

Intelligente Bauwerke

Verfahren zur Auswertung, Verifizierung und Aufbereitung von Messdaten

Berichte der
Bundesanstalt für Straßenwesen

Brücken- und Ingenieurbau Heft B 164

The logo consists of the word "bast" in a bold, lowercase, green sans-serif font. The letters are slightly shadowed, giving it a 3D appearance. The logo is positioned in the bottom right corner of the page.

Intelligente Bauwerke

Verfahren zur Auswertung, Verifizierung und Aufbereitung von Messdaten

von

Markus Kleinert
Felix Sawo

Knowtion GmbH
Karlsruhe

**Berichte der
Bundesanstalt für Straßenwesen**

Brücken- und Ingenieurbau Heft B 164

bast

Die Bundesanstalt für Straßenwesen veröffentlicht ihre Arbeits- und Forschungsergebnisse in der Schriftenreihe **Berichte der Bundesanstalt für Straßenwesen**. Die Reihe besteht aus folgenden Unterreihen:

- A - Allgemeines
- B - Brücken- und Ingenieurbau
- F - Fahrzeugtechnik
- M - Mensch und Sicherheit
- S - Straßenbau
- V - Verkehrstechnik

Es wird darauf hingewiesen, dass die unter dem Namen der Verfasser veröffentlichten Berichte nicht in jedem Fall die Ansicht des Herausgebers wiedergeben.

Nachdruck und photomechanische Wiedergabe, auch auszugsweise, nur mit Genehmigung der Bundesanstalt für Straßenwesen, Stabsstelle Presse und Kommunikation.

Die Hefte der Schriftenreihe **Berichte der Bundesanstalt für Straßenwesen** können direkt bei der Carl Ed. Schünemann KG, Zweite Schlachtpforte 7, D-28195 Bremen, Telefon: (04 21) 3 69 03 - 53, bezogen werden.

Über die Forschungsergebnisse und ihre Veröffentlichungen wird in der Regel in Kurzform im Informationsdienst **Forschung kompakt** berichtet. Dieser Dienst wird kostenlos angeboten; Interessenten wenden sich bitte an die Bundesanstalt für Straßenwesen, Stabsstelle Presse und Kommunikation.

Die **Berichte der Bundesanstalt für Straßenwesen (BASt)** stehen zum Teil als kostenfreier Download im elektronischen BASt-Archiv ELBA zur Verfügung.
<https://bast.opus.hbz-nrw.de>

Impressum

Bericht zum Forschungsprojekt 15.0636
Intelligente Bauwerke - Verfahren zur Auswertung,
Verifizierung und Aufbereitung von Messdaten

Fachbetreuung
Sarah Windmann

Referat
Betonbau

Herausgeber
Bundesanstalt für Straßenwesen
Brüderstraße 53, D-51427 Bergisch Gladbach
Telefon: (0 22 04) 43 - 0

Redaktion
Stabsstelle Presse und Kommunikation

Druck und Verlag
Fachverlag NW in der
Carl Ed. Schünemann KG
Zweite Schlachtpforte 7, D-28195 Bremen
Telefon: (04 21) 3 69 03 - 53
Telefax: (04 21) 3 69 03 - 48
www.schuenemann-verlag.de

ISSN 0943-9293
ISBN 978-395606-576-7

Bergisch Gladbach, Mai 2021

Kurzfassung – Abstract

Intelligente Bauwerke: Verfahren zur Auswertung, Verifizierung und Aufbereitung von Messdaten

Das Forschungsvorhaben FE 15.0636/2016/GRB schließt an das Forschungsvorhaben FE 15.0548/2011/GRB an und hatte die Weiterentwicklung und Erprobung der im Rahmen dieses Projektes erarbeiteten modellbasierten und statistischen Analyseverfahren, bei denen auch moderne Methoden aus der künstlichen Intelligenzforschung eingesetzt werden, zum Ziel. Der Fokus lag dabei vor allem auf Verfahren zur Sensordatenplausibilisierung und Erkennung von Anomalien sowie auf Verfahren zur Extraktion relevanter Informationen aus umfangreichem Datenmaterial. Für die Sensordatenplausibilisierung wurde ein besonders robustes Filterverfahren eingesetzt, das tolerant gegenüber Ausreißern in den Messwerten ist. Für dieses Verfahren wurde gezeigt, dass die benötigten Modellparameter bei einfachen Signalverläufen einzelner physikalischer Größen anhand von repräsentativen Beispieldatensätzen gelernt werden können. Für komplexere Signale mehrerer zusammenhängender physikalischer Größen wurde gezeigt, wie eine Lösung durch explizite Modellierung erreicht werden kann. Außerdem wurde ein Verfahren zur Untersuchung von Zusammenhängen in Sensormessdaten entwickelt. Die Evaluation der Verfahren geschah anhand von Daten, die an dem Brückenbauwerk BW 402e, welches zu Forschungszwecken mit teils redundanten Sensornetzen ausgestattet wurde, erhoben wurden. Schließlich wurden Softwarearchitekturen erarbeitet, die die Realisierung von Brückenmonitoringsystemen im großen Maßstab ermöglichen sollen.

Smart bridges: Techniques for assessment, verification and preparation of measurement data

The research project FE 15.0636/2016/GRB follows the previous project FE 15.0548/2011/GRB with the aim to further develop and test model-based and statistical data analysis methods for bridge monitoring based on modern methods of artificial intelligence research. The focus was mainly on techniques for sensor data validation and anomaly detection as well as the extraction of relevant information from large datasets. For the validation of sensor data a robust filtering algorithm was used, which is tolerant to outliers in the measured signal. For this algorithm it was shown that the necessary model parameters can be learned from representative datasets for simple signals of single physical parameters. For more complex signals of multiple related parameters the relationship between external influences on a bridge structure and the structure's reactions was developed. The techniques were evaluated based on data recorded at the bridge BW 402e, which was equipped with partially redundant sensor networks for research purposes. Finally, software architectures were developed, which allow the realization of large-scale bridge monitoring systems.

Inhalt

1	Einleitung	7	4.3.2	Plausibilisierung von Temperaturdaten mit dem ORKF	23
1.1	Zielstellung	7	4.4	Plausibilisierung zusammenhängender physikalischer Größen	26
1.2	Anwendungsszenarien	7	4.4.1	Plausibilisierung von Temperatur und Luftfeuchte	26
1.2.1	Überwachung von Einzelkomponenten	7	4.4.2	Explizite physikalische Modellierung: Temperaturlausgleichsmodell	28
1.2.2	Überwachung des Gesamtbauwerkes	7	4.4.3	Modell für Wärmeaustausch zwischen Außenbereich, Hohlkastenwand und Hohlkasteninnern	28
1.3	Lösungsansätze	7	4.4.4	Modell für Wärmeaustausch zwischen Außenbereich und Hohlkastenwand	30
1.3.1	Anomalieerkennung	7	4.5	Zusammenfassung	32
1.3.2	Klassifikation	8			
1.4	Überblick	8			
2	Literaturübersicht	9			
3	Erste Untersuchung der Sensordaten	12	5	Gesamtkonzept für die algorithmisch gestützte Sensordatenanalyse für Brückenbauwerke	33
3.1	Datenimport	12	5.1	Einleitung	33
3.2	Abgeleitete Mindestanforderungen	13	5.2	Beschreibung des algorithmischen Ablaufs	33
3.2.1	Anforderungen an die Abtastrate	13	5.2.1	Datenerfassung	34
3.2.2	Anforderungen an die Synchronisation der Sensordaten	13	5.2.2	Vorverarbeitung	34
3.2.3	Anforderungen an die Datenqualität	14	5.2.3	Einbettung	37
4	Plausibilisierung Messsystem und Sensordatenfusion	14	5.2.4	Gruppierung	38
4.1	Einleitung	14	5.2.5	Attribuierung	39
4.2	Beschreibung der eingesetzten Verfahren	15	5.2.6	Kombinierte Auswertung mehrerer Sensorsignale	40
4.2.1	Verfahren zur Filterung und Glättung von Daten	15	5.3	Detaillierte Beschreibung der einzelnen Algorithmen	42
4.2.2	Bestimmung von Modellparametern mit dem Expectation-Maximization-Algorithmus	18	5.3.1	Zuordnung von zu unterschiedlichen Zeitpunkten extrahierten Signalenfenstern zu einzelnen Fahrzeugüberfahrten	42
4.2.3	Verfahren zur Detektion von Anomalien	19	5.3.2	Skalenraumanalyse zur Bestimmung der Fenstergrößen	44
4.3	Plausibilisierung einzelner physikalischer Größen	20	5.3.3	Fahrspurdetektionen	48
4.3.1	Plausibilisierung von Temperaturdaten anhand von Smoothing Splines	20	5.3.4	Einbettung	49
			5.3.5	Gruppierung	51

