

Adaptive Fehlerdiagnose bei gleichzeitigen Sensorfehlern in Bauwerksmonitoringsystemen


Thamer Al-Zuriqat, Carlos Chillón Geck, und Kosmas Dragos

Institut für Digitales und Autonomes Bauen, Technische Universität Hamburg, Blohmstraße 15,
21079 Hamburg, Deutschland

E-Mail: thamer.al-zuriqat@tuhh.de

Abstract: Sensorfehler können zum Verlust wertvoller Daten und zu mangelhaften Zustandsbewertungen und Lebensdauerabschätzungen führen, wobei im schlimmsten Fall strukturelle Schäden unentdeckt bleiben. Infolgedessen finden Fehlerdiagnosekonzepte zunehmend Anwendung in Bauwerksmonitoringsystemen. Die meisten Fehlerdiagnosekonzepte für Bauwerksmonitoringsysteme erfassen jedoch nur das Auftreten eines einzelnen Fehlers, was das gleichzeitige Auftreten mehrerer Fehler, die in realen Bauwerksmonitoringsystemen vorkommen können, nicht berücksichtigt. In diesem Beitrag wird ein adaptiver Ansatz zur Fehlerdiagnose für Bauwerksmonitoringsysteme vorgestellt, der das gleichzeitige Auftreten von Fehlern bei mehreren Sensoren berücksichtigt. Der adaptive Ansatz umfasst Fehlerdetektion, -isolation und -behebung. Der Ansatz baut auf analytischer Redundanz auf, die korrelierte Daten von mehreren Sensoren eines Bauwerksmonitoringsystems verwendet. Insbesondere werden Fehler mithilfe der Prognosen von künstlichen neuronalen Netzen (KNN), die Korrelationen innerhalb der Sensordaten nutzen, diagnostiziert. Der vorgeschlagene Ansatz zur adaptiven Fehlerdiagnose bei gleichzeitigen Sensorfehlern in Bauwerksmonitoringsysteme wurde anhand von Sensordaten einer Eisenbahnbrücke validiert. Die Ergebnisse zeigen, dass der vorgeschlagene Ansatz in der Lage ist, Bauwerksmonitoringsysteme zuverlässig und effizient in Zukunft nutzen zu können.

Keywords: Bauwerksmonitoringsysteme; Sensorfehler; Fehlerdiagnose.



1 Einleitung

Das Monitoring von Ingenieurbauwerken gewinnt zunehmend an Bedeutung [1]. Die Zuverlässigkeit von Bauwerksmonitoringsystemen hängt von einer korrekten Synchronisierung bzw. Funktion der

verwendeten Messgeräte ab [2]. Sensoren in Bauwerksmonitoringsystemen können jedoch Fehler aufweisen, die die Zuverlässigkeit und Leistung von Bauwerksmonitoringsystemen beeinträchtigen. Sensorfehler erstehen u. a. durch Hardware- und Softwarefehlfunktionen, Stromausfälle, Umwelteinflüsse oder Signalstörungen verursacht werden [3]. Zu den häufigsten Sensorfehlern gehören Bias, Complete Failure, Complete Failure with Noise, Gain, Drift, uns Outlier [4]. Basierend auf analytischer Redundanz wurden bisher Ansätze zur Fehlerdiagnose für Monitoringsysteme, einschließlich Bauwerksmonitoringsysteme [5], vorgeschlagen, um Sensorfehler zu erkennen, zu isolieren, zu identifizieren und zu beheben [6]. Analytische Redundanz basiert auf mathematischen Modellen zur Beschreibung eines Systems und nutzt die in den Sensordaten enthaltenen redundanten Informationen, um Fehlerdiagnosedurchzuführen [7]. Aufgrund der komplexen und manchmal nichtlinearen Beziehungen innerhalb der Sensordaten wird für die Fehlerdiagnose zunehmend künstliche Intelligenz angewendet [8, 9]. Beispielsweise wurden künstliche neuronale Netze (KNN) in drahtlose Sensorknoten integriert und an einer Teststruktur im Labor validiert, um Sensorfehler autonom und dezentral zu erkennen und zu isolieren [7], und anschließend den Fehlerdiagnose-Ansatz vom Zeitbereich auf den Frequenzbereich erweitert [10]. Eine Kombination von KNN-Modellen wurde ebenfalls für eine vollständige Fehlerdiagnose eingeführt, wobei KNN-Modelle für die Erkennung, Isolierung und Behebung von Sensorfehlern und faltbare neuronale Netze für die Fehleridentifizierung verwendet wurden [11]. Die oben beschriebenen analytischen Redundanzansätze für Bauwerksmonitoringsysteme beschränken sich jedoch auf die Diagnose von Sensorfehlern, die bei einzelnen Sensoren zu unterschiedlichen Zeitpunkten auftreten, was die Anwendung auf reale Bauwerksmonitoringsysteme, bei denen Sensorfehler bei mehreren Sensoren gleichzeitig auftreten können [12], einschränkt.

