12
97. Jahrgang
Dezember 2020
ISSN 0932-8351
A 1556

Bautechnik

Zeitschrift für den gesamten Ingenieurbau

- BIM-basierte Kollaboration
- BIM-basierte Instandhaltung von Ingenieurbauwerken mit Monitoringsystemen
- Machine Learning Prognose von Messdaten des Bauwerksmonitorings
- Nichtlineare Optimierungsprozesse im Bauingenieurwesen
- Dünenerosionen an der Ostseeküste
- Zu Schlosssprengungen bei kombinierten Spundwänden
- Baugrube und Gründung des Forschungszentrums von Roche in Basel
- Technischer Jahresbericht 2020 der EAU

Ernst & Sohn
A Wiley Brand

DOI: 10.1002/bate.202000073

Frederik Wedel, Steffen Marx

Prognose von Messdaten beim Bauwerksmonitoring mithilfe von Machine Learning

In diesem Aufsatz wird der nichtlineare bzw. instationäre Zusammenhang zwischen Luft- und Bauwerkstemperatur über ein Machine-Learning-Modell abgebildet. Anhand dieser Problemstellung werden verschiedene Anwendungsfälle für Methoden des maschinellen Lernens (Regression) auf Monitoringdaten dargestellt, die aus in der Praxis aufgetretenen Fragestellungen resultieren. Dazu wird auf neuronale Netze als Methode des Machine Learnings spezifisch eingegangen, die im Kontext von Langzeitmonitoringdaten an Talbrücken der VDE 8 angewandt werden. Es wird bspw. gezeigt, dass mithilfe dieser Methoden Messfehler erkannt und kompensiert werden können oder das Bauwerksverhalten vorhergesagt werden kann. Im Ergebnis wird festgehalten, dass diese Methoden ein großes Potenzial für die automatisierte Auswertung großer Datenmengen aufweisen, da keine komplexen physikalischen Modelle benötigt werden. Der Aufsatz legt dabei den Fokus stärker auf die Anwendung von KI-Methoden als auf den mathematischen bzw. theoretischen Hintergrund der Methoden.

Stichworte Brücke; Monitoring; Temperaturverhalten; maschinelles Lernen; Vorhersage

Prediction of the bridge temperature using monitoring data and machine learning

In this paper, the nonlinear or rather transient relationship between the air temperature and the building temperature is simulated by a machine learning model. Based on this modelling, different use cases for the application of machine learning regression methods to monitoring data are presented, which resulted from practical questions. Basic knowledge of neural networks will be given and for the calculations, long-term monitoring data of valley bridges from VDE 8 are used. It is shown, for example, that these methods can be used to detect and compensate measurement errors or to predict the behaviour of structures. The results show that these methods, have a great potential for the evaluation of large amounts of data since no physical models are required. The paper focuses more on the application of AI methods rather than on the mathematical or theoretical background of the methods.

Keywords bridge; monitoring; temperature behaviour; machine learning; prediction

1 Einleitung

Bei der voranschreitenden Digitalisierung spielt die Erfassung und Bewertung von Daten eine immer größere Rolle. Um die riesigen Datenmengen bewältigen zu können, haben sich in den vergangenen Jahren Verfahren aus dem Bereich der künstlichen Intelligenz (KI; engl.: Artificial Intelligenz, AI) etabliert. Im Bereich der Automobilindustrie (bspw. Assistenzsysteme für Fahrzeuge oder autonomes Fahren) sind sie bereits zum Standard geworden und in der Medizin assistiert die KI bspw. bei der Auswertung von MRT-Aufnahmen oder Hautbildern, während die Nutzung in der Baubranche bislang größtenteils auf die Forschung begrenzt ist. Dies hängt u. a. damit zusammen, dass die Ingenieure die Verfahren nicht gut kennen, ihnen nicht vertrauen oder die Reproduzierbarkeit als eingeschränkt einschätzen [1].

Auch das Monitoring von Infrastrukturbauwerken findet immer mehr Zustimmung und ist für eine prädiktive Instandhaltung unabdingbar [1, 2]. Es fallen dabei sehr große Datenmengen an, bei denen eine manuelle Auswertung oft nur noch begrenzt möglich oder sinnvoll ist. Häufig sind komplexe physikalische Modelle (bspw. FE-Modelle, aber auch analytische Modelle) notwendig, um Einwirkungen und Bauwerksreaktionen in Bezug zu setzen und evtl. Abweichungen festzustellen. Für Methoden aus dem Bereich des maschinellen Lernens (Machine Learning, ML) werden diese physikalischen Modelle nicht benötigt, deren Eingangsparameter oft nur schwer zu ermitteln sind oder geschätzt werden müssen. Im Sinne der prädiktiven Instandhaltung eignen sich ML-Methoden daher gut für die automatisierte Auswertung von Messdaten, da die Beschreibung physikalischer Prozesse nicht erforderlich ist und der Aufwand damit erheblich gesenkt werden kann. Die Vorgehensweise zur Nutzung dieser Methoden ist dabei immer gleich: Anlernen eines Machine-Learning-Modells (Machine Learning Model) auf einen Datensatz und Anwenden des trainierten Modells auf neue Daten. So können u. a. komplexe nichtlineare und instationäre Zusammenhänge durch ein auf (Mess-)Daten trainiertes Machine-Learning-Modell beschrieben werden.

Im Folgenden sollen einige Anwendungsmöglichkeiten von Machine-Learning-Methoden in Bezug auf Langzeitmonitoringdaten von Infrastrukturbauwerken dargestellt werden, um ihr Potenzial aufzuzeigen. Dafür wird zunächst ein kurzer Überblick über das maschinelle Lernen gegeben, wobei der theoretische bzw. mathematische Hintergrund von KI-Methoden stark vereinfacht dargestellt wird. Anschließend erfolgt die Anwendung auf die Beschreibung des Zusammenhangs zwischen der Luft- und Bauwerkstemperatur. Anhand dieses Beispiels werden weitere Anwendungsfälle dieser Methoden aus der Praxis dargestellt, was den Fokus des Aufsatzes darstellt.

 © 2020 Ernst & Sohn Verlag für Architektur und technische Wissenschaften GmbH & Co. KG, Berlin.

2 Maschinelles Lernen

2.1 Überblick

Das maschinelle Lernen ist ein Teilgebiet der künstlichen Intelligenz mit dem Ziel, Wissen bzw. Informationen und Zusammenhänge aus Daten zu extrahieren. In diesem Kontext wird auch häufig von prädiktiver Analytik oder statistischem Lernen gesprochen [3]. Es gliedert sich wiederum in drei Bereiche auf (Bild 1). Einen Überblick liefert auch [1].

Das bestärkende Lernen ist eine besondere Form des maschinellen Lernens, bei dem ein Agent auf Grundlage von Belohnungen eine bestimmte Strategie erlernt. Es verhalf u. a. Google eine Software zu entwickeln, die in der Lage war, die weltbesten Go-Spieler zu besiegen [4]. (Anm.: Das chinesische Brettspiel Go galt lange Zeit als große Herausforderung für die Entwicklung im Bereich des maschinellen Lernens.)

Beim unüberwachten Lernen ist das Ergebnis der zu lernenden Aufgabe ebenfalls nicht bekannt. Häufig werden sog. Clusterverfahren eingesetzt. Diese lernen, die Eingabedaten nach den gegebenen Merkmalen (Features) voneinander zu trennen und in für den Algorithmus bzw. den Nutzer unbekannte Gruppen (Cluster) zu sortieren. Clusterverfahren können bspw. für die Plausibilisierung von Messdaten genutzt werden [5].

Die dritte Form ist das überwachte Lernen. In diesem Fall wird das gewünschte Ergebnis während der Lernphase mit in den Algorithmus hineingegeben. Der Algorithmus stellt dann einen Zusammenhang zwischen Eingangs- und Ausgangsdaten her. Die Klassifikation im Bereich des überwachten Lernens ist vergleichbar mit dem Clustern, nur sind die Gruppen (Labels) im Vorfeld bekannt. Der Algorithmus ist nach dem Training in der Lage, einen Output für einen unbekannten Input zu generieren, ohne dass dabei die Hilfe eines Menschen notwendig ist [3].

