

Erkennung struktureller Veränderungen an realen Brücken unter Nutzung von Methoden des Maschinellen Lernens

Detection of structural changes in bridges
using machine learning methods

Vorgelegt von
Frederik Wedel
an der Fakultät für Bauingenieurwesen

Dissertation

Zur Erlangung des akademischen Grades

Doktor-Ingenieur (Dr.-Ing.)

Erstgutachter
Prof. Dr.-Ing. Steffen Marx

Zweitgutachter
Prof. Dr.-Ing. Karsten Geißler
Prof. Dr.-Ing. Thomas Braml

Tag der Einreichung: 04.04.2025

Tag der Verteidigung: 10.10.2025

- Hauptreferent: **Prof. Dr.-Ing. Steffen Marx**
Institut für Massivbau
Technische Universität Dresden
- Korreferent: **Prof. Dr.-Ing. Karsten Geißler**
Entwerfen und Konstruieren – Stahlbau
Technische Universität Berlin
- Korreferent: **Prof. Dr.-Ing. Thomas Braml**
Institut für konstruktiven Ingenieurbau
Universität der Bundeswehr München
- Kommissionsmitglied: **Prof. Dr.-Ing. Robert Jockwer**
Institut für Stahl- und Holzbau
Technische Universität Dresden
- Vorsitzender: **Prof. Dr.-Ing. habil. Karsten Menzel**
Institut für Bauinformatik
Technische Universität Dresden

Kurzfassung

Die zunehmende Anzahl alternder Brückenbauwerke und die damit verbundene Notwendigkeit, ihre Sicherheit und Nutzungsdauer zu gewährleisten, erfordern eine automatisierte Überwachung. Strukturelle Anomalien sollen frühzeitig erkannt werden, um rechtzeitig Maßnahmen einleiten zu können und kritische Schäden zu verhindern. Obwohl es in der Forschung zahlreiche Methoden zur Anomalieerkennung gibt, bleibt deren Übertrag in die Praxis begrenzt. Häufig werden diese Ansätze auf Labor- oder simulierten Daten getestet, deren Übertragbarkeit auf reale Bedingungen ungewiss ist.

In dieser Arbeit wird eine regressionsbasierte Methode auf reale Messdaten angewendet und ihre Praxistauglichkeit untersucht. Die Methode wurde gezielt gewählt, da sie Langzeitmonitoringdaten nutzt, die häufig an Bauwerken, wo ein Monitoring durchgeführt wird, erfasst werden und somit ohne zusätzlichen Messaufwand verfügbar sind. Die vorliegende Arbeit basiert auf Daten realer Bauwerke, bei denen dokumentierte strukturelle Änderungen erfasst wurden. Die Methode basiert auf der Vorhersage von Tragwerksreaktionen aus Temperaturmessungen mittels Machine-Learning-Modellen. Abweichungen zwischen den vorhergesagten und gemessenen Daten werden als Anomalien interpretiert, deren ingenieurtechnische Bewertung weiterhin auf physikalischen Zusammenhängen und Fachwissen beruhen muss. Dabei wird die Peak-Over-Threshold-Methode für die robuste Schwellenwertbestimmung verwendet, um zuverlässige Aussagen über das Vorliegen struktureller Änderungen zu treffen. Die Ergebnisse zeigen, dass die Methode auch unter praxisnahen Bedingungen zuverlässig funktioniert und robuste Vorhersagen liefert. Durch systematische Untersuchungen zu den erforderlichen Trainingsparametern konnte eine effektive und frühzeitige Anwendung der Methode ermöglicht werden. Zusätzlich wurden praxisorientierte Empfehlungen erarbeitet, die die Robustheit und Übertragbarkeit der Methode weiter stärken. Besonders hervorzuheben ist, dass die Methode in der Lage ist, strukturelle Anomalien, die sich in den gemessenen temperaturbedingten Tragwerksreaktionen widerspiegeln, frühzeitig zu erkennen und dabei flexibel auf unterschiedliche Bauarten und Problemstellungen anwendbar ist. Sie eignet sich sowohl für Massivbauwerke als auch für Verbundbauwerke und kann lineare Zusammenhänge ebenso modellieren wie nichtlineare Beziehungen, beispielsweise das temperaturbedingte Lagerverhalten. Dabei kommt die Methode mit Ausnahme der ingenieurtechnischen Interpretation ohne komplexe physikalische Modelle aus, was ihre Anwendbarkeit in der Praxis erheblich erleichtert.

Die durchgeführten Untersuchungen zeigen, dass der Multi-Layer-Perceptron-Regressor das leistungsstärkste Modell für die Vorhersage von Tragwerksreaktionen ist. Er ist leicht und schnell zu trainieren und ermöglicht eine präzise Abbildung sowohl linearer als auch nichtlinearer Zusammenhänge bei hoher Effizienz und Robustheit gegenüber Overfitting.

Ein wesentlicher Erkenntnisgewinn liegt weiterhin in der Unterscheidung zwischen Messfehlererkennung und struktureller Anomaliedetektion. Während zur Messfehlererkennung korrelierte Tragwerksreaktionen als Eingangsdaten genutzt werden, um Sensorausfälle oder Kalibrierprobleme zu identifizieren, werden zur Erkennung struktureller Änderungen ausschließlich externe Einwirkungen wie Temperatur verwendet. Dies verhindert, dass Strukturänderungen durch Korrelationen in den Eingangsdaten überdeckt werden.