Um gleichzeitige Sensorfehler zu diagnostizieren, wird in diesem Beitrag ein adaptiver Ansatz zur Fehlerdiagnose für Bauwerksmonitoringsysteme auf Grundlage analytischer Redundanz (AFDAR) vorgestellt. Der AFDAR-Ansatz baut auf früheren Arbeiten auf, in denen KNN-Modelle und Signalverarbeitung für Fehlerdiagnose in Bauwerksmonitoringsystemen vorgeschlagen wurden [7, 9, 11]. Im Gegensatz zu den bisherigen Ansätzen kombiniert der in dieser Studie vorgeschlagene AFDAR-Ansatz KNN-Modelle mit gleitenden Durchschnitten einzelner Sensordaten, um auftretende Sensorfehler bei mehreren Sensoren zu erkennen, diese zu isolieren und darüber hinaus zu beheben. Im Folgenden wird die Konzeption und Implementierung sowie die Validierung des AFDAR-Ansatzes vorgestellt.

2 Konzeption und Implementierung des AFDAR-Ansatzes

In diesem Abschnitt werden das Design und die Implementierung des AFDAR-Ansatzes vorgestellt, der insgesamt vier Schritte umfasst: (1.) Initialisierung, (2.) Fehlererkennung, (3.) Fehlerisolation und (4.) Fehlerbehebung (Abbildung 1). Im Folgenden werden die vier Schritte des AFDAR-Ansatzes erläutert.