In der Forschung im Bereich des Bauwerksmonitorings werden Klassifikatoren bspw. dafür genutzt, um den Ursprung bzw. die Quelle akustischer Signale beim Schallemissionsmonitoring an Betonbauteilen zu identifizieren [6]. Dies ist erforderlich, um die Signale nach (Struktur-) Schädigungssignalen und Rauschen voneinander zu trennen. Weiterhin werden mit Klassifikatoren Langzeitdaten in [7] in plausible und unplausible (fehlerhafte) Daten separiert.

Eine weitere in diesem Aufsatz genutzte Form des überwachten Lernens ist die Regression. Multiparameterregressionen wurden bspw. in [8], Support-Vector-Regressionen in [9] und neuronale Netze in [10] genutzt, um den Einfluss von Einwirkungen auf Brückenbauwerksreaktionen zu untersuchen. Auf Grundlage der Regressionsparameter konnte in [8] der Verkehrseinwirkung bspw. der größte Einfluss zugesprochen werden. In [11] werden

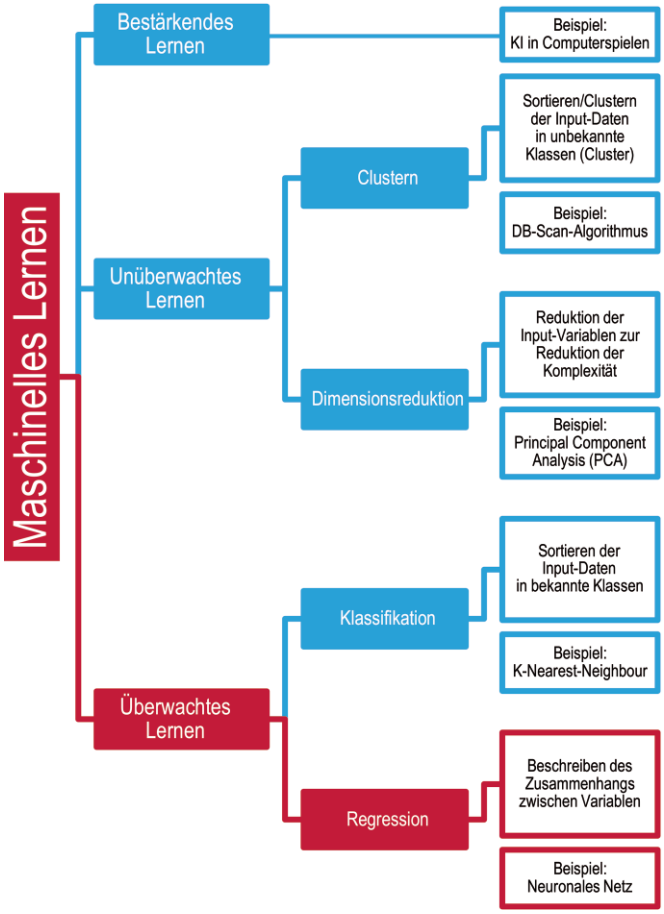

Bild 1 Bereiche des maschinellen Lernens und Kennzeichnung der hier angewandten Methode (rot)
Fields of machine learning and marking of the method used (red)

neuronale Netze für ähnliche Untersuchungen genutzt. Dort wird die Dimension der Inputdaten durch die Principal Component Analysis (PCA) (Bild 1) zuvor reduziert. Regressionsverfahren werden in [12, 13] außerdem zur Erkennung von Messfehlern genutzt (Abschn. 4.1). Einen Überblick über ML-Methoden im Zusammenhang mit Monitoringdaten liefert außerdem [1].

Zur Abbildung instationärer Prozesse mithilfe von Regressionsverfahren sei bspw. auf [14] verwiesen, wo das Temperaturverhalten in verschiedenen Tiefen des Bodens in Abhängigkeit von den Umgebungsparametern (Lufttemperatur, Niederschlag etc.) beschrieben wird. [15] löst diese Problematik stationär, indem Monatswerte genutzt werden.

In Bild 2 sind zwei Verfahrensweisen dargestellt, die sich im Bekanntsein des Outputs voneinander unterscheiden. Das Training eines Algorithmus ist vergleichbar mit Bild 2a, wobei der Output beim Clustern i. d. R. nicht bekannt ist, die Anwendung des Algorithmus kann durch Bild 2b beschrieben werden, welches außerdem den Fall beschreibt, dass der Output nicht bekannt ist. Beispielsweise ist die Lufttemperatur (Input) bekannt und die Bauwerkstemperatur (Output) soll ermittelt werden. In diesem Fall wird aus ingenieurtechnischer Sicht üblicherweise zu einem analytischen oder FE-Modell gegriffen,

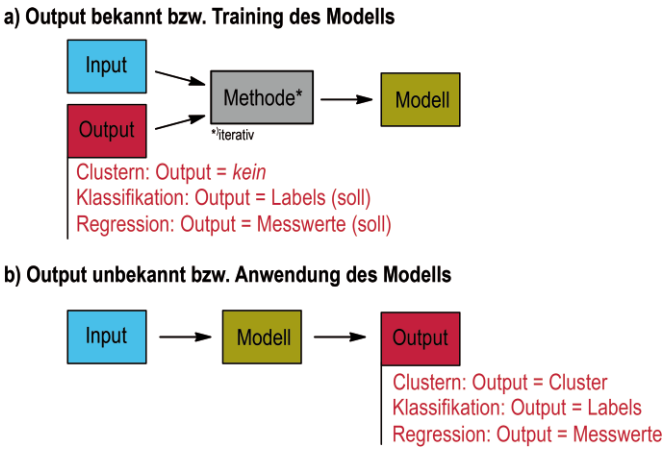

Bild 2 Darstellung des Trainings und der Anwendung von Machine-Learning-Modellen
Illustration of the training and application of machine learning models

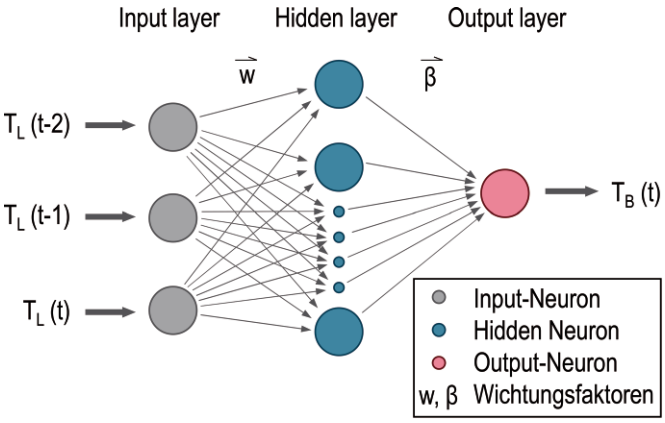

Bild 3 Neuronales Netz mit drei Input-Neuronen im Input Layer, einem Output-Neuron im Output Layer und sieben Hidden-Neuronen in einem Hidden Layer
Neural network with three input neurons in the input layer, one output neuron in the output layer and seven hidden neurons in one hidden layer

um das Bauwerksverhalten physikalisch zu beschreiben. Wenn sowohl Luft- als auch Bauwerkstemperatur bekannt sind (Bild 2a), kann ein analytisches oder FE-Modell verbessert/kalibriert werden. Dieser Prozess erfolgt dann i. d. R. iterativ, indem die (meist geschätzten) Parameter des physikalischen Modells so lange angepasst werden, bis der Unterschied zwischen der berechneten und der tatsächlichen Bauwerkstemperatur gering ist, sodass im Ergebnis ein kalibriertes Modell steht. Genauso wird beim Training eines Machine-Learning-Modells vorgegangen, welches jedoch keinen physikalischen Hintergrund besitzt. Im Ergebnis steht dann ein trainiertes (mathematisches) Modell. Der Vorteil ist, dass die physikalischen Zusammenhänge nicht als solche beschrieben werden müssen.