5.4	Interpretation der Streudiagramme . . .	53
5.4.1	Auswertung einzelner Sensoren	53
5.4.2	Kombinierte Auswertung mehrerer Sensoren	54
5.5	Anwendungsfälle	54
5.5.1	Untersuchung von Temperatur- einflüssen	54
5.5.2	Untersuchung der Einflüsse von Fahrzeugüberfahrten	55
5.5.3	Untersuchung des Zusammenhangs zwischen Messdaten von Sensoren am Lager und von in Querrichtung zur Fahrbahn messenden Sensoren . . .	57
6	Softwarearchitekturen für die Brückenüberwachung	59
6.1	Komponenten	59
6.2	Anpassung der Architektur an verschiedene Anforderungen	59
6.2.1	Toleranz gegenüber Netzwerkausfall . . .	59
6.2.2	Anpassung an beschränkte Netz- werkbandbreite und Speicherplatz	60
6.2.3	Echtzeit- und Stapelverarbeitung	60
6.2.4	Skalierbarkeit	61
6.3	Übersicht vorhandener Technologien . . .	62
7	Zusammenfassung und Ausblick . . .	63
	Literatur	63
	Bilder	66
	Tabelle	70

1 Einleitung

1.1 Zielstellung

Hauptziel dieses Projektes ist die Untersuchung aktueller Verfahren aus den Bereichen der Sensordatenfusion und des maschinellen Lernens hinsichtlich ihrer Einsatzmöglichkeiten an intelligenten Bauwerken. Der Begriff „intelligentes Bauwerk“ bezeichnet hierbei Bauwerke, die mit Sensoren ausgestattet sind, die es ermöglichen, über die gesamte Lebenszeit des Bauwerkes hinweg Daten aufzuzeichnen, die Aufschluss über den augenblicklichen Zustand des Bauwerks geben.

Zu diesem Zweck wird in diesem Forschungsprojekt an das Forschungsvorhaben „Intelligente Bauwerke – Anforderungen an die Aufbereitung von Messgrößen und ihrer Darstellungsform“, siehe [1], angeknüpft. Dort wurden bereits erste Verfahren im Hinblick auf ihre Eignung für die Plausibilisierung und Aufbereitung von Messreihen einzelner Sensoren entwickelt und untersucht. Allerdings konnten damals noch keine Erfahrungen mit Sensordaten einer gesamtheitlich instrumentierten Brücke gesammelt werden. Daher ist es ein Ziel dieses Vorhabens, die entwickelten Konzepte anhand von der BAST bereitgestellten realen Sensordaten eines ausgewählten Bauwerks zu evaluieren. Weiterhin lag der Fokus in dem Vorgängerprojekt auf der Verarbeitung von Messreihen einzelner Sensoren. Im Gegensatz hierzu soll in diesem Projekt auch untersucht werden, inwiefern Messreihen mehrerer Sensoren für die Ableitung höherwertiger Informationen herangezogen werden können.

1.2 Anwendungsszenarien

An dem Bauwerk BW 402e, das die Fahrbahn der BAB 3 mit zwei Fahrstreifen über die Verbindung der BAB 9 von Regensburg nach München führt, wurden im Zuge einer vollständigen Erneuerung im Jahr 2016 verschiedene Sensornetzwerke installiert. Anhand der Messdaten sollen einerseits Informationen über den Zustand kritischer Einzelkomponenten des Bauwerkes, nämlich des Fahrbahnüberganges und der Lager, andererseits aber auch Aussagen über den Gesamtzustand des Bauwerkes und die Umweltbedingungen abgeleitet werden. Die zu diesem Zweck installierten Sensornetzwerke motivieren die im Folgenden aufgeführten Anwendungsfälle für die Ableitung höherwertiger Informationen aus den gegebenen Messreihen.

1.2.1 Überwachung von Einzelkomponenten

Für die Beurteilung der Zuverlässigkeit und Restlebensdauer eines Bauwerkes ist es hilfreich, kritische Einzelkomponenten zu überwachen, um mögliche Ausfälle rechtzeitig vorhersagen zu können. Im Falle der betrachteten Autobahnüberführung sind kritische Komponenten beispielsweise die Lager des Überbaus sowie der Fahrbahnübergang. Diese Komponenten werden regelmäßig dynamisch belastet und verschleifen daher besonders schnell. Deshalb wurden diese Komponenten seitens des Herstellers mit Kraft-, Druck-, Weg-, und Beschleunigungssensoren ausgestattet, anhand deren Messungen Aussagen bezüglich des Zustands dieser Komponenten abgeleitet werden können sollen.

Die Konzentration auf Einzelkomponenten erfolgt auch in der Erwartung, dadurch nützliche Aussagen über Verhaltensänderungen des Bauwerkes treffen zu können, ohne dazu das gesamte Bauwerk modellieren zu müssen. Diese Reduktion der Komplexität soll zu einfacheren Modellen und Algorithmen führen ohne Einbußen hinsichtlich der Aussagekraft der Modelle hinsichtlich der betrachteten Qualitätsparameter in Kauf zu nehmen.

1.2.2 Überwachung des Gesamtbauwerkes

Zur Untersuchung einiger Eigenschaften des gesamten Bauwerkes ist es nicht ausreichend, nur auf die Sensordaten der instrumentierten Einzelkomponenten zurückzugreifen. Vielmehr sind hierfür Daten verschiedenartiger, über das gesamte Bauwerk verteilter Sensoren notwendig. Daher werden in diesem Projekt synchron erfasste Messdaten von Dehnungs-, Verschiebungs-, und Beschleunigungssensoren eines Systems, das speziell für die Erfassung von Verhaltensänderungen des gesamten Bauwerkes und von Verkehrslasten konzipiert wurde (RTMS – Road Traffic Management System), ausgewertet.