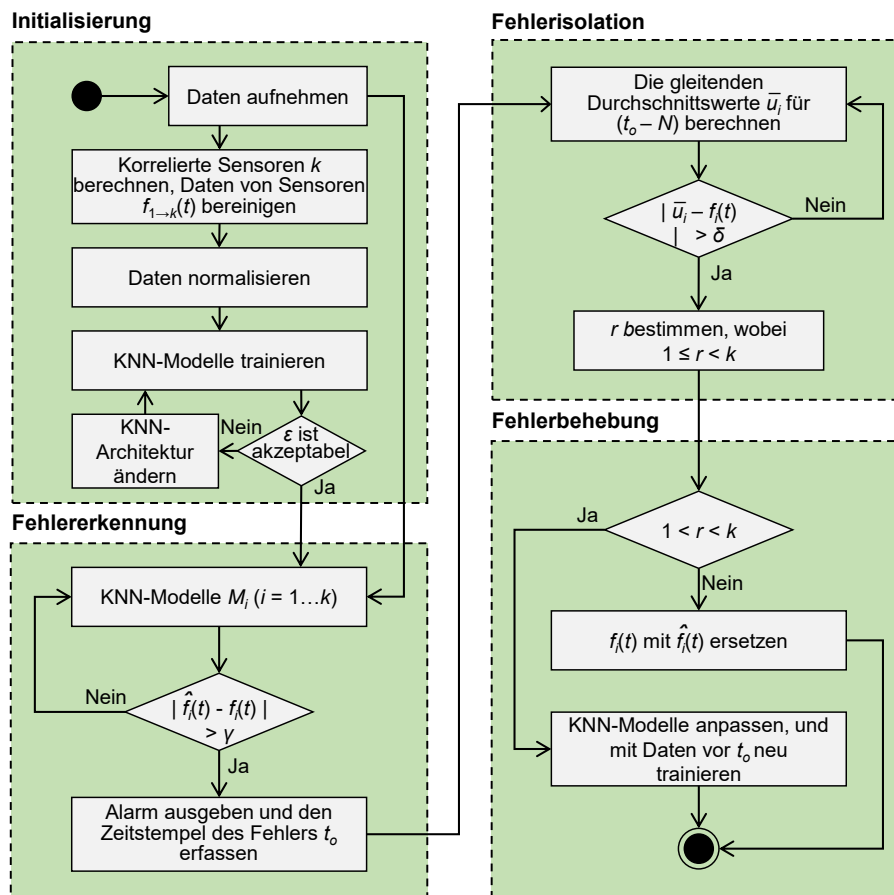


Abbildung 1: Flussdiagramm für den AFDAR-Ansatz.

1. Initialisierung: Die Initialisierung beginnt mit einer Korrelationsanalyse der Sensordaten. Das Ergebnis der Korrelationsanalyse bestimmt die Anzahl der korrelierten Sensoren k . Daraufhin werden die von den korrelierten Sensoren aufgezeichneten Daten $f_{1 \rightarrow k}(t)$ „bereinigt“. Die korrelierten Sensordaten werden einer Minimum-Maximum-Normalisierung unterzogen. Dieselbe Normalisierung ist auf die neu aufgezeichneten Sensordaten anzuwenden, die nach dem Training in die KNN-Modelle eingegeben werden.

Die normalisierten Daten werden daraufhin zum Trainieren von KNN-Modellen verwendet, wobei jedes KNN-Modell aus bestehenden Beziehungen zwischen bekannten Eingabedaten und bekannten Ausgabedaten „lernt“. Als Ergebnis wird ein KNN-Modell M_i für jeden korrelierten Sensor i ($i = 1 \dots k$) entworfen und mit Sensordaten aus dem Bauwerksmonitoringsystem trainiert. Die KNN-Architektur basiert auf der Vorhersagegenauigkeit des Modells M_i , die unter dem Schwellenwert für die Fehlererkennung γ liegt, der durch den Wert des mittleren quadratischen Fehlers (RMSE) ϵ zwischen den virtuellen Ausgaben $\hat{f}_i(t)$ und den Sensordaten $f_i(t)$ bestimmt wird.

2. Fehlererkennung: In diesem Schritt werden die neu aufgezeichneten Sensordaten in alle KNN-Modelle als Input benutzt. Bei Fehlern in r Sensoren ($1 < r < k$) wird erwartet, dass die Residuen zwischen den tatsächlichen Sensordaten und den virtuellen Ausgängen in den Modellen M_n ($n = 2 \dots r$)

den Wert γ überschreiten, wodurch nur für die r Sensoren eine Fehlererkennungsmeldung ausgegeben wird. Die Zeit bis zur Markierung der Verletzung der Fehlererkennungsschwelle γ dient als Zeitstempel für den Fehler. Trotz der Entwicklung und des Trainings von KNN-Modellen, die für jeden korrelierten Sensor bestimmt sind, erfordert die Fehlerisolation eine weitere Analyse der Sensordaten auf der Ebene der einzelnen Sensoren.

3. Fehlerisolation: Nach der Fehlererkennung wird der Zeitstempel des Fehlers verwendet, um ein Zeitfenster N festzulegen. Um das Zeitfenster N herum werden die Werte des gleitenden Durchschnitts \bar{u}_i von p Datenpunkten u_{ij} ($j = 1 \dots p, p < N$) für Sensor i berechnet. Das Zeitfenster sollte eine angemessene Länge N ($t_o - N/2, t_o + N/2$) um den Zeitstempel der Störung haben, um eine zuverlässige Verfolgung des gleitenden Durchschnitts zu gewährleisten. Allmähliche oder abrupte Änderungen der \bar{u}_i Werte sind ein Hinweis auf Sensorfehler. Folglich deuten Abweichungen zwischen den Werten \bar{u}_i und dem Schwellenwert für die Fehlerisolation δ von Zeit zu Zeit auf fehlerhafte Sensordaten von Sensor i hin.