2.2 Neuronale Netze

Neuronale Netze sind eine besondere Form des maschinellen Lernens, bei denen der Zusammenhang zwischen In- und Output über eine Netzstruktur approximiert wird. Diese Art der Regressionsmodelle ist gut für die vorliegende Problemstellung geeignet, wie ebenfalls aus der Literatur hervorgeht [14, 15]. Denkbar wäre bspw. aber auch ein Support Vector Regressor. Ein Performance-Vergleich verschiedener Methoden soll in diesem Aufsatz nicht vorgenommen werden, da das Hauptaugenmerk auf der Darstellung von Anwendungsfällen liegt.

Ein neuronales Netz ist beispielhaft in Bild 3 dargestellt. Es besteht aus drei Teilen: der Input- sowie der Output-Schicht (Input Layer, Output Layer) und der bzw. den versteckten Schicht(-en) (Hidden Layer). Die Layer wiederum bestehen aus Neuronen (Neurons).

Auf der linken Seite stehen die Eingabedaten. Für die in Abschn. 3 gezeigte Problemstellung ist dies die Lufttemperatur T_L zu verschiedenen Zeitpunkten, um die zeitliche Komponente beim Zusammenhang zwischen der Luft- und der Bauwerkstemperatur zu berücksichtigen (instationärer Prozess, s. Abschn. 3.1). Die Anzahl der Neuronen im Input Layer richtet sich nach der Anzahl der Features, in diesem Beispiel: drei. Der Output ist die Bauwerkstemperatur T_B zum Zeitpunkt t. Dazwischen befinden sich beliebig viele Hidden Layers mit beliebig vielen Neuronen. Die Anzahlen können über sog. Hyperparameter gesteuert und vom Nutzer vorgegeben werden. Die Inputdaten werden gewichtet, summiert und – sofern das Neuron aktiviert wird – in das nächste Neuron übergeben. Ob ein Neuron aktiviert wird, ist von der Aktivierungsfunktion abhängig. Für weitergehende Informationen zu neuronalen Netzen sei bspw. auf [16] verwiesen.

Beim Training (Training/Fit) eines Netzwerks werden die in Bild 3 dargestellten Wichtungsfaktoren so lange automatisiert angepasst, bis eine bestimmte Bedingung erfüllt ist. Die Bedingung ist, dass der vom Modell produzierte Output $T_{B,Modell}$ den tatsächlichen Output $T_{B,gemessen}$ möglichst gut abbildet. Als Kriterium (Metric) kann bspw. das Bestimmtheitsmaß R^2 oder der mittlere absolute Fehler (Mean Absolute Error, *mae*) genutzt werden. Das Training erfolgt dabei iterativ. Der Datensatz wird dazu mehrfach hintereinander durchgegangen (Epochs). Die sog. Batch Size bestimmt dabei, nach wie vielen Inputdaten die Gewichte angepasst werden.

Es ist weiterhin darauf zu achten, dass kein Overfitting stattfindet. Dies beschreibt das Phänomen, dass das Modell die Trainingsdaten sehr viel besser vorhersagen kann als die Nicht-Trainingsdaten. In diesem Zusammenhang wird auch von „Auswendiglernen“ gesprochen (Abschn. 3.3).

Bei der Anwendung (Prediction) des trainierten Modells werden die neuen Inputdaten in das trainierte Modell gegeben. Mit den (beim Training erzeugten) Wichtungsfaktoren wird der Output erzeugt. Dies ist vergleichbar mit Bild 2b.

3 Prognose des Temperaturverhaltens der Grubentalbrücke

3.1 Problemstellung

Im Folgenden wird der Zusammenhang zwischen Luft- und Bauwerkstemperatur dargestellt und durch ein Machine-Learning-Modell beschrieben. Dazu werden Messdaten der Grubentalbrücke herangezogen (Bild 4). Hintergründe zu den Messungen (Bauwerke, Messlayouts etc.) sind in [17–19] beschrieben und resultieren im Wesentlichen aus der semiintegralen Bauweise.

Während der Herstellung des Bauwerks wurden Sensoren zur Erfassung der Bauwerkstemperatur im Querschnitt an verschiedenen Stellen einbetoniert. Die Lufttemperatur wird zwischen den Stegen gemessen; die Messstelle befindet sich damit dauerhaft im Schatten. Um aus den sechs verschiedenen Bauwerkstemperaturmessstellen eine repräsentative (und sog. dehnungswirksame) Bauwerkstemperatur zu erhalten, wird ein gewichteter Mittelwert so berechnet, dass die Resultierende möglichst stark mit gemessenen Fugenverschiebungen korreliert [19].

Gerade bei Massivbrücken können durch die Baustoffeigenschaften (Wärmeausbreitung und -speicherung) und die Querschnittsabmessungen große Differenzen zwischen Luft- und Bauwerkstemperatur entstehen [20]. Bild 5 zeigt diesen instationären Zusammenhang. Es ist zu erkennen, dass bspw. bei einer Lufttemperatur von etwa 14 °C nahezu jede Bauwerkstemperatur zwischen 2 und 26 °C liegen kann.

Bei den folgenden Untersuchungen wird indirekt unterstellt, dass die Bauwerkstemperatur lediglich von der Lufttemperatur abhängt, da diese als einziger Input in das Modell gegeben wird. Einflüsse wie Sonneneinstrahlung, Wind und Niederschlag werden nicht berücksichtigt. Dabei ist anzumerken, dass diese ohnehin zu den Lufttemperaturmessungen korrelieren. Nach diesem Ansatz ist die Bauwerkstemperatur direkt abhängig von der Lufttemperatur, wobei die Dauer, bei der eine bestimmte Lufttemperatur vorliegt, einen großen Einfluss auf die resultierende Bauwerkstemperatur hat, da es sich um einen instationären Prozess handelt.

Nach Bild 5 und [20] kann der Zusammenhang zwischen Luft- und Bauwerkstemperatur daher wie folgt zusammengefasst werden:

- Die Bauwerkstemperatur hängt der Lufttemperatur zeitlich hinterher (instationär),
- die Bauwerkstemperatur erreicht i. d. R. sowohl im positiven als auch im negativen Bereich nicht die Extremtemperaturen der Lufttemperatur,
- für jede Lufttemperatur kann es mehrere Bauwerkstemperaturen geben (und andersherum).

Im Folgenden soll dieser Zusammenhang über ein Machine-Learning-Modell beschrieben werden. Eine analytische Beschreibung oder ein FE-Modell wären ebenfalls möglich, allerdings wären genaue Kenntnisse über

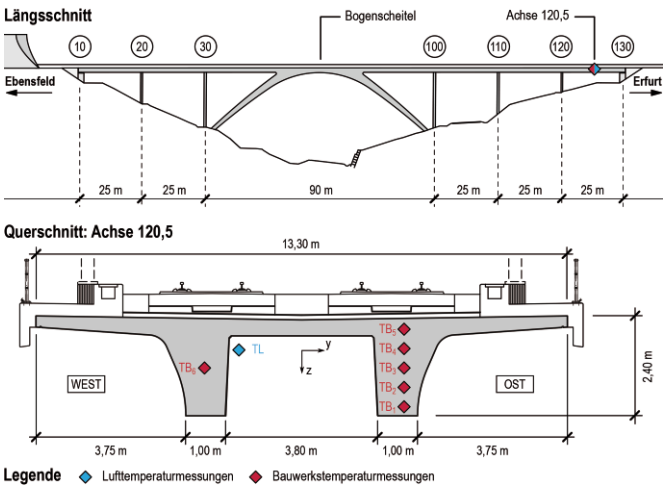

Bild 4 Längs- und Querschnitt der Grubentalbrücke mit Sensorik
Longitudinal and cross section of the Grubentalbrücke with sensors