1.3 Lösungsansätze

1.3.1 Anomalieerkennung

Allgemein wird unter einer Anomalie eine Abweichung von einem üblicherweise beobachteten Verhalten verstanden. Bei diesem Projekt entstehen solche Unregelmäßigkeiten beispielsweise aufgrund von Sensordefekten, Bauwerksveränderun-

gen oder Einwirkungen auf das Bauwerk von außen. Für die Anomalieerkennung sollten in diesem Projekt hauptsächlich modellfreie Algorithmen oder Algorithmen mit einfachen Modellen eingesetzt werden. Modellfrei bedeutet hierbei, dass Modelle nicht vom Nutzer vorgegeben werden, sondern von den Algorithmen zur Laufzeit erstellt werden. Dies ist zu unterscheiden von Verfahren, die sich auf detaillierte vorgegebene Modelle des Bauwerkes, wie beispielsweise Finite-Elemente-Modelle (FE-Modelle) stützen.

Besteht die Aufgabenstellung darin, mögliche Fehlerzustände zu erkennen, ist eine bewährte Vorgehensweise die Erstellung eines „Normal-Modells“, vgl. [2]. Ein solches Normal-Modell beschreibt das Verhalten eines Systems im fehlerfreien Zustand und wird anhand von an dem System im fehlerfreien Zustand aufgezeichneten Sensordaten automatisch erstellt. Hierfür dienen die Sensordaten des betrachteten Systems als Eingabe für ein maschinelles Lernverfahren, das relevante Merkmale aus den Daten extrahiert und mit dem vorliegenden Verhalten im fehlerfreien Fall korreliert. Später aufgezeichnete Sensordaten werden dann mit diesem Normal-Modell verglichen und Abweichungen werden als Anomalie ausgegeben.

Das hier allgemein beschriebene Vorgehen lässt sich prinzipiell sowohl auf Einzelkomponenten, wie die instrumentierten Lager oder den Fahrbahnübergang, als auch auf das gesamte Brückenbauwerk anwenden. Allerdings ist davon auszugehen, dass sich die Verfahren je nach Anwendungsfall unterscheiden werden. Beispielsweise könnten für die Untersuchung des Verhaltens des gesamten Bauwerks eher Verfahren geeignet sein, die das Schwingungsverhalten des Bauwerkes analysieren, während für die Untersuchung von Einzelkomponenten eher lokale, gradientenbasierte Merkmale herangezogen werden könnten.

Für die Bewertung der Verfahren zur Anomalieerkennung eignen sich bestimmte Extremereignisse, für die der Zeitpunkt des Auftretens bekannt ist. Extreme Wettersituationen sind ein Beispiel für solche Extremereignisse. Das Auftreten von Extremwetter-situation lässt sich unter Umständen aus den Messdaten der zu dem Bauwerk gehörenden Wetterstation ablesen.

1.3.2 Klassifikation

Die Klassifikation unterscheidet sich von der im vorherigen Absatz beschriebenen Anomalieerkennung dadurch, dass die aufgenommenen Sensordaten einer von mehreren Klassen zugeordnet werden sollen. Zunächst kann die Anomalieerkennung als Spezialfall der Klassifikation mit genau zwei Klassen, einer Normalklasse und einer Fehlerklasse, aufgefasst werden. Bei der praktischen Anwendung sind die Fehlerfälle jedoch oftmals nicht im Voraus bekannt, sodass hier hauptsächlich Daten für den Normalfall zur Verfügung stehen, mit denen das Normal-Modell erstellt wird. Im Gegensatz hierzu benötigen Klassifikationsverfahren typischerweise eine große Menge Beispieldaten für jede Klasse.

1.4 Überblick

Zunächst gibt Kapitel 2 einen Überblick über frühere wissenschaftliche Arbeiten, bei denen Methoden des maschinellen Lernens zur Überwachung von Bauwerken eingesetzt wurden. Dabei liegt der Fokus hauptsächlich auf Verfahren zur Tragwerksüberwachung.

Kapitel 3 fasst die Ergebnisse einer zu Beginn des Projektes durchgeführten ersten Analyse der Sensordaten zusammen und leitet Mindestanforderungen an deren Qualität ab.

In Kapitel 4 werden verschiedene Verfahren zur Anomalieerkennung für die Plausibilisierung von Sensordaten vorgestellt und ihre Anwendung auf aufgezeichnete Wetterdaten demonstriert.

Kapitel 5 stellt das in diesem Projekt entwickelte Konzept zur algorithmisch gestützten Sensordatenanalyse für Brückenbauwerke vor. Das Verfahren soll Experten bei der Erkennung von Zusammenhängen in umfangreichen an einem Brückenbauwerk aufgezeichneten Daten unterstützen. Dazu wird eine Kombination von Gruppierungsalgorithmen und Klassifikationsverfahren eingesetzt, um Sequenzen von in mehreren Kanälen beobachteten Signalmustern zu kodieren.

Schließlich stellt Kapitel 6 Softwarearchitekturen vor, mit denen ein großflächiger Einsatz von Verfahren zur Bauwerksüberwachung im gesamten Fernstraßennetz realisiert werden könnte.

2 Literaturübersicht

Dieser Literaturüberblick stellt einige grundlegende Arbeiten zur automatisierten Überwachung von Tragwerkskonstruktionen (Englisch: „Structural Health Monitoring“ (SHM)) vor und soll einen Eindruck vom gegenwärtigen Stand der Forschung vermitteln. Da die Beurteilung und Vorhersage der Eigenschaften von Tragwerken auch im Maschinenbau, hier insbesondere im Flugzeug- und Schiffbau, eine große Rolle spielt, stammen einige der hier aufgeführten frühen, grundlegenden Arbeiten aus diesen Anwendungsgebieten.

In einer grundlegenden Arbeit untersuchten WORDEN et al. die notwendigen Voraussetzungen für die automatisierte Überwachung der Stabilität von Tragwerkskonstruktionen [2]. Auf der Basis ihrer eigenen Erfahrung und der zum Zeitpunkt der Studie existierenden Literatur leiteten die Autoren einige Grundprinzipien solcher Systeme ab.

Die Autoren vertreten den Standpunkt, dass eine über die bloße Erkennung und Lokalisierung von Schäden hinausgehende Schadensanalyse, die beispielsweise eine Bewertung der Schadensstärke oder eine Kategorisierung umfasst, in der Regel nur durch den Einsatz überwachter Lernverfahren zu erreichen ist. Dabei werden dem Überwachungssystem initial Messdaten von Schadensfällen und die damit verbundene Bewertung bzw. Kategorisierung präsentiert, anhand derer das System den Zusammenhang zwischen Messdaten und Schadensfällen lernen soll. Weil der gesuchte Zusammenhang zwischen Sensormessungen und möglichen Schadenszuständen üblicherweise nicht aus der Theorie abgeleitet werden kann, gibt es hierzu oft keine Alternativen. Der praktische Einsatz von maschinellen Lernverfahren wird durch die notwendige zeit- und kostenintensive Datenerhebung erschwert.

Allgemein weisen die Autoren darauf hin, dass für den Einsatz von Überwachungssystemen immer eine Vergleichsgrundlage vorhanden sein muss. Im einfachsten Fall sind dies lediglich Messdaten, die im störungsfreien Betrieb erhoben wurden. Damit kann, den Autoren zufolge, immerhin noch eine Schadenserkennung und eventuell auch -lokalisierung durch unüberwachte Lernverfahren, die anhand von im störungsfreien Betrieb aufgezeichneten Daten trainiert wurden, erfolgen. Unter Umständen können auch die Ergebnisse einer theoretischen

Modellierung als Vergleichsgrundlage dienen.