4. Fehlerbehebung: Sobald die fehlerhaften Sensoren erkannt wurden, passen sich die KNN-Modelle wie folgt an die neuen Bedingungen des Bauwerksmonitoringsystems an. Das Anpassen der KNN-Modelle bedeutet im Wesentlichen, dass die Sensordaten der r korrelierten Sensoren, die als fehlerhaft diagnostiziert wurden, aus den KNN-Eingangsschichten aller Modelle entfernt werden. Sodann werden die Architekturen der KNN-Modelle geändert und neu trainiert, um virtuelle Ausgaben für die fehlerhaften Sensoren zu erzeugen. Nach dem Training werden die virtuellen Ausgänge der M_n ($n = 2 \dots r$) Modelle als Ersatz für die fehlerhaften Sensordaten verwendet, so dass die Sensorfehler berücksichtigt werden. Die Schwellenwerte γ und δ hängen von der Art der vom Bauwerksmonitoringsystem aufgezeichneten Daten ab und sind deshalb anwendungsspezifisch.

3 Validierung des AFDAR-Ansatzes

In diesem Abschnitt wird die Validierung des AFDAR-Ansatzes erläutert. Anhand eines realen Bauwerksmonitoringsystems, das an einer Eisenbahnbrücke installiert ist, wird geprüft, inwieweit die Zuverlässigkeit und Leistung von realen Bauwerksmonitoringsystemen gewährleistet werden kann.

3.1 Beschreibung der Brücke und des Monitoringsystems

Die Brücke besteht aus zwei parallelen Stahlfachwerkträgern, die eine 45 cm dicke Stahlbetonplatte tragen. Die Brücke besteht insgesamt aus 15 Feldern mit einer Länge von jeweils 58 m, mit Ausnahme der Randfelder, die 57 m lang sind, und hat eine Gesamtlänge von 868 m. Die Fahrbahnbreite beträgt 14,1 m und der Abstand zwischen den Mittelpunkten der Stahlfachwerkträger 6,2 m. Abbildung 2 zeigt den Querschnitt der Brückenmitte sowie die Position der in die Fahrbahn eingebetteten Temperatursensoren.




Abbildung 2: Brückenquerschnitt und Position der Temperatursensoren.

Es werden Sensordaten von 10 Temperatursensoren verwendet, die in die Stahlbetondecke an den in Abbildung 2 dargestellten Positionen (S1...S10) eingebettet sind. Die für die Validierung verwendeten Temperaturmessungen wurden über einen Zeitraum von fünf Jahren mit einer Abtastrate von 1,7 mHz aufgezeichnet, d. h. alle 10 Minuten wurde eine Temperaturmessung festgehalten, wobei insgesamt 256 000 Messungen von jedem Sensor aufgezeichnet wurden. Eine starke positive Korrelation wird durch den Pearson-Korrelationskoeffizienten zwischen allen 10 Temperatursensoren des Bauwerksmonitoringsystems angezeigt. Es werden insgesamt 10 KNN-Modelle trainiert, die der Anzahl der korrelierten Sensoren ($k = 10$) entsprechen. Jedes Modell sagt die virtuellen Ausgänge eines Sensors voraus, wobei die Temperaturmessungen der anderen neun korrelierten Sensoren im Bauwerksmonitoringsystem als Eingangsdaten verwendet werden. Mit dem Training der 10 KNN-Modelle ist die Initialisierungsphase abgeschlossen und die verbleibenden Schritte des AFDAR-Ansatzes, d. h. Fehlererkennung, Fehlerisolation und Fehlerbehebung, werden separat ausgeführt.

3.2 Ergebnisse und Diskussion

Die Temperaturmessungen, die für den Validierungstest verwendet wurden, entsprechen einem Zeitraum von einem Jahr. Insgesamt wurden 52 560 Temperaturmessungen von allen Sensoren aufgezeichnet. Tabelle 1 zeigt die Anzahl der durch den AFDAR-Ansatz diagnostizierten Fehler in den neu aufgezeichneten Daten. Wie aus der Übersicht hervorgeht, hat der AFDAR-Ansatz 4632 Fehler in den aufgezeichneten Sensordaten diagnostiziert. Um sicherzustellen, dass der vorgeschlagene AFDAR-Ansatz reale Sensorfehler korrekt erkennt, werden die von allen Temperatursensoren aufgezeichneten Daten Seite an Seite visualisiert. Durch die Visualisierung und den Vergleich der Daten lassen sich Abweichungen bei den fehlerhaften Sensordaten feststellen.