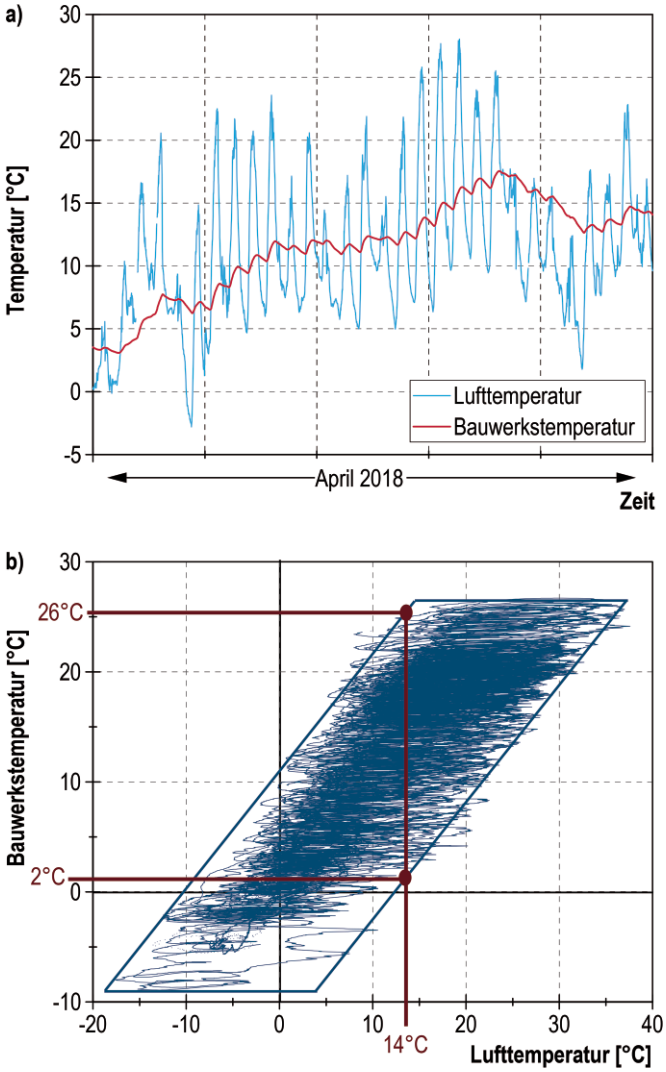

Bild 5 a) Luft- und Bauwerkstemperaturmessungen im April 2018, b) Bauwerkstemperatur als Funktion der Lufttemperatur (Messzeitraum: 10/2015–10/2019)
a) Air and bridge temperature in April 2018, b) bridge temperature as a function of air temperature (measurement period: 10/2015–10/2019)

die Bauwerksgeometrie (Querschnitt) sowie Baustoffeigenschaften (Wärmeleitfähigkeit, spezifische Wärmekapazität etc.) erforderlich. Diese entfallen bei ML-Algorithmen, da es sich hier um einen datenbasierten Ansatz ohne physikalische Gesetzmäßigkeiten handelt bzw. sind diese in den Messdaten zwangsläufig enthalten.

3.2 Datensatz, Datenvorbereitung und Training

Der Datensatz bestehend aus den Zeitreihen Lufttemperatur zwischen den Überbaustegen der Grubentalbrücke (dauerhaft verschattet) und die gemittelte dehnungswirksame Bauwerkstemperatur über einen Zeitraum von etwa 38 Monaten wurden bereits in Bild 5 dargestellt. Die Messwerte wurden alle zehn Minuten erfasst. Für das Training werden die Daten von 2017 genutzt.

Die Daten wurden vor dem Training linear zwischen 0 und 1 skaliert. Das neuronale Netz besitzt zwei Hidden Layers mit je 100 Neuronen. Mit einer Batch Size von 2 wurden 13 Epochs für das Training durchlaufen. Als Aktivierungsfunktion wurde ReLU (Rectified Linear Unit Function) und als Optimierungsalgorithmus ein stochastischer gradientenbasierter Optimierer genutzt. Die genannten Einstellungen (Anzahl von Layern und Neuronen, Batch Size, Aktivierungsfunktion) wurden mithilfe von Sensitivitätsstudien so gewählt, dass eine ausreichende Genauigkeit bei vertretbarer Rechenzeit (ca. 2.30 min bei 32 Threads á 3,5 GHz) vorlag. Sowohl die Erhöhung der Layer als auch die der Neuronen führte höchstens zu einer marginalen Verbesserung des Ergebnisses bei erheblich höherem Rechenaufwand.

In den Input Layer wird die Lufttemperatur der vergangenen zwei Wochen hineingegeben. Vorangestellte Parameterstudien lieferten diesen optimalen Zeitraum. Bei einer Messrate von einem Wert alle 30 min entspricht dies 2 Werte/h · 24 h/d · 14 d = 672 Werten der Lufttemperatur, die zum Training und zur Anwendung je zu berechnender Bauwerkstemperatur in den Algorithmus gegeben werden. Auf diese Art und Weise wird der instationäre Charakter des Prozesses im Modell berücksichtigt.

3.3 Ergebnisse

Die Ergebnisse der Prediction sind in Bild 6 dargestellt. Da für das Training eine lineare Skalierung vorgenommen wurde, wurde diese nach der Prediction invertiert. Das Modell wird auf den gesamten Messzeitraum von 38 Monaten angewendet. Einen merklichen Unterschied zwischen dem Trainingzeitraum (Jahresscheibe 2017, entspricht 32 % der Daten) und dem übrigen Zeitraum (entspricht 68 % der Daten) gibt es nicht, sodass davon ausgegangen werden kann, dass kein Overfitting stattgefunden hat (Abschn. 2.2).

Aus Bild 6a wird deutlich, dass die Verläufe der gemessenen und der berechneten Bauwerkstemperaturen sehr

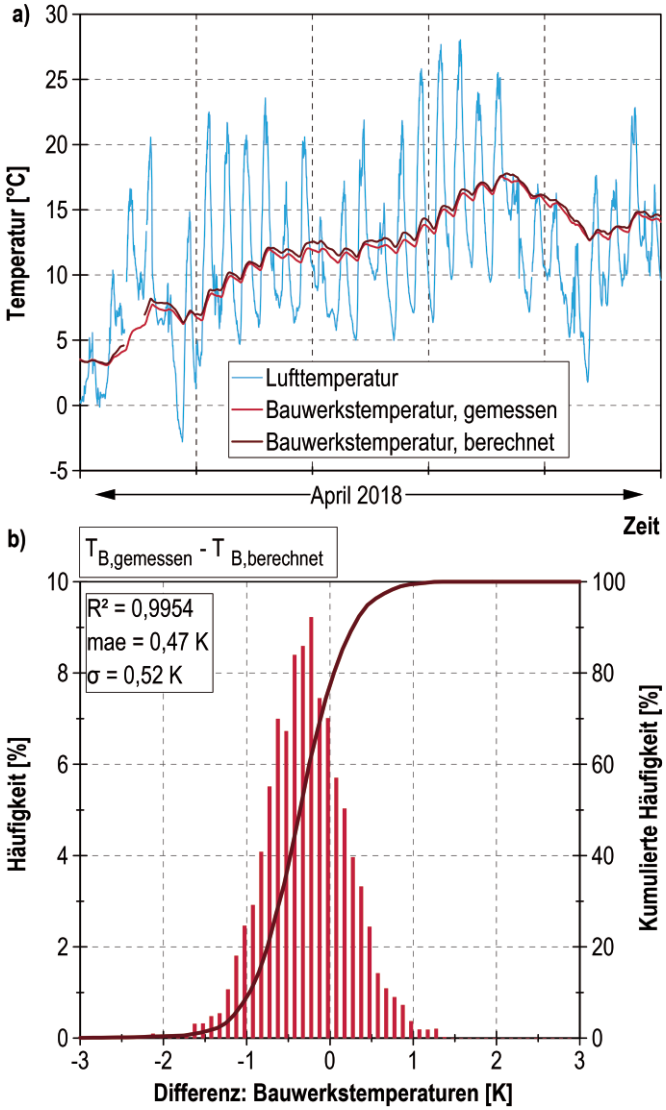

Bild 6 a) Ergebnisse des Modells im Vergleich zur tatsächlichen Bauwerkstemperatur, b) Histogrammklassierung der Differenz zwischen gemessener und berechneter Bauwerkstemperatur über den gesamten Messzeitraum
a) Results of the prediction compared to the actual bridge temperature, b) histogram classification of the difference between measured and calculated bridge temperatures over the entire measurement period

gut übereinstimmen. Infolge fehlender Messwerte der Lufttemperatur Anfang April ist eine entsprechende Lücke in den berechneten Daten vorhanden. Für die untere Abbildung (Bild 6b) wurde die Differenz zwischen der gemessenen und der berechneten Bauwerkstemperatur ermittelt und die Verteilung dieser Residuen berechnet. Zusätzlich sind das Bestimmtheitsmaß R^2, der mittlere absolute Fehler *mae* und die Standardabweichung σ für den kompletten Messzeitraum (38 Monate) angegeben.