Weiterhin wird von den Autoren auf die Bedeutung sorgfältig ausgewählter Merkmale hingewiesen. Aussagekräftige Merkmale reduzieren die Anzahl der benötigten Trainingsbeispiele, die typischerweise exponentiell mit der Dimension ansteigt. Zudem sollten die Merkmale möglichst frei von Umgebungseinflüssen wie Wind oder Temperatur sein, die keine Auswirkung auf die Schadensanalyse haben sollten.

In einer weiteren Arbeit wendeten WORDEN et al. diese Prinzipien auf die Überwachung von Flugzeugtragflächen an [3]. Dabei wurden aufeinander aufbauend die Detektion von Schäden, deren Lokalisierung sowie die Beurteilung ihres Ausmaßes behandelt. Hierfür wurden die untersuchten Tragflächen zu mechanischen Schwingungen angeregt und Transmissionsspektren von an den Tragflächen angebrachten Beschleunigungssensoren aufgezeichnet. Da die Autoren die zu untersuchenden Tragflächen nicht beschädigen durften, haben sie stattdessen Teile der Tragflächen, die zu Inspektionszwecken demontiert werden können, durch eigene Teile ersetzt, in die gezielt Fehler eingebracht werden können. Dies ermöglichte eine spätere Evaluierung der Algorithmen sowie eine über die Schadenserkennung und -lokalisierung hinausgehende Datenauswertung. In einem ersten Schritt wurden die Abschnitte der Transmissionsspektren, die für die Schadensvorhersage geeignet sind, identifiziert. Diese dienten später als Merkmal für die Schadenserkennung. Diese Beschränkung auf aussagekräftige Abschnitte der Transmissionsspektren war den Autoren zufolge notwendig, weil die Befestigung der untersuchten Tragflächenabdeckungen ebenfalls einen großen Einfluss auf die aufgezeichneten Spektren hatte, und sonst mehr Trainingsdaten nötig gewesen wären, um den Einfluss der Beschädigungen von dem Einfluss der Befestigung auf die Spektren zu trennen. Die Detektion von Fehlern wurde von den Autoren nur an einzelnen Teilen der Abdeckung demonstriert. Hierfür verwendeten sie eine Ausreißererkennung anhand der Mahalanobis-Distanz, die auf einer einfachen, zuvor für den fehlerfreien Fall erstellten Statistik der extrahierten Merkmale beruht. Für die Lokalisierung von Fehlern wurde ein Sensornetzwerk eingesetzt, mit dem Ausreißerindikatoren berechnet werden können. Diese dienen als Eingabe für ein neuronales Netzwerk, das daraus die Nummer des entfernten Tragflä-

chenteils vorhersagen soll. Dieses Netzwerk wurde zuvor anhand von Daten aus dem Experiment trainiert, sodass es sich daher insgesamt um ein überwachtes Verfahren handelt.

SOHN et al. geben einen aktualisierten Literaturüberblick für die Jahre 1996 – 2001 auf der Basis eines früheren Rückblicks von 1995 [4]. Auch in dieser Arbeit wurde das Problem der Tragwerksüberwachung hauptsächlich als Mustererkennungsproblem angesehen, das mit statistischen Methoden zu lösen ist. Bezüglich der Methodik werden die Verfahren nach Art der verwendeten Merkmale und der statistischen Modellierung der Merkmalsklassifikation unterschieden. Bei den Merkmalen dominieren solche, die aus dem Schwingungsverhalten des betrachteten Bauwerkes abgeleitet werden können, während bei der statistischen Modellierung für den Fall, dass lediglich Betriebsdaten vorhanden sind, eine einfache Ausreißerererkennung eingesetzt wird und komplexere Verfahren, wie neuronale Netze oder genetische Algorithmen verwendet werden, wenn auch Daten zu Schadensfällen vorliegen. Als kritische Punkte wurden die Anfälligkeit der gemessenen Frequenzparameter von Umgebungseinflüssen und der Mangel an Erfahrungen mit realen Tragwerken genannt. Dies stimmt mit den Aussagen von WORDEN et al. überein [5].

Eine Alternative zu der Auswertung von Spektren wurde von ZANG et al. vorgestellt [6]. Dabei werden die aufgezeichneten Zeitreihen mehrerer Sensoren einer Unabhängigkeitsanalyse (Englisch: Independent Component Analysis, ICA) unterzogen. Die hierbei in einer initial durchzuführenden Lernphase bestimmte Mischmatrix enthält Merkmale der Zeitreihen, die verwendet werden, um ein neuronales Netz zur Schadensvorhersage zu trainieren.

Die in jüngster Zeit veröffentlichten Arbeiten basieren auf den gleichen Prinzipien wie die zuvor vorgestellten grundlegenden Arbeiten und erweitern diese vor allem hinsichtlich der für die Merkmalsextraktion und statistischen Modellierung eingesetzten Algorithmen.

Viele Verfahren zur Überwachung von Bauwerken stützen sich auf eine Analyse der Eigenfrequenzen und zugehörigen Eigenformen des gesamten untersuchten Tragwerks. Mit Methoden, die unter dem Sammelbegriff „Operational Mode Analysis“ (OMA) zusammengefasst werden, können diese Analysen für bestehende Bauwerke im Betrieb durchgeführt

werden, wobei keine kontrollierte externe Anregung des Bauwerkes erfolgen muss, siehe [7].

Ausgehend von der Beobachtung, dass mögliche Umgebungseinflüsse vor Anwendung einer Ausreißererelimination mit der Mahalanobisdistanz kompensiert werden müssen, erweiterten CROSS et al. frühere Arbeiten von WORDEN [5] durch Verfahren zur Kompensation der Umgebungseinflüsse [8]. Zu diesem Zweck führten sie das aus der Ökonometrie stammende Verfahren der Kointegration von Zeitreihen ein und verglichen die damit erzielten Ergebnisse mit denen einer Kompensation durch Projektion auf die kleinsten Hauptkomponenten. Die Kointegration lässt sich auf Messreihen nicht-stationärer Prozesse mit stationärer erster Ableitung anwenden. Das Verfahren identifiziert die Koeffizienten einer stationären Linearkombination der nicht-stationären Größen. Diese Linearkombination beschreibt in den Messwerten gemeinsam vorkommende Trends, die wahrscheinlich von Umgebungseinflüssen herrühren. Dies ermöglicht die Kompensation der Umgebungseinflüsse. Den Autoren zufolge können sowohl mit Kointegration als auch mit PCA Merkmale generiert werden, die unabhängig von Umgebungseinflüssen sind, aber dennoch mit den Schadensfällen korreliert sind. Die Autoren favorisieren das Verfahren der Kointegration, da die Orthogonalitätsforderung an die Eigenvektoren bei der PCA ihrer Meinung nach die Möglichkeit einschränkt, optimale Lösungen für den zu eliminierenden Unterraum zu finden.

In einer vergleichenden Studie zur Schadenserkennung an stabförmigen oder ebenen Strukturen untersuchten FAN et al. verschiedene Verfahren hinsichtlich ihrer Fähigkeiten zur Erkennung einfacher, mehrfacher sowie großflächiger Schäden und ihrer Robustheit gegenüber Rauschen und der Platzierung der Sensoren [9]. Als Vergleichsgrundlage dient ein Finite-Elemente-Modell (FE-Modell). Eine Besonderheit dieser Arbeit ist, dass Verfahren, die auf einer Auswertung der Eigenfrequenzen, der Eigenformen sowie der Spannungsenergie beruhen, miteinander verglichen werden. Bei dem Vergleich schneiden die mit Mode Shape Curvature (MSC) und Damage Index Method (DIM) benannten Verfahren, die die Krümmung der Eigenformen beziehungsweise die Spannungsenergie analysieren, am besten ab, während Verfahren, die die Frequenzeigenschaften analysieren, als ungeeignet für die Schadenserkennung an komplexen Tragwerken angesehen werden.