Table 1: Reale Sensorfehler des Bauwerksmonitoringsystems, erkannt durch den AFDAR-Ansatz.

Sensor	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	Gesamt
Anzahl von Fehlern	0	18	274	0	1	0	0	4339	0	0	4632

Gleichzeitige Fehler wurden durch den AFDAR-Ansatz in den Sensoren S3 und S8 erkannt, da die aufgezeichneten Temperaturmessungen den Schwellenwert für die Fehlererkennung überschreiten. Abbildung 3 zeigt die von Sensor S3 (oben, rote Linie) und von Sensor S8 (unten, dunkelgrüne Linie) aufgezeichneten Daten. Die hellgrünengrünen Linien zeigen die virtuellen Ausgaben der KNN-Modelle, und die gestrichelten schwarzen Linien stellen die Schwellenwerte für die Fehlererkennung dar. Die Anwendung des AFDAR-Ansatzes hat ergeben, dass zwischen dem 19. und dem 20. Dezember insgesamt 274 gleichzeitige Fehler in den Sensoren S3 und S8 aufgetreten sind.

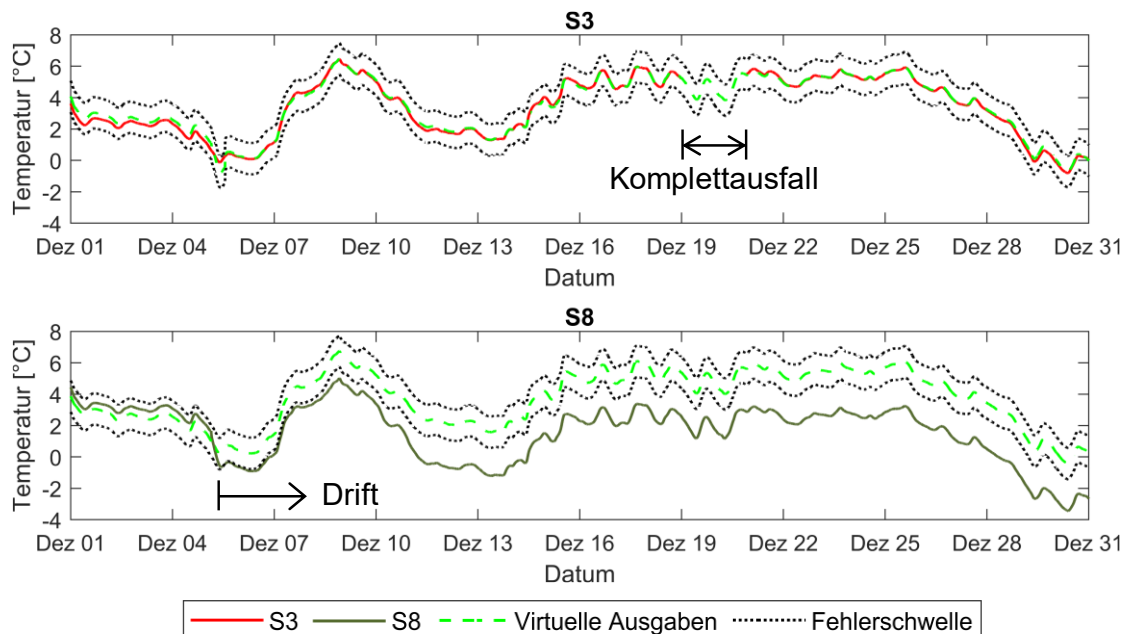


Abbildung 3: Vergleich von Temperaturmessungen und virtuellen Ausgaben mit der Fehlerschwelle.