Die Ergebnisse zeigen, dass das Vorgehen für die vorliegende Problemstellung geeignet ist. Die gezeigte Vorgehensweise wird im Folgenden auf verschiedene Problemstellungen in Bezug auf den Zusammenhang zwischen Luft- und Bauwerkstemperatur übertragen.

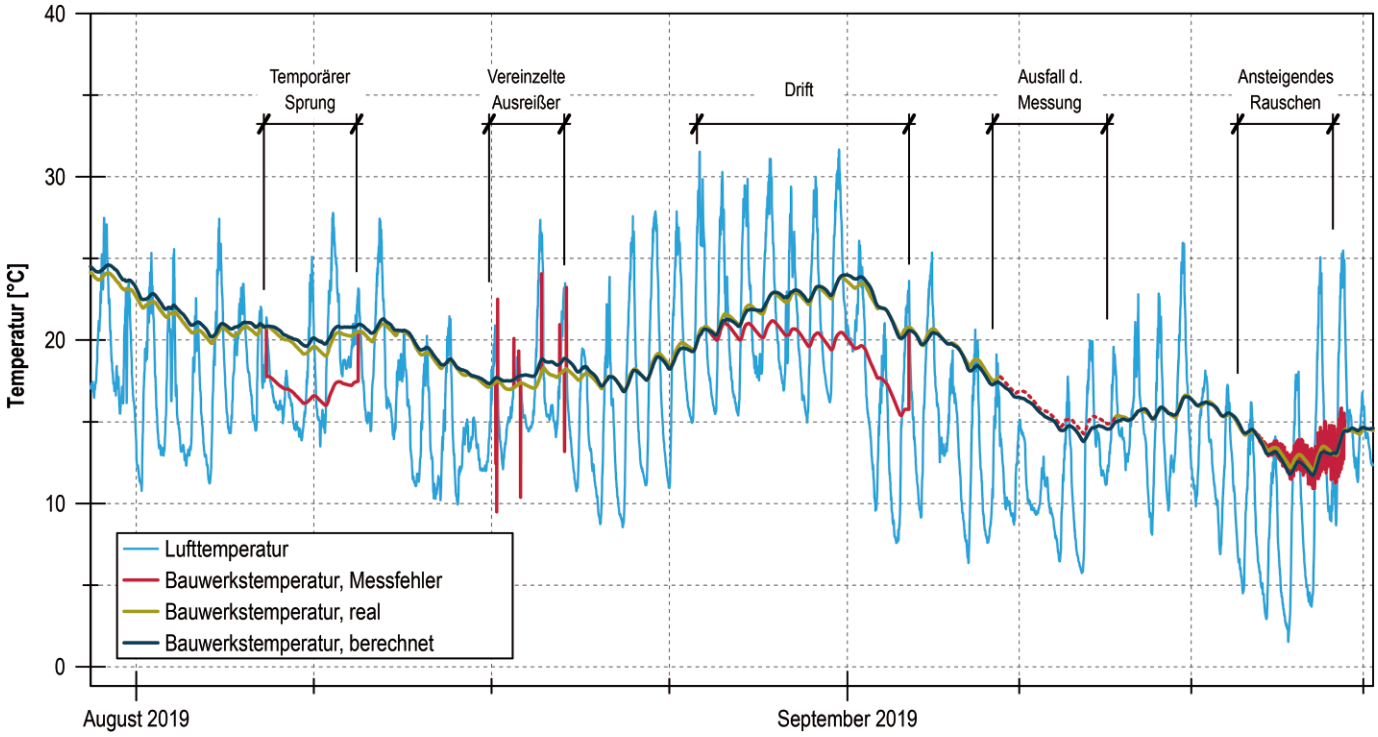

Bild 7 Darstellung typischer Messfehler am Beispiel der Bauwerkstemperatur und Vergleich zur aus der Lufttemperatur berechneten Bauwerkstemperatur (Messfehler wurden künstlich eingefügt)
Diagram of typical measurement faults using the example of the bridge temperature and comparison with the bridge temperature calculated from the air temperature (measurement errors were artificially inserted)

4 Anwendungsfälle

4.1 Messfehlerdetektion und -kompensation

Eine wichtige Anwendungsmöglichkeit für die vorgestellte Methode ist das Erkennen von Messfehlern sowie deren Kompensation. Während langjähriger Bauwerksmessungen kann es zu verschiedenen Messfehlern kommen, welche bspw. in [21, 22] beschrieben sind. Typische Messfehler zeigt Bild 7. Je nach Ursache treten solche Messfehler häufig nur an vereinzelten Sensoren auf, sodass eine Berechnung des prognostizierten Verhaltens über andere Sensoren möglich ist, sofern diese nicht auch verunreinigt sind.

Die fehlerhaften Bereiche könnten durch entsprechende Vergleichslogiken zwischen realem (fehlerhaftem) Messwert und prognostiziertem (berechnetem) ausfindig und im weiteren Verlauf bewertet und wenn nötig kompensiert werden.

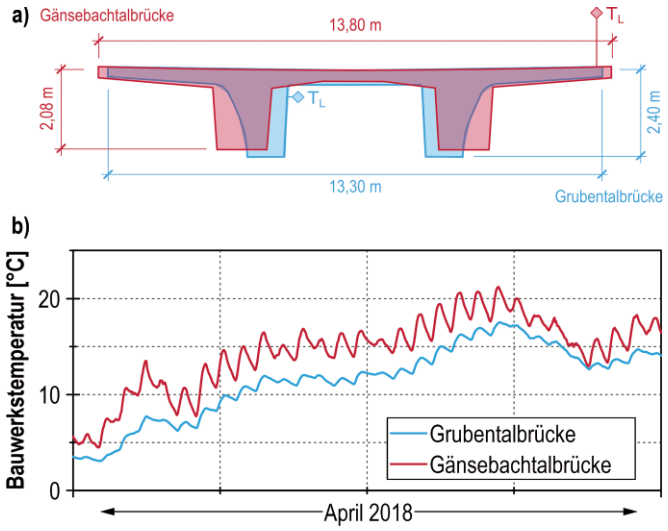

Bild 8 a) Regelquerschnitte der Grubental- und Gänsebachtalbrücke und Positionen der Lufttemperaturmessungen im Vergleich, b) Bauwerkstemperaturmessungen im Vergleich
a) Comparison of cross-sections of the Grubentalbrücke and Gänsebachtalbrücke and positions of the air temperature sensors, b) bridge temperature measurements in comparison

4.2 Übertragung von trainierten Modellen auf andere Bauwerke

Dieser Anwendungsfall trat im Zuge des Rückbaus einer Spannbetontalbrücke auf. Für den sukzessiven Rückbau mit Vorschubrüstung waren Trennschnitte des Überbaus erforderlich. Um die Standsicherheit während des Rückbaus zu gewährleisten, durften die Trennschnitte nur unter bestimmten Temperaturrandbedingungen des Überbaus durchgeführt werden. Die unbekannte Bauwerkstemperatur sollte aus vorliegenden Lufttemperaturmessungen bestimmt werden. Es lagen jedoch nur kombinierte Luft- und Bauwerkstemperaturmessungen eines Bauwerks mit ähnlichen Randbedingungen vor. Diese können dennoch genutzt werden, wie anhand des bereits gezeigten Beispiels der Grubentalbrücke erläutert wird.