COMANDUCCI et al. vergleichen sechs verschiedene Verfahren zur Schadenserkennung an Brückenbauwerken [10]. Die Schadenserkennung basiert dabei in jedem Fall auf einer Ausreißererkenntnis mit der Mahalanobisdistanz. Zunächst werden die Eigenfrequenzen und Eigenformen der Brückenschwingungen in einer Trainingsphase aufgezeichnet. Mit diesen Daten werden verschiedene Modelle trainiert, die den Einfluss der Umgebungsbedingungen auf die Moden beschreiben sollen. Die dabei aufgetretenen Residuen dienen als Referenz für die spätere Auswertung. In der Anwendungsphase werden die gelernten Modelle eingesetzt, um die Umgebungsbedingungen zu kompensieren, und die dabei festgestellten Residuen werden mit den Residuen aus der Trainingsphase mit den Methoden der Ausreißererkenntnis verglichen. Das Verfahren wird mit Daten, die an einem realen Brückenbauwerk aufgezeichnet wurden, evaluiert. Dazu wird mit einem FE-Modell ein Schadensfall simuliert und die dadurch hervorgerufenen Abweichungen auf die tatsächlichen Messwerte aufgeschlagen. Bei dem Vergleich schneidet eine Kombination von PCA und linearer Ausgleichung am besten ab, wenn die aufgeschlagenen Fehlerterme linear sind. Wenn nicht-lineare Fehler simuliert werden, schneidet ein lokales PCA Verfahren, bei dem mehrere Hauptkomponentenanalysen auf einer Zerlegung des Merkmalsraums durchgeführt werden, am besten ab. Die Methode der Kointegration schneidet bei der Schadenserkennung eher schlecht ab, benötigt dafür aber die kürzeste Trainingsphase.

TAMURA et al. verwenden die Daten von Beschleunigungssensoren, die an Fahrbahnübergängen einer mehrspurigen Straßenbrücke befestigt sind, um Defekte an Fahrbahnübergängen zu detektieren [11]. Hierzu wurden ein unüberwachtes und ein überwachtes Lernverfahren mit der Methode der Support-Vektor-Maschinen realisiert. Als Merkmale werden sowohl Zeitreihen fester Länge als auch deren Spektren verwendet. Um eine gewisse Unabhängigkeit von Umgebungseinflüssen zu erreichen, womit in diesem Fall vor allem die Abhängigkeit der Messdaten von den Typen und Geschwindigkeiten der überfahrenden Fahrzeuge gemeint ist, werden nur Merkmale aus Zeitabschnitten verwendet, bei denen die Höhe der in dem Signal detektierten Maxima einer bestimmten Reihenfolge folgt. Die Auswertung ergibt, dass das unüberwachte Verfahren durch diese Merkmalsauswahl deutlich verbessert werden kann. Insgesamt schneidet das überwachte

Verfahren trotzdem noch besser ab. Die Ergebnisse hängen kaum davon ab, ob Zeitreihen oder Spektren als Merkmalsvektoren verwendet werden.

Die oben vorgestellten Verfahren haben gemein, dass sie auf einem Vergleich der an einer Struktur im Normalbetrieb erhobenen Daten mit aktuellen Messdaten beruhen. Abweichungen werden dann als Schadensereignis interpretiert. Eine andere Herangehensweise ist, einen Vergleich mit einem Modell durchzuführen. Hierfür wird oft die sogenannte Finite Element Model Updating-Methode eingesetzt. Grundsätzlich werden bei diesem Verfahren an der Struktur erhobene Messdaten regelmäßig mit Vorhersagen aus einem Finite-Elemente-Modell (FEM) verglichen. Dann werden die Parameter des FEM mit nicht-linearen Optimierungsverfahren so angepasst, dass die Abweichung zwischen Vorhersage und Messdaten minimal ist. Sind hierbei große Parameteranpassungen notwendig, so deutet dies auf Fehler an der Struktur hin, die mit dem Modell auch lokalisiert werden können. Ein Nachteil dieser Verfahren ist die für die nicht-lineare Optimierung benötigte Rechenzeit.

MORDINI et al. stellen eine Scilab-Implementierung eines solchen FEM-Updating Algorithmus vor, der auf offene FEM-Programmbibliotheken zugreift [12]. Damit wird ein Modell für die Schadenserkennung an Trägern und Spannseilen realisiert, das Eigenfrequenzen und Eigenformen als Eingabeparameter benötigt. Die Eigenfrequenzen sollen die Erkennung von Schäden erlauben, während die Eigenformen Aussagen über die Ausdehnung von Schäden möglich machen sollen. Bei einer Erprobung an realen Schwingungsdaten, die an Stahlseilen einer Hängebrücke erhoben wurden, konnten so durch Korrosion beschädigte Kabel erkannt werden.

Neben den zuvor diskutierten Verfahren zur Überwachung der Stabilität des gesamten Tragwerks gibt es auch Verfahren zur Erfassung der individuellen auf eine Brücke einwirkenden Achslasten, siehe [13] sowie [14] für einen Überblick. Diese Verfahren sollen eine zeitnahe Überwachung des Lastverkehrs sowie der auf einzelne Bauwerke wirkenden Spitzenlasten ermöglichen. Prinzipiell basieren diese Verfahren auf einem in [15] entwickelten Verfahren, bei dem eine mit Dehnungssensoren ausgestattete Brücke gewissermaßen als Waage verwendet wird. Unter Zuhilfenahme von Zusatzinformationen, insbesondere Achszahl und Fahrzeugge-

schwindigkeit, können dann unter der Annahme, dass die Durchbiegung der Brücke proportional zu dem Produkt aus der Fahrzeuglast und der aus der Statik bekannten Einflusslinie ist, die individuellen Achslasten bestimmt werden. Aufgrund dieses Vorgehens werden diese Verfahren im Englischen unter dem Begriff „Bridge Weight in Motion (B-WIM)“ zusammengefasst.

LUBASCH stellt in seiner Dissertation ein solches System zur Identifikation statischer Verkehrslasten auf der Basis gemessener Querschnittsdehnungen vor [16]. Dabei wird eine Kombination von evolutionären Optimierungsverfahren und künstlichen Neuronalen Netzen eingesetzt. Ein Vorteil dieses Verfahrens ist, dass die unbekannt Parameter Fahrzeuggewicht, -geschwindigkeit und Achsabstände bei der Optimierung ebenfalls bestimmt werden und daher nicht separat erfasst werden müssen.

3 Erste Untersuchung der Sensordaten

3.1 Datenimport

Die bereitgestellten Sensordaten konnten in die Entwicklungsumgebung MATLAB importiert werden. Für das Einlesen des binären 32-bit Diadem Formates und der von dem Road Traffic Management System (RTMS) aufgenommenen CSV-Dateien wurden zu diesem Zweck eigene Funktionen implementiert und frei verfügbare Skripte angepasst. Die an den instrumentierten Lagern aufgenommenen und im CATMAN-Dateiformat gespeicherten Daten konnten mithilfe des mitgelieferten Skriptes eingelesen werden. Bild 1, Bild 2 sowie Bild 3 zeigen beispielhaft importierte Sensordaten von jedem der drei Messsysteme. In Bild 1 und Bild 2 wurde der Ausschnitt so gewählt, dass ein zeitlich abgegrenztes Signal, das sich klar vom Sensorrauschen unterscheidet, vollständig enthalten ist. Dieser Signalverlauf ist auf die Überfahrt eines Fahrzeugs zurückzuführen. Bild 3 zeigt den Temperaturverlauf, der von einem drahtlosen Sensor des iBAST-Systems innerhalb von sieben Tagen aufgezeichnet wurde.