Um die Ergebnisse der Fehlererkennung, -isolation und -erhebung bei gleichzeitigen Sensorfehlern in der realen Welt auswerten zu können, werden die Sensoren S3 und S8 zwischen dem 19. und 20. Dezember genauer analysiert. Da beide Sensoren fehlerhaft sind, werden die Modelle M_3 und M_8 durch Änderung der Architektur der KNN-Modelle angepasst. Die KNN-Architektur wird geändert, indem die Sensoren S3 und S8 von der Eingabeschicht in die Ausgabeschicht verlagert werden und das angepasste KNN-Modell $M_{3,8}$ trainiert wird. Abbildung 4 zeigt die Architektur des angepassten KNN-Modells $M_{3,8}$, das die virtuellen Ausgaben $\hat{f}_3(t)$ und $\hat{f}_8(t)$ für die beiden Sensoren S3 und S8 vorhersagt.

4 Zusammenfassung und Schlussfolgerungen

Die meisten Fehlerdiagnose-Ansätze konzentrieren sich auf das Auftreten von Einzelfehlern, ohne gleichzeitige Sensorfehler bei mehreren Sensoren zu berücksichtigen. In diesem Beitrag wurde ein adaptiver Fehlerdiagnose-Ansatz auf Grundlage analytischer Redundanz (AFDAR) vorgestellt, mit

dem gleichzeitige Sensorfehler in mehreren Sensoren von Bauwerksmonitoringsystemen zuverlässig diagnostiziert werden können, um die Zuverlässigkeit und Leistungsfähigkeit von realen Bauwerksmonitoringsystemen zu gewährleisten. Der Ansatz kombiniert KNN-Modelle mit gleitenden Durchschnitten einzelner Sensordaten, um gleichzeitige Sensorfehler zu erkennen, zu isolieren und zu beheben. Zur Validierung des vorgeschlagenen Ansatzes wurden die von einem realen Bauwerksmonitoringsysteme gesammelten Daten verwendet. Zusammenfassend kann festgehalten werden, dass der AFDAR-Ansatz vielversprechend ist, um die Genauigkeit von Sensoren und damit die Zuverlässigkeit und Leistung von Bauwerksmonitoringsystemen zu gewährleisten. Zukünftige Arbeiten können sich nun darauf konzentrieren, den AFDAR-Ansatz zu erweitern, um zwischen Sensorfehlern und strukturellen Schäden zu unterscheiden sowie die Berechnungseffizienz zu verbessern, um den Ansatz zu dezentralisieren und ihn in drahtlose Sensorknoten einbetten.

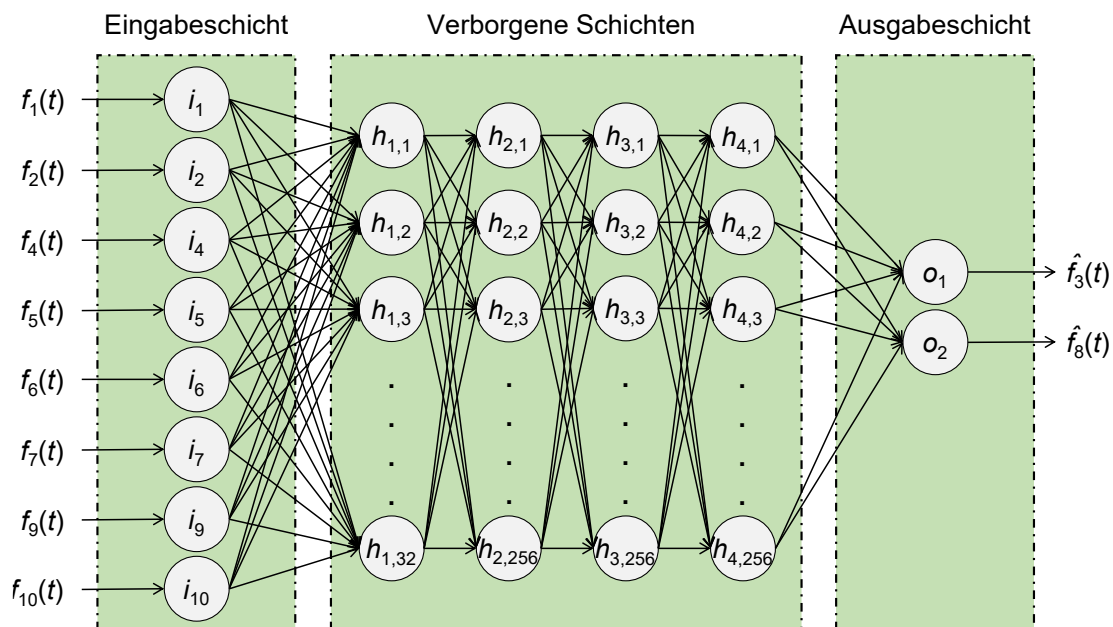


Abbildung 4: Angepasstes Modell $M_{3,8}$ für die Sensoren S3 und S8.