Bild 8a zeigt die Querschnitte der Grubentalbrücke und Gänsebachtalbrücke. Ihre Querschnitte sind zweistegige

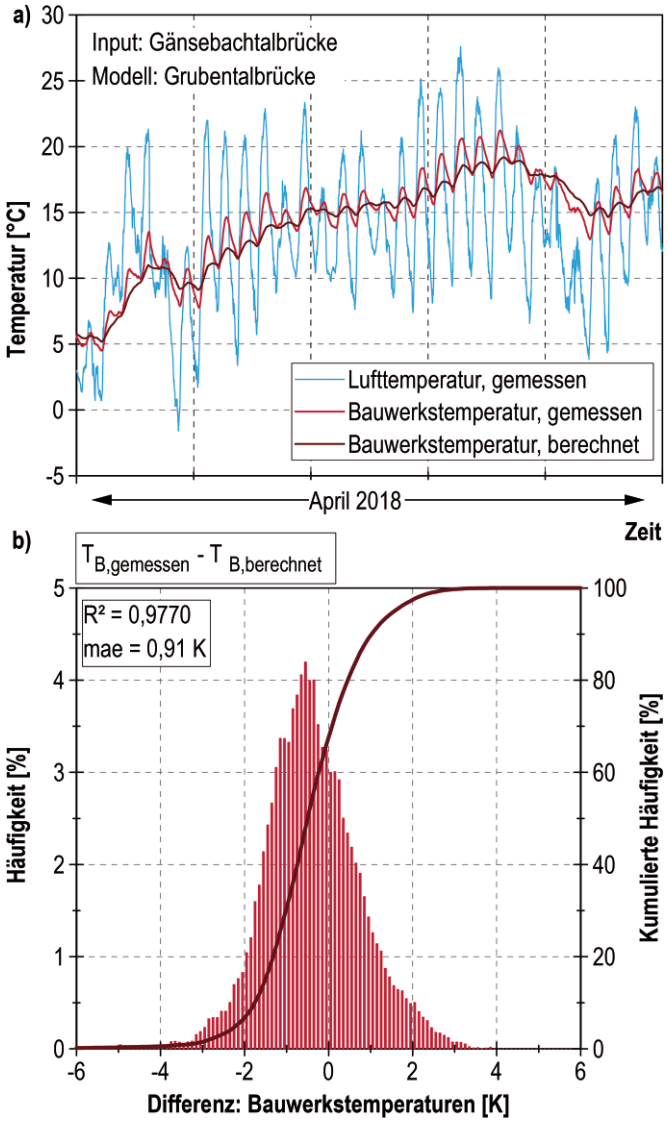

Bild 9 Anwendung des Modells von der Grubentalbrücke auf Daten der Gänsebachtalbrücke: a) Darstellung über die Zeit, b) Histogrammklassierungen der Differenzen zwischen gemessener und berechneter Bauwerkstemperatur über einen Zeitraum von vier Jahren
Application of the model trained with data of Grubentalbrücke to data of Gänsebachtalbrücke; a) representation over time, b) histogram classifications of the differences between measured and calculated bridge temperature over a measuring period of four years

Plattenbalken mit ähnlichen Abmessungen. Bild 8b zeigt die jeweiligen Temperaturen der Bauwerke im Zeitraum April 2018.

Die Bauwerkstemperaturmessungen wurden bei beiden Bauwerken analog ausgeführt und zu einer dehnungswirksamen Bauwerkstemperatur zusammengefasst. Die Lufttemperaturmessungen wurden bei der Grubentalbrücke zwischen den Stegen des Plattenbalkens und bei der Gänsebachtalbrücke an einem Mast etwa 2 m oberhalb der Fahrbahn durchgeführt (Bild 8a). Während die gemessenen Lufttemperaturen bei den Bauwerken (hier nicht dargestellt) tägliche Schwankungen in ähnlicher Größe aufwiesen, reagiert die Gänsebachtalbrücke empfindlicher auf diese Änderungen. Es ist erkennbar, dass vergleichsweise größere Schwankungen der täglichen Bauwerkstemperatur bei der Gänsebachtalbrücke vorliegen. Dafür gibt es neben der Querschnittsgeometrie mehrere Ursachen: Einerseits kann die Grubentalbrücke durch das steile Tal und die dichte Vegetation verschattet werden, während die Gänsebachtalbrücke auf freiem Feld unverschattet bleibt. Andererseits wird der wesentliche Einfluss jedoch darin vermutet, dass die Grubentalbrücke Nord-Süd ausgerichtet ist, während die Gänsebachtalbrücke eher eine Ost-West-Ausrichtung aufweist. Dies führt dazu, dass das Tragwerk der Gänsebachtalbrücke einen Großteil des Tags von der Sonne direkt beschienen wird, während die Sonne bei der Grubentalbrücke hauptsächlich auf die feste Fahrbahn scheint und sich dies weniger stark auf die Temperatur des Tragwerks selbst auswirkt.

Für die nachfolgend dargestellte Untersuchung wurde das Modell aus Abschn. 3.2 genutzt, demnach fand das Training mit Daten der Grubentalbrücke statt. Es werden für die Prediction jedoch die Lufttemperaturmessungen der Gänsebachtalbrücke verwendet, um die Bauwerkstemperatur ebendieser zu ermitteln. Die Ergebnisse sind in Bild 9 dargestellt.

Aus Bild 9a wird deutlich, dass die berechnete Bauwerkstemperatur nur den ungefähren Verlauf der gemessenen Bauwerkstemperatur nachempfinden kann, die Tagesextremwerte aber nicht gut abbildet. Dabei sei angemerkt, dass lt. Bild 9b über 90 % der Abweichungen zwischen der gemessenen und der berechneten Temperatur im gesamten Messzeitraum (vier Jahre) kleiner sind als ± 2 K. Die Abweichungen sind darin begründet, dass die Bauwerkstemperatur an der Grubentalbrücke kleineren täglichen Schwankungen unterliegt als die der Gänsebachtalbrücke (Bild 8b). Das Modell hat demnach entsprechende Schwankungen der Bauwerkstemperatur in Größenordnung der Grubentalbrücke ermittelt, die für die Gänsebachtalbrücke zu klein sind. Es konnte dennoch gezeigt werden, dass die Abweichungen gering sind und das Verfahren grundsätzlich funktioniert und für den vorliegenden Fall geeignet ist.

4.3 Separation von Einflüssen

In Abschn. 3.1 wird vorausgesetzt, dass die Bauwerkstemperatur allein durch die Lufttemperatur beschrieben werden kann. Natürlich gibt es weitere Umwelteinflüsse, die dabei eine Rolle spielen. Wie in [20] dargestellt und in Abschn. 4.2 beschrieben, hat bspw. die Sonneneinstrahlung ebenfalls einen Einfluss auf die Bauwerkstemperatur. Nachfolgend wird neben der Lufttemperatur auch die Sonneneinstrahlung in das Modell gegeben. Dazu muss ein neues Training mit multivariablem Input stattfinden. Das Berücksichtigen der Strahlung verbessert das Bestimmtheitsmaß der Prediction auf R^2 = 0,9962, den mittleren absoluten Fehler auf *mae* = 0,41 K und die Standardabweichung auf σ = 0,47 K bei gleichen Randbedingungen im Vergleich zum Modell ohne Strahlung (s. Bild 6).