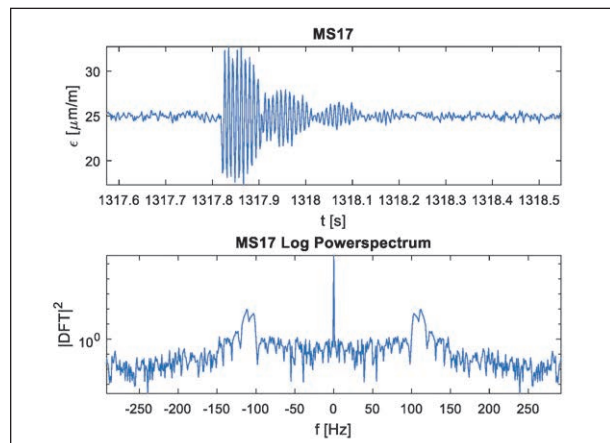


Bild 1: Messreihenausschnitt und halblogarithmische Darstellung des zugehörigen Leistungsspektrums für den Dehnmessstreifen ‚MS17‘ des RTM-Systems




Bild 2: Messreihenausschnitt und halblogarithmische Darstellung des zugehörigen Leistungsspektrums für den Beschleunigungssensor ‚B4‘, der zu dem instrumentierten Fahrbahnübergang gehört




Bild 3: Messreihenausschnitt für den Temperatursensor ‚1CBF4‘ des iBAST-Systems

3.2 Abgeleitete Mindestanforderungen

3.2.1 Anforderungen an die Abtastrate

Bild 1 und Bild 2 zeigen neben den Sensordaten auch das zugehörige Leistungsspektrum in halb-logarithmischer Darstellung. Dieses beschreibt die Verteilung der Signalenergie auf die einzelnen Frequenzanteile. Beide Spektren weisen ein Maximum bei der Frequenz von 0 Hz auf. Dies entspricht der konstanten Verschiebung der Signale von der Nulllinie (Gleichanteil).

Davon abgesehen gibt es deutliche Unterschiede in den Spektren. Das in Bild 1 gezeigte Spektrum des Dehnungssensors weist zwei eng benachbarte, stark abgegrenzte Maxima in der Nähe von 110 Hz auf. Der Signalverlauf ähnelt daher auch einer Schwebung, deren Amplitude exponentiell abklingt. Dies lässt vermuten, dass hier zwei Eigenfrequenzen angeregt wurden, die kritisch gedämpft sind. Im Gegensatz hierzu weist das Spektrum des Beschleunigungssensors in Bild 2 ein breiteres Maximum bei ca. 150 Hz auf und fällt dann langsam ab. Hier ist in dem Signal ebenfalls ein Schwebungsmuster erkennbar, das aber stärker von weiteren Effekten überlagert wird.

Die Spektren geben Aufschluss darüber, ob die Abtastrate bei der Aufzeichnung ausreichend hoch gewählt wurde, um das Abtasttheorem einzuhalten. Hierzu wurden entsprechende Spektren für alle Sensoren des RTMS und der instrumentierten Lager sowie des Fahrbahnübergangs für jeweils zwei Zeitfenster ausgegeben und begutachtet. Dabei wurden keine Hinweise auf eine Verletzung des Abtasttheorems (Aliasing) gefunden.

Für den hier gezeigten Dehnungssensor des RTMS scheint die relevante Signalinformation im Frequenzbereich bis 300 Hz enthalten zu sein, sodass die Abtastrate von 600 Hz ausreichend ist. Die von den Beschleunigungs- und Kraftsensoren an dem Fahrbahnübergang aufgezeichneten Daten weisen generell ein etwas breiteres Spektrum bis ca. 1.000 Hz auf. Die gewählte Abtastrate von 2.500 Hz scheint hier ebenfalls ausreichend zu sein.

Ebenso wurde auch in den übrigen betrachteten Sensordaten kein Hinweis auf Aliasing gefunden, sodass die gewählten Abtastraten insgesamt als ausreichend angesehen werden können. Allerdings muss hierbei eingeschränkt werden, dass nur ein kleiner zeitlicher Ausschnitt der Daten untersucht

wurde. Ob eine weitere Reduktion der Abtastraten möglich ist, muss unter Berücksichtigung der Aufgabenstellung und der dafür eingesetzten Verfahren im Einzelfall untersucht werden.

3.2.2 Anforderungen an die Synchronisation der Sensordaten

Dieses Kapitel behandelt die Frage, wie gut die Sensordaten synchronisiert werden müssen, um in der Einleitung dargelegten Anwendungsszenarien nutzbar zu sein. Generell sind die Anforderungen an die Synchronisation der Sensordaten eng verknüpft mit den Anforderungen an die Abtastrate, die im vorigen Kapitel diskutiert wurden. Beide hängen letztendlich davon ab, wie dynamisch das System bzw. der zu untersuchende Teilaspekt des Systems ist. Für die Rekonstruktion verteilter Systeme sollte zudem auch bei der Synchronisation das Abtasttheorem eingehalten werden, d. h. die Synchronisation sollte mindestens so genau sein, dass die Abtastzeitpunkte bis zur durch das Abtasttheorem vorgegebenen Grenzfrequenz einander eindeutig zugeordnet werden können, wie in Bild 4 gezeigt. Aus dieser Überlegung folgt die folgende Abschätzung für die maximal tolerierbare Abweichung δt_{\max} der korrespondierenden Abtastzeitpunkte der zu synchronisierenden Signale:

$$\delta t_{\max} = \frac{1}{2 \max(f_1, f_2)} \quad (1)$$

In Formel (1) sind f_1 und f_2 die gewählten Abtastfrequenzen der beiden zu synchronisierenden Signale und δt_{\max} ist der maximal tolerierbare Synchronisierungsfehler.




Bild 4: Synchronisation zweier Signale. Die schwarzen und blauen Pfeilspitzen markieren die Abtastzeitpunkte zweier Signale. Die korrespondierenden Messungen dürfen nicht weiter als ein halbes Abtastintervall voneinander abweichen, damit eine eindeutige Zuordnung erfolgen kann.

3.2.3 Anforderungen an die Datenqualität

Die Qualität von Sensormessungen wird durch verschiedene, sich überlagernde stochastische Prozesse beeinflusst. Die für die Untersuchung von Zeitgebern entwickelte Allen-Varianz-Analyse bietet eine Möglichkeit, verschiedene Störeinflüsse anhand von aus langen Zeitreihen bestimmten Kurven grafisch zu ermitteln. Für die Charakterisierung von Beschleunigungssensoren wird dies in [17] beschrieben.

Dabei wird davon ausgegangen, dass die Sensormessungen die folgende Form haben:

$$\tilde{s}_t = s_t + b_t + n_t \quad (2)$$

Hier ist \tilde{s}_t der verfälschte, aufgezeichnete Messwert, s_t der unbekannte, wahre Wert und b_t , n_t sind Störterme. Der Störterm n_t beinhaltet zeitlich unkorreliertes, normalverteiltes Rauschen mit Standardabweichung σ_t , während b_t einen sich langsam mit der Zeit verändernden Nullpunktfehler (Bias) beschreibt.

