls die Messwerte einzelner Weichenumläufe (z. B. aufgrund von Störungen des Messsystems) fehlen, damit es im Rahmen der Modellimplementierung nicht versehentlich zu einer zwischenzeitlichen Vertauschung der beiden, sich im realen Zeitverlauf normalerweise stets abwechselnden Zeitreihenkomponenten $X_t^{(1)}$ (Umlauf in eine Richtung) und $X_t^{(2)}$ (Umlauf in die andere Richtung) kommt.

Inwieweit sich ansonsten alternative Modellierungsansätze basierend auf neuronalen Netzen oder Ähnlichem zur Modellierung und Prognose der hier untersuchten Weichenüberwachungsdaten eignen, ist Teil weiterer Forschung.

Danksagung

Die hier vorgestellten Arbeiten erfolgten mit Unterstützung internationaler Praxispartner des europäischen Joint-Untertakings Shift2Rail im Rahmen der Projekte In2Smart (Grant Nr. 730569) und In2Smart2 (Grant Nr. 881574). Die Autoren danken der Firma Strukton Rail, namentlich Edin Hadzic und Henk Samson, für die Bereitstellung der hier analysierten Messdaten des Weichenüberwachungssystems POSS. ■

QUELLEN

- [1] Bollrath, B. Sattler, U.: Weichendiagnosesystem Sidis W – Betriebliche Erfahrungen. In: ETR – Eisenbahntechnische Rundschau, 10/2006
- [2] Redeker, R.: POSS[®]: Railway condition monitoring developed by a maintainer. In: 5th IET Conference on Railway Condition Monitoring and Non-Destructive Testing, 29.-30. Nov. 2011, Derby, UK
- [3] Narezo Guzmán, D.; Hadzic, E.; Schuil, R.; Baars, E.; Groos, J. C.: Data-driven condition now- and forecasting of railway switches for improvement in the quality of railway transportation. In: 4th European Conference of the Prognostics and Health Management (PHM) Society, 3.-6. Jul. 2018, Utrecht, Niederlande. URL: <https://elib.dlr.de/118932/>
- [4] Narezo Guzmán, D.; Neumann, Th.; Groos, J. C.: Kontinuierliche Überwachung der LST mit eingebetteten Sensoren. In: DER EISENBAHNINGENIEUR, 11/2018, S. 6-11. URL: <https://elib.dlr.de/124734/>
- [5] Neumann, Th.; Narezo Guzmán, D.: Bayesian network design for fault diagnostics of railway switches. In: 29th European Safety and Reliability Conference, 22.-26. Sept. 2019, Hannover. URL: <https://elib.dlr.de/122317/>

- [6] Neumann, Th.; Narezo Guzmán, D.; Groos, J. C.: Transparente Fehlerdiagnose bei Weichenstörungen mittels Bayes'scher Netze. In: SIGNAL+DRAHT, 12/2019, S. 23-31. URL: <https://elib.dlr.de/128850/>
- [7] Schenkendorf, R.; Böhm, Th.: Aspekte einer datengetriebenen, zustandsabhängigen Instandhaltung: (Teil 3) Zustandsdiagnose und -prognose. In: EI – DER EISENBAHNINGENIEUR, 05/2015, S. 43-49. URL: <https://elib.dlr.de/96279/>
- [8] Böhm, Th.: Präzise Prognose von Störungen an Eisenbahnweichen. Dissertation, TU Braunschweig, 2018. URL: <https://elib.dlr.de/126578/>
- [9] Dutschk, B.; Groos, J. C.; Hadzic, E.; Böhm, Th.: Deeper insight in railway switch condition nowcasting. In: 1st World Congress on Condition Monitoring, 13.-16. Jun. 2017, London, UK. URL: <https://elib.dlr.de/123162/>
- [10] Narezo Guzmán, D.; Hadzic, E.; Baasch, B.; Heusel, J.; Neumann, Th.; Schrijver, G.; Buurmsma, D.; Groos, J. C.: Anomaly Detection and Forecasting Methods Applied to Point Machine Monitoring Data for Prevention of Switch Failures. In: COMADEM 2019, 3.-5. Sept. 2019, Huddersfield, UK. URL: <https://elib.dlr.de/127352/>
- [11] Brockwell, P. J.; Davis, R. A.: Introduction to Time Series and Forecasting. 2nd Edition, Springer, New York, 2002
- [12] Garcia, F. P.; Pedregal, D. J.; Roberts, C.: Time series methods applied to failure prediction and detection. In: Reliability Engineering and System Safety 95 (2010), S. 698-703
- [13] Lütkepohl, H.: New Introduction to Multiple Time Series Analysis. Springer, Berlin, 2005
- [14] Liu, K.; Subbarayan, S.; Shoults, R. R.; Manry, M. T.; Kwan, C.; Lewis, F. L.; Naccarino, J.: Comparison of Very Short-Term Load Forecasting Techniques. In: IEEE Transactions on Power Systems 11(2) (1996), S. 877-882
- [15] Masum, S.; Liu, Y.; Chiverton, J.: Multi-Step Time Series Forecasting of Electric Load Using Machine Learning Models. In: Rutkowski et al. (eds.): ICAISC 2018, LNAI 10841, S. 148-159
- [16] Gómez, V.: VARMAX and Transfer Function Models. In: Linear Time Series with MATLAB and OCTAVE. Statistics and Computing. Springer, Cham, 2019, S. 121-172
- [17] Durbin, J.; Koopman, S. J.: Time Series Analysis by State Space Methods. Oxford Statistical Series 38, Oxford University Press, 2012



Daniel Fässler, B. Sc.

Studentischer Mitarbeiter
daniel.faessler@dlr.de



Dr. Thorsten Neumann

Wiss. Mitarbeiter
thorsten.neumann@dlr.de



Dr. Daniela Narezo Guzmán

Wiss. Mitarbeiterin
daniela.narezoguzman@dlr.de

alle: Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR), Institut für Verkehrssystemtechnik, Berlin

www.pintsch.net



Systemlösungen für die Bahninfrastruktur

- Bahnübergangstechnik
- Achszähltechnik
- Stellwerkstechnik
- Rangiertechnik
- Gleisinfrastruktur
- Digitalisierung & Diagnose, Service
- Sensortechnik Tiefenbach


PINTSCH
Sicherheit für die Bahn