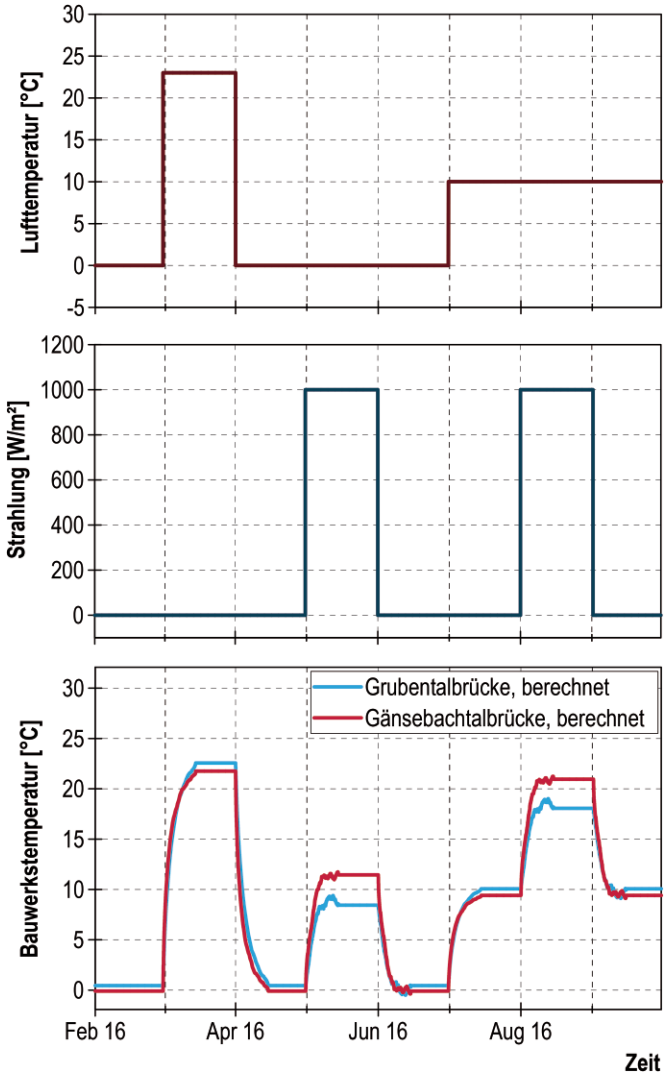

Bild 10 Berechnung der Bauwerkstemperaturen auf Grundlage der Lufttemperatur und der globalen Sonneneinstrahlung an Grubental- und Gänsebachtalbrücke auf Grundlage eines fiktiven Datensatzes zur Darstellung des Einflusses der Input-Daten
Simulation of the structure temperatures based on air temperature and global solar radiation at the Grubental- and the Gänsebachtalbrücke based on a fictitious data set to illustrate the influence of the input data

Mithilfe eines fiktiven Datensatzes können die Einflüsse aus Lufttemperatur und Sonneneinstrahlung voneinander getrennt werden, wie Bild 10 zeigt. Es werden die zwei Modelle der Grubental- und der Gänsebachtalbrücke genutzt. Die Lufttemperatur wird zeitweise auf 23 °C angehoben, die Strahlung auf 1 000 W/m^2 (entspricht etwa einem sonnigen Sommertag).

Um die Einflüsse zu separieren, wird zunächst nur die Lufttemperatur, dann die Sonneneinstrahlung und dann eine Kombination als fiktiver Datensatz erzeugt. Die Ergebnisse der Untersuchungen können wie folgt zusammengefasst werden:

- Beide Bauwerke benötigen etwa zwei Wochen, damit ein Gleichgewicht zwischen Luft- und Bauwerkstemperatur herrscht.
- Bei der Sonneneinstrahlung wird nur etwa eine Woche für das Gleichgewicht benötigt.
- Die Gänsebachtalbrücke reagiert sensitiver auf die Sonneneinstrahlung. Dies bestätigt die in Abschn. 4.2 getroffenen Aussagen.

4.4 Vorhersage von Messdaten

In Abschn. 4.2 wurde der Anwendungsfall der Übertragbarkeit auf andere Bauwerke oder Problemstellungen gezeigt. Im Beispiel musste die Bauwerkstemperatur für eine komplexe (Rück-)Baumaßnahme in einem bestimmten Bereich liegen. In der Regel muss die Durchführung solcher Maßnahmen auf der Baustelle gut geplant sein, weil häufig verschiedene Gewerke daran teilnehmen, die zuvor koordiniert werden müssen. Daher ist es erforderlich, den genauen Termin zur Durchführung der Maßnahme bestenfalls einige Tage/Wochen im Vorfeld exakt festzulegen. Da die voraussichtliche Bauwerkstemperatur (und damit speziell die voraussichtliche Lufttemperatur) jedoch ein wesentliches Kriterium für die Durchführung darstellte, ist es hilfreich, wenn diese Einflussgröße zuvor abgeschätzt werden kann.

Es gibt für die Vorhersage von (Mess-)Daten zwei Möglichkeiten. Sie unterscheiden sich darin, ob bereits in die Zukunft prognostizierte Daten einbezogen werden können:

a) Prognose allein auf Grundlage vergangener Messdaten,
b) Prognose mithilfe von bereits vorhergesagten Wetterdaten (bspw. die Wettervorhersage des Deutschen Wetterdienstes).

Auf die Darstellung von Methode a) wird im Folgenden verzichtet, da der genutzte Regressor dies nicht leisten

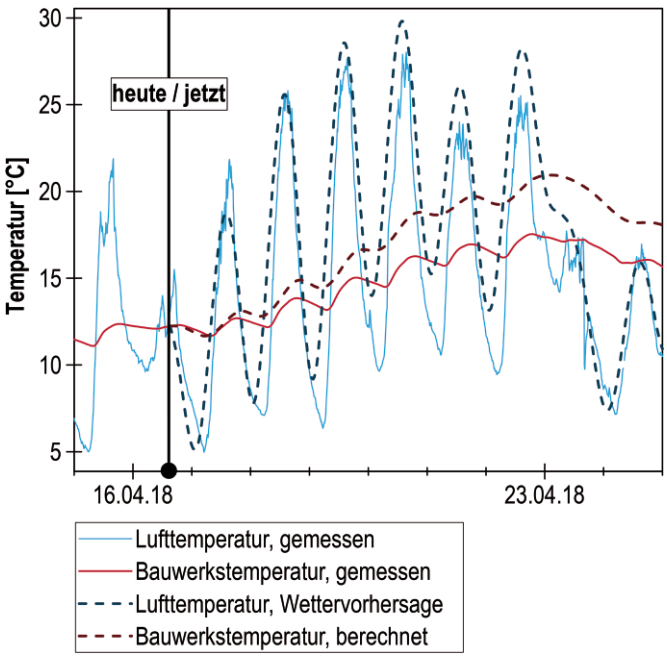

Bild 11 Vorhersage der Bauwerkstemperatur auf Grundlage einer fiktiven Wettervorhersage
Forecast of the bridge temperature based on a fictitious weather forecast

kann. Dafür wären komplexere neuronale Netze (bspw. Long Short-Term-Memory Networks) oder autoregressive Modelle (wie sie bspw. in [23] genutzt wurden) erforderlich, die in den hier beschriebenen Untersuchungen nicht genutzt wurden.

Das Ergebnis von Methode b) ist abhängig von der Prognosequalität der Wettervorhersage. Ansonsten kann das bereits in Abschn. 3.2 eingeführte Modell genutzt werden. Am Ende des Inputs werden lediglich die Prognosedaten der Wettervorhersage angehängt (Anm.: Es handelt sich um eine fiktive Wettervorhersage). Bild 11 zeigt die Resultate. Die prognostizierte Lufttemperaturentwicklung in den nächsten Tagen liegt über der real gemessenen. Dies führt dazu, dass die vom Modell berechnete Bauwerkstemperatur ebenfalls oberhalb der gemessenen liegt. Mit den in Bild 6b gezeigten Abweichungen zwischen gemessener und berechneter Bauwerkstemperatur ist die Güte der Vorhersage der Bauwerkstemperatur hier nur noch abhängig von der Zuverlässigkeit des Wetterberichts.

5 Zusammenfassung

Der Zusammenhang zwischen Luft- und Bauwerkstemperatur ist durch die zeitliche Komponente als instationär zu beschreiben. Über ein Machine-Learning-Modell konnte dieser ohne physikalisches Modell mit ausreichender Genauigkeit beschrieben werden (mittlerer absoluter Fehler von etwa 0,5 K). Zusätzlich wurde diese Vorgehensweise auf andere Anwendungsfälle übertragen. Die Ergebnisse können wie folgt zusammengefasst werden:

- physikalisch komplexe Zusammenhänge können über Machine-Learning-Algorithmen beschrieben werden,
- Messfehler können damit automatisch erkannt und kompensiert werden,
- trainierte Modelle können auf andere Problemstellungen/Bauwerke mit ähnlichen Randbedingungen übertragen werden,
- Einflüsse auf bestimmte Bauwerksverhalten/Messgrößen können voneinander separiert werden,
- das in der Zukunft liegende Bauwerksverhalten kann auf Grundlage bereits prognostizierter Werte (bspw. Wettervorhersage) abgeschätzt werden.