Erste Schätzungen für b_t und σ_t können durch die Berechnung von Mittelwert und Varianz einer ausreichend langen Messreihe bei konstantem und bekanntem Eingangssignal s_t (meist das Nullsignal) erhalten werden. Dabei wird die langsame Veränderung des Bias allerdings vernachlässigt. Um diese Biasdrift ebenfalls charakterisieren zu können, werden lange Zeitreihen, bei denen der Sensor in Ruhe ist, benötigt. Solche Messreihen können normalerweise nur unter Laborbedingungen aufgenommen werden.

Für die Verwendung der Messdaten in Algorithmen zur Sensordatenfusion und Anomalieerkennung ist vor allem wichtig, dass sich die Charakteristik der Störterme nicht unvorhergesehen mit der Zeit ändert. Beispielsweise ist es möglich, zeitlich veränderliches Rauschen zu modellieren. Wenn dies jedoch unterlassen wird, wird wahrscheinlich eine Anomalie erkannt, sobald sich beispielsweise die Varianz des Rauschens zu stark von ihrem Wert während der Trainingsphase unterscheidet. Problematisch sind in diesem Zusammenhang vor allem langsame Veränderungen, wie z. B. die Biasdrift, weil diese in Trainingsdaten, die sich über vergleichsweise kurze Zeitabschnitte erstrecken, keine Rolle spielen und außerhalb des Labors nicht von tatsächlichen langsamen Veränderungen, z. B. aufgrund von Veränderungen der Statik von Gebäuden, unterscheiden lassen. Wenn die Biasdrift nicht

schon vor Installation der Sensoren im Labor charakterisiert wurde, kann sie daher nur durch anbringen zusätzlicher, redundanter Sensoren erkannt werden. Für eine quantitative Kompensation werden in jedem Fall redundante Messungen benötigt.

Ein weiteres wichtiges Merkmal für die Qualität von Sensordaten ist das Signal-Rauschverhältnis (Engl.: Signal-to-noise ratio (SNR)). Hierbei wird ebenfalls davon ausgegangen, dass das zu untersuchende Signal aus einer additiven Überlagerung des eigentlichen Nutzsignals mit einem störenden weißen Rauschsignal besteht. Nullpunktfehler werden allerdings vernachlässigt.

Dann kann ein sogenannter Optimalfilter (Engl.: matched filter) definiert werden, für den das Signal-Rausch-Verhältnis maximal ist [18]. Das Signal-Rausch-Verhältnis ρ nimmt dann den folgenden Wert an:

$$\rho = \sqrt{\frac{E_f}{\sigma_0^2}} \quad (3)$$

Hier ist E_f die Energie des zu detektierenden Signals, die durch Integration über dessen Fourier-Spektrum bestimmt wird, und σ_0^2 die spektrale Leistungsdichte des weißen Rauschens. Damit ist ein Kriterium für die Detektion von Ereignissen in den aufgezeichneten Sensordaten gegeben.

4 Plausibilisierung Messsystem und Sensordatenfusion

4.1 Einleitung

Ziel der Plausibilisierung ist es, Sensormessungen daraufhin zu überprüfen, ob ihre Werte nachvollziehbar sind. Es geht also darum, grobe Fehler oder unmögliche Messwerte zu identifizieren. Ziel der Sensordatenfusion ist hingegen die Verbesserung der Genauigkeit durch optimale Kombination der Informationen aus unterschiedlichen Datenquellen. Die Kombination unterschiedlicher Datenquellen bei der Sensordatenfusion erlaubt zudem die Ableitung neuer Größen, die mit den Messungen einzelner Sensoren nicht bestimmbar wären. Diese beiden Problemstellungen sind eng miteinander verknüpft: Algorithmen zur Sensordatenfusion berechnen oftmals auch Genauigkeitsmaße, die als Güte-

kriterium bei der Plausibilisierung verwendet werden können. Ein Beispiel hierfür sind die Kovarianzmatrizen, die die Genauigkeit der Schätzung eines Kalman-Filters beschreiben. Weiterhin ist die Möglichkeit, verschiedene Messgrößen mit Sensordatenfusion zusammenzuführen, für die Plausibilisierung zusammenhängender physikalischer Größen von Bedeutung ist.

Die Ansätze zur Sensordatenfusion und Plausibilisierung unterscheiden sich auch darin, inwiefern sie ein genaues physikalisch-mathematisches Modell der untersuchten Vorgänge voraussetzen. Ansätze, für die kein solches Modell erstellt werden muss, werden im Folgenden als modellfrei bezeichnet. Diese bieten sich besonders für die Plausibilisierung einzelner physikalischer Größen an, da hier die Zusammenhänge zwischen verschiedenen physikalischen Größen keine Rolle spielen und daher auch nicht modelliert werden müssen. Trotzdem liegen modellfreien Methoden in diesem Sinne in der Regel bestimmte Annahmen zu Grunde, beispielsweise, dass sich ein Messwert nur langsam verändert, oder dass ein Messwert innerhalb bestimmter Grenzen liegen muss. Diese Annahmen folgen oft aus einem groben physikalischen Verständnis der Vorgänge, benötigen aber keine genaue mathematische Modellbildung. Beispielsweise folgt die Annahme, dass sich ein Messwert nur langsam verändert, aus Vorwissen über die Dynamik eines Systems.

Im Gegensatz hierzu bieten modellbasierte Methoden die Möglichkeit, das Hintergrundwissen über die physikalischen Abläufe in dem untersuchten System zur Verbesserung der Schätz- und Plausibilisierungsergebnisse einzusetzen. Allerdings besteht hier auch in größerem Maße die Gefahr der systematischen Verzerrung der Ergebnisse, wenn das Modell die physikalischen Gegebenheiten nicht gut beschreibt. Dies kann beispielsweise auftreten, wenn sich die Umgebungsbedingungen mit der Zeit verändern.

In Kapitel 4.2 werden Verfahren zur Plausibilisierung vorgestellt. Die unterschiedliche Funktionsweise dieser Verfahren und ihre jeweiligen Stärken und Schwächen werden in Kapitel 4.3 und Kapitel 4.4 am Beispiel der Plausibilisierung von Temperaturmessungen dargestellt. Hierfür wurden Temperaturdaten gewählt, weil für die Modellierung des Wärmetransports in Gebäuden bereits Modelle existieren, anhand derer die Vorgehensweise gut erläutert werden kann.

4.2 Beschreibung der eingesetzten Verfahren

4.2.1 Verfahren zur Filterung und Glättung von Daten

4.2.1.1 Smoothing Splines

Smoothing Splines [22], [23] sind ein Beispiel für eine Methode zur modellfreien Plausibilisierung, die sich auf Annahmen zur Dynamik eines Systems stützt. Ein Smoothing Spline ist eine stückweise polynomiale Funktion, die bestimmte Stetigkeitseigenschaften hat¹, und folgenden Fehlerterm minimiert:

$$\varepsilon = (1 - \alpha) \int_{t_0}^{t_1} \left(\frac{d^2 s}{dt^2} \right)^2 dt + \alpha \sum_k (y_k - s(t_k))^2 \quad (4)$$

In obiger Formel bezeichnet $s(t)$ den Smoothing Spline, der die Messwerte y_k zu den Zeitpunkten t_k approximiert. Der erste Term bestraft Abweichungen von einem geraden Funktionsverlauf, während die Summe im zweiten Term Abweichungen zwischen dem Smoothing Spline und den Messwerten bestraft. Über den Parameter α werden diese beiden Strafterme gegeneinander gewichtet. Die oben angesprochene Annahme über die Dynamik des Systems findet hier also über die Wahl eines geeigneten α Eingang in die Plausibilitätsprüfung.