Außerdem erfordert die Anwendung der Methode eine ingenieurtechnische Expertise in mehreren zentralen Bereichen: Zunächst ist eine sorgfältige Datenwahl erforderlich, um geeignete Eingangsgrößen für die Modellierung der Tragwerksreaktionen auszuwählen und sicherzustellen, dass relevante Einflussfaktoren angemessen berücksichtigt werden. Auch beim Feature-Engineering, das die Identifikation

und Aufbereitung relevanter Merkmale umfasst, insbesondere zur Abbildung transienter Prozesse, die das Tragverhalten beeinflussen ist ingenieurtechnische Expertise erforderlich. Ebenso spielt sie bei der Ergebnisinterpretation eine wesentliche Rolle, da erkannte Anomalien hinsichtlich ihrer Ursachen differenziert bewertet werden müssen. Insbesondere im Hinblick darauf, ob es sich um Messfehler oder tatsächliche strukturelle Veränderungen handelt. Die Methode ist demnach nicht darauf ausgelegt, ohne kritische Überprüfung angewendet zu werden, sondern sollte stets im Kontext ingenieurtechnischer Annahmen und Domänenwissen genutzt werden.

Weiterhin kann die Methode unter günstigen Bedingungen bereits nach vier Monaten Messzeitraum angewendet werden. Dennoch zeigt sich, dass ein längerer Zeitraum von sechs bis neun Monaten und idealerweise ein Jahr zu robusteren Ergebnissen führt, da so eine höhere Variabilität in den Trainingsdaten abgedeckt wird.

Außerdem wurde beobachtet, dass Strukturänderungen innerhalb des Trainingszeitraums einen nahezu linearen Einfluss auf die Modellperformance haben. Das bedeutet, dass Modelle, die überwiegend mit Daten aus der Zeit vor einer Strukturänderung trainiert wurden, das ursprüngliche Tragverhalten stärker widerspiegeln, während Modelle mit Daten nach der Änderung das neue Tragverhalten besser erfassen. Dies unterstreicht die Notwendigkeit einer gezielten Auswahl des Trainingszeitraums bei der Anwendung datengetriebener Methoden im Bauwerksmonitoring.

Insgesamt liefert die Arbeit einen Beitrag zur Entwicklung einer praxistauglichen und robusten Methode.

Schlagwörter

Brücke, Monitoring, Temperaturverhalten, Maschinelles Lernen; Vorhersage, Anomaliedekektion

Abstract

The increasing number of ageing bridge structures and the associated necessity to ensure their safety and longevity require automated monitoring systems. Structural anomalies must be detected at an early stage to allow timely interventions and prevent critical damage. Although numerous methods for anomaly detection exist in research, their transfer to practical applications remains limited. These approaches are often tested on laboratory or simulated data, whose applicability to real-world conditions is uncertain.

In this study, a regression-based method is applied to real measurement data, and its practical applicability is examined. The method was deliberately chosen because it utilizes long-term monitoring data, which are commonly collected at bridges where monitoring is conducted and are therefore available without additional measurement effort. This study is based on data from real structures where documented structural changes have been recorded. The method relies on predicting structural responses from temperature measurements using machine learning models. Differences between predicted and measured data are interpreted as anomalies. The Peak-Over-Threshold method is used for robust threshold determination to make reliable statements about the presence of structural changes. The results demonstrate that the method performs reliably under practical conditions and provides robust predictions. Systematic investigations of the necessary training parameters enabled an effective and early application of the method. Additionally, practice-oriented recommendations were developed to further enhance the robustness and transferability of the method. A key aspect is that the method can detect structural anomalies at an early stage while being flexible in its application to different structural types and challenges. It is suitable for both reinforced prestressed concrete and composite structures and can model linear relationships as well as nonlinear behaviors, such as temperature-induced bearing movement. The method does not rely on complex physical assumptions, significantly facilitating its practical applicability.

The conducted investigations show that the Multi-Layer Perceptron (MLP) regressor is the most effective model for predicting structural responses. It is lightweight and quick to train, enabling precise modeling of both linear and nonlinear relationships with high efficiency and robustness against overfitting.

Another major scientific contribution lies in the differentiation between measurement fault detection and structural anomaly detection. While correlated structural responses are used as input data to detect sensor faults or calibration issues, only external loads such as temperature are considered for the detection of structural changes. This ensures that structural changes are not masked by correlations within the input data.

Furthermore, applying the method requires engineering expertise in several key areas. First, careful data selection is necessary to choose appropriate input variables for modeling structural responses and to ensure that relevant influencing factors are properly considered. Feature engineering is also critical, involving the identification and processing of relevant features, particularly for capturing transient processes that affect structural behavior. Additionally, result interpretation plays a crucial role, as detected anomalies must be carefully assessed regarding their causes. Especially in distinguishing between measurement faults and actual structural changes. Thus, the method is not designed to be applied without critical evaluation but should always be used in the context of engineering assumptions and domain knowledge.

Moreover, the method can be applied under favorable conditions after just four months of measurement data. However, findings indicate that a longer period of six to nine months, ideally one year, leads to more robust results, as it ensures greater variability in the training data.

Additionally, it was observed that structural changes occurring within the training period have an almost linear effect on model performance. This means that models trained primarily on data from before a structural change tend to reflect the original structural behavior more strongly, whereas models trained on data after the change better capture the new structural behavior. This highlights the importance of carefully selecting the training period when applying data-driven methods in structural health monitoring.

Overall, this study contributes to the development of a practically applicable and robust method for monitoring structural behavior using machine learning.

Keywords Bridge, Structural Health Monitoring, Temperature Behaviour, Machine Learning, Prediction, Anomaly Detection