Acknowledgements

Diese Arbeit wurde von der Deutschen Forschungsgemeinschaft (DFG) unter dem Geschäftszeichen SM 281/20-1 und vom Bundesministerium für Digitales und Verkehr (BMDV) im Rahmen des mFUND-Programms (19FS2013B) gefördert. Die Autoren danken der Marx Krontal Partner MKP GmbH für die Unterstützung. Alle Meinungen, Erkenntnisse, Schlussfolgerungen oder Empfehlungen, die in diesem Artikel geäußert werden, sind die der Autoren und spiegeln nicht unbedingt die der DFG, oder des BMDV wider.

Literaturverzeichnis

- [1] K. Smarsly, K. H. Law, and D. Hartmann, "Towards Life-Cycle Management of Wind Turbines based on Structural Health Monitoring," In Proceedings of the First International Conference on Performance-Based Life-Cycle Structural Engineering, Hong Kong, China, 12/05/2012.
- [2] K. Dragos, M. Theiler, F. Magalhães, C. Moutinho, and K. Smarsly, "On-board data synchronization in wireless structural health monitoring systems based on phase locking," *Structural Control and Health Monitoring*, 25(11), e2248, 2018.
- [3] L. Li, G. Liu, L. Zhang, and Q. Li, "Sensor fault detection with generalized likelihood ratio and correlation coefficient for bridge SHM," *Journal of Sound and Vibration*, 442, pp. 445–458, 2019.
- [4] Z. Zhang, A. Mehmood, L. Shu, Z. Huo, Y. Zhang, and M. Mukherjee, "A Survey on Fault Diagnosis in Wireless Sensor Networks," *IEEE Access*, 6, pp. 11349–11364, 2018.
- [5] K. Smarsly and Y. Petryna, "A Decentralized Approach towards Autonomous Fault Detection in Wireless Structural Health Monitoring Systems," In Proceedings of the 7th European Workshop on Structural Health Monitoring, Nantes, France, 07/08/2014.
- [6] R. J. Patton, "Fault detection and diagnosis in aerospace systems using analytical redundancy," In Proceedings of the IEE Colloquium on Condition Monitoring and Fault Tolerance, London, UK, 11/06/1990.
- [7] K. Smarsly and K. H. Law, "Decentralized fault detection and isolation in wireless structural health monitoring systems using analytical redundancy," *Advances in Engineering Software*, 73, pp. 1–10, 2014.
- [8] A. Zaher, S. D. J. McArthur, D. G. Infield, and Y. Patel, "Online wind turbine fault detection through automated SCADA data analysis," *Wind Energy*, 12(6), pp. 574–593, 2009.
- [9] T. Al-Zurikat, C. Chillón Geck, K. Dragos, and K. Smarsly, "Adaptive fault diagnosis for simultaneous sensor faults in structural health monitoring systems," *Infrastructures*, 8(3), 39, 2023.
- [10] K. Dragos, and K. Smarsly, "Distributed adaptive diagnosis of sensor faults using structural response data," *Smart Materials and Structures*, 25(10), 105019, 2016.
- [11] H. Fritz, J. J. Peralta Abadía, D. Legatiuk, M. Steiner, K. Dragos, and K. Smarsly, "Fault diagnosis in structural health monitoring systems using signal processing and machine learning techniques," in *Structural health monitoring based on data science techniques*, A. Cury, D. Ribeiro, F. Ubertini, and M. D. Todd, Eds., Cham: Springer International Publishing, pp. 143-164, 2022.
- [12] K. Dragos and K. Smarsly, K., "Decentralized infrastructure health monitoring using embedded computing in wireless sensor networks," in *Dynamic Response of Infrastructure to Environmentally Induced Loads*, A. Sextos and G. D. Manolis, G. D., Eds., Cham: Springer International Publishing, pp. 183-201, 2017.