4.2.1.2 Kalman-Filter

An dieser Stelle wird zunächst die Funktionsweise des herkömmlichen Kalman-Filters beschrieben, vgl. [24]. Dieser spielt eine wichtige Rolle bei Verfahren zur Sensordatenfusion und bei der Plausibilisierung von Sensormessungen. Zudem ist ein Verständnis des Kalman-Filters auch für das Verständnis des Outlier Robust Kalman-Filters in Kapitel 4.2.1.3 hilfreich.

Bild 5 zeigt eine grafische Darstellung der Annahmen über den modellierten Prozess, die dem Kalman-Filter zugrunde liegen. Dabei handelt es sich um ein sogenanntes Bayes-Netz [25]. Die kreisförmigen Knoten in einem solchen Netz repräsentieren Zufallsvariablen und Pfeile repräsentieren stochastische Abhängigkeiten. Bei den Zufallsvariablen kann es sich auch um mehrdimensionale Zufallsvektoren handeln. Die eckigen Kästchen ste-

¹ Meist wird C^2 -Stetigkeit garantiert.




Bild 5: Bayes-Netz zu dem generativen Modell, das die dem Kalman-Filter zugrundeliegenden Annahmen über den beobachteten Prozess beschreibt.

hen für Steuergrößen, die als Eingabe für den Prozess dienen. Diese werden in der Regel nicht als Zufallsvariablen aufgefasst.

In Bild 5 stehen die mit x_t bezeichneten Zufallsvariablen für den aktuellen Systemzustand zum Zeitpunkt t . Dieser könnte beispielsweise aus Temperatur und Luftfeuchte sowie deren zeitlichen Ableitungen bestehen, um die Dynamik auf einfache Weise zu modellieren. Sensormessungen oder Beobachtungen werden in Bild 5 durch kreisförmige Knoten mit dicken hellblauen Rändern dargestellt und mit z_t bezeichnet.

Bei dieser Modellierung werden die Messungen bzw. Beobachtungen strikt von dem eigentlichen Zustand, der die Beobachtungen erzeugt und oft das eigentliche Ziel einer Schätzung ist, unterscheiden. Der Zustand kann nicht direkt beobachtet werden, es handelt sich um eine latente Variable, deren Schätzwert teilweise erst nach mehreren Zeitschritten aus den Beobachtungen bestimmt werden kann. Dabei hilft neben dem Messmodell auch das zeitliche Modell, das die Dynamik des untersuchten Prozesses beschreibt.

Aus einem Bayes-Netz kann die Wahrscheinlichkeitsdichte über die beteiligten Zufallsvariablen direkt abgelesen werden. Jeder Wurzelknoten ohne eingehenden Pfeil trägt einen Faktor $p(x)$ zu der gemeinsamen Dichtefunktion bei, der die Randverteilung über die in dem Knoten enthaltene Zufallsvariable x enthält. Für jeden Knoten mit eingehendem Pfeil wird ein Faktor $p(x|Eltern(x))$ zu der Wahrscheinlichkeitsdichtefunktion hinzugefügt, der die bedingte Wahrscheinlichkeitsdichte für x

enthält, wenn die Werte der Zufallsvariablen aus den Elternknoten festgehalten werden.

Des Weiteren können die stochastischen Unabhängigkeitsbeziehungen zwischen Zufallsvariablen unter Zuhilfenahme einiger einfacher Regeln mithilfe eines Bayes-Netzes bestimmt werden. Für das Netz aus Bild 5 folgt daraus, dass jeder Zustand x_t nur von seinem Vorgängerzustand x_{t-1} abhängt. Diese Markov-Annahme ist somit auch eine der Voraussetzungen für das Kalman-Filter.

Weiterhin wird bei dem Kalman-Filter von normalverteilten Zufallsvariablen und linearen Abhängigkeiten für das System- und Messmodell ausgegangen. Das Netz in Bild 5 repräsentiert daher eine Wahrscheinlichkeitsdichte mit folgenden Faktoren:

$$p(x_t|x_{t-1}) \sim N(Ax_{t-1} + Bu_t, Q) \quad (5)$$

$$p(z_t|x_t) \sim N(Hx_t, R) \quad (6)$$

In obigen Gleichungen steht $N(x,P)$ für die Normalverteilung mit Mittelwert x und Kovarianzmatrix P und \sim bedeutet „verteilt wie“.

Die Matrizen A , B und H , die das Zustandsübergangs- und Messmodell beschreiben, können sich mit der Zeit ändern, die durch sie beschriebenen Zusammenhänge müssen jedoch näherungsweise linear sein. Eine häufig verwendete Variante des Kalman-Filters ist das sogenannte Extended Kalman-Filter, bei dem die Matrizen für Zustandsübergangs- und Messmodell durch die Jakobimatrizen beliebiger analytischer Zustandsübergangs- und Messgleichungen ersetzt werden. Dabei handelt es sich jedoch um eine Approximation, die mit zunehmender nicht-Linearität schnell zu unbrauchbaren Schätzergebnissen führt.

Treffen die hier beschriebenen Voraussetzungen zu, dann bietet das Kalman-Filter eine effiziente Methode zur Berechnung des bestmöglichen Schätzwertes \hat{x}_t aus den Beobachtungen $z_1, z_2, z_3, \dots, z_t$ bis zum Zeitpunkt t . Hierfür wird der geschätzte Zustand und dessen Kovarianz zunächst gemäß dem Zustandsübergangsmodell aus Gleichung (5) in der Zeit fortgeschrieben:

$$x_t^- = Ax_{t-1}^+ + Bu_t \quad (7)$$

$$P_t^- = AP_{t-1}^+A^T + Q \quad (8)$$

Hierbei kennzeichnen die hochgestellten Zeichen $+$, $-$ die Schätzungen für den Zustand x_t und des-

sen Kovarianz P_t vor bzw. nach der Verarbeitung einer Messung. Die Prädiktion wird dann verwendet, um das Residuum s_t und dessen Kovarianzmatrix S zu bestimmen:

$$s_t = z_t - Hx_t \quad (9)$$

$$S_t = R + HP_t^-H^T \quad (10)$$

Damit kann schließlich der neue Filterzustand unter Berücksichtigung der Messung berechnet werden:

$$K = PH^TS^{-1} \quad (11)$$

$$x_t^+ = x_t^- + Ks_t \quad (12)$$

$$P_t^+ = P_t^- - KSK^T \quad (13)$$

Den optimalen Schätzwert für x_t erhält man nun durch abwechselnde Ausführung der Gleichungen (7)-(8) für die Prädiktion und (9)-(13) für die Aktualisierung mit neuen Messungen.

Die Residuen und ihre Kovarianz aus den Gleichungen (9) und (10) sind für die Erkennung von Ausreißern in den Messwerten von großer Bedeutung und können somit auch für die Plausibilisierung verwendet werden.

4.2.1.3 Outlier Robust Kalman-Filter

Das Outlier Robust Kalman-Filter (ORKF) ist eine Variante des Kalman-Filters, die besonders robust gegenüber Ausreißern in den Messdaten ist [26]. Bei dem herkömmlichen Kalman-Filter wird angenommen, dass das Messrauschen normalverteilt ist und dass sich die