Im Ergebnis kann festgehalten werden, dass Machine-Learning-Methoden ein großes Potenzial für die Anwendung auf Monitoringdaten besitzen. Sie sind vielfältig einsetzbar und können dazu beitragen, verschiedene ingenieurtechnische Problemstellungen aus der Praxis auf einfache Art und Weise zu bewältigen. Die Grundlage dafür sind Langzeitdaten infolge eines Bauwerksmonitorings.

In weiteren Untersuchungen wird erörtert, wie das gezeigte Verfahren dafür genutzt werden kann, Struktur- und Verhaltensänderungen von Bauwerken zu erkennen bzw. vorherzusagen, um solche Effekte ausfindig zu machen und im Sinne der prädiktiven Instandhaltung ggf. notwendige Maßnahmen frühzeitig einzuleiten.

Literatur

[1] Luckey, D.; Fritz, H.; Legatiuk, D.; Dragos, K.; Smarsly, K. (2020) *Artificial intelligence techniques for smart city applications* in: Toledo Santos, E.; Scheer, S. [eds.] *Proceedings of the 18th International Conference on Computing in Civil and Building Engineering*. ICCCBE and CIB W78 Joint 2020, Sao Paolo, Brasilien, 18–20 Aug. 2020, pp. 3–15.

[2] Ullerich, C.; Grabe, M.; Wenner, M.; Herbrand, M. (2020) *smartBRIDGE Hamburg – prototypische Pilotierung eines digitalen Zwillings* in: Bautechnik 97, H. 2, S. 118–128.

[3] Müller, A. C.; Guido, S. (2016) *Introduction to Machine Learning with Python*. Sebastopol, CA: O'Reilly Media, Inc.

[4] DeepMind Technologies Limited (2020) *AlphaGo* [online]. London: DeepMind Technologies Limited. https://deepmind.com/research/case-studies/alphago-the-story-so-far [Zugriff am: 15. Mai 2020]

[5] Sawo, F.; Klumpp, V.; Beutler, F. (2015) *Intelligente Bauwerke – Anforderungen an die Aufbereitung von Messgrößen und ihrer Darstellungsform* in: Berichte der Bundesanstalt für Straßenwesen, Reihe B: Brücken- und Ingenieurbau (114).

[6] Wedel, F.; Käding, M.; Marx, S. (2019) *Schallemissionsmessungen zur Spanndrahtbrucherkennung* in: Beiträge zur 7. DAfStb-Jahrestagung mit 60. Forschungskolloquium 2019, S. 120–132.

[7] Sawo, F.; Eckhard, K. (2018) *Model-based and Statistical Approaches for Sensor Data Monitoring for Smart Bridges* [online]. https://www.intelligentebruecke.de/ibruecke/DE/Home/home_node.html [Zugriff: am 1. Juli 2020]

[8] Cross, E.; Koo, K.; Brownjohn J.; Worden, K. (2013) *Long-term monitoring and data analysis of the Tamar Bridge* in: Mechanical Systems and Signal Processing 35, no. 1–2, pp. 16–34.

[9] Ni, Y.; Hua, X.; Fan, K.; Ko, J. (2005) *Correlating modal properties with temperature using long-term monitoring data and support vector machine technique* in: Engineering Structures 27, no. 12, pp. 1762–1773.

[10] Ni, Y.; Zhou, H.; Ko, J. (2009) *Generalization Capability of Neural Network Models for Temperature-Frequency Correlation Using Monitoring Data* in: Journal of Structural Engineering 135, no. 10, pp. 1290–1300.

[11] Kromanis, R.; Kripakaran, P. (2014) *Predicting thermal response of bridges using regression models derived from measurement histories* in: Computers & Structures 136, pp. 64–77.

[12] Dragos, K.; Jahr, K.; Smarsly, K. (2016) *Nonlinear sensor fault diagnosis in wireless sensor networks using structural response data* in: The 23rd International Workshop of the European Group for Intelligent Computing in Engineering (EG-ICE). Krakau, Polen, 29 June 2016.

[13] Steiner, M.; Legatiuk, D.; Smarsly, K. (2019) *A support vector regression-based approach towards decentralized fault diagnosis in wireless structural health monitoring systems* in: The 12th International Workshop on Structural Health Monitoring (IWSHM). Stanford, CA, USA, 10 Sept. 2019.

[14] Feng, Y.; Cui, N.; Hao, W.; Gao, L.; Gong, D. (*2019). Estimation of soil temperature from meteorological data using different machine learning models* in: Geoderma 338, pp. 67–77.

[15] Bilgili, M. (2010) *Prediction of soil temperature using regression and artificial neural network models* in: Meteorol Atmos Phys 110, pp. 59–70.

[16] Farrar, C. R.; Worden, K. (2012) *Structural Health Monitoring: A Machine Learning Perspective*. West Sussex: John Wiley & Sons Ltd.

[17] Marx, S.; Wenner, M.; Käding, M.; Wedel, F. (2018) *Vom Rechnen und Wissen – Monitoring an den Talbrücken der Neubaustrecke Erfurt-Leipzig/Halle* in: Curbach, M. [Hrsg.] *28. Dresdner Brückenbausymposium Planung, Bauausführung, Instandsetzung und Ertüchtigung von Brücken* [Tagungsband]. TU Dresden, 12./13. März 2018, S. 41–56.

[18] Wenner, M.; Marx, S.; Koca, M. (2019) *Zusätzliche Schienenspannungen aus Langzeitverformungen von Eisenbahnbrücken mit Fester Fahrbahn – Modell und Realität* in: Bautechnik 96, H. 9, S. 674–695.

[19] Wenner, M.; Marx, S. (2015) *Structural Health Monitoring (SHM) an der Scherkondetalbrücke: eine semi-integrale Eisenbahn-Betonbrücke* in: Beton- und Stahlbetonbau 110, H. S2, S. 2–8.

[20] Mangerig, I.; Lichte, U.; Beucher, S. (2008) *FE 15.441/2006/FR, Fortschreibung DIN-FB 101, Einwirkungen auf Brücken – Ergänzende Untersuchungen zum Teilsicherheitsbeiwert für Temperatureinwirkungen auf Brücken* [Forschungsbericht]. Universität der Bundeswehr München.

[21] Dragos, K.; Smarsly, K. (2016) *Distributed adaptive diagnosis of sensor faults using structural response data* in: Smart Materials and Structures 25, no. 10.

[22] Jäger, D.; Zug, S.; Brade, B.; Dietrich, A.; Steup, C.; Moewes, C.; Cretu, A. (2014) *Assessing neural networks for sensor fault detection* in: IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications, Ottawa, 2014.

[23] Scott, D.; Simpson, T.; Dervilis, N.; Rogers, T.; Worden, K. (2018) *Machine Learning for Energy Load Forecasting* in: Journal of Physics: Conference Series 1106.

Autoren

Frederik Wedel, M. Sc. (Korrespondenzautor)
frederik.wedel@marxkrontal.com
Marx Krontal Partner
MKP GmbH
Uhlemeyerstr. 9+11
30175 Hannover

Univ.-Prof. Dr.-Ing. Steffen Marx
steffen.marx1@tu-dresden.de
Technische Universität Dresden
Institut für Massivbau
01062 Dresden

Zitieren Sie diesen Beitrag

Wedel, F.; Marx, S. (2020) *Prognose von Messdaten beim Bauwerksmonitoring mithilfe von Machine Learning.* Bautechnik 97, H. 12, S. 836–845. https://doi.org/10.1002/bate.202000073

Dieser Aufsatz wurde in einem Peer-Review-Verfahren begutachtet. Eingereicht: 21. Juli 2020; angenommen: 3. November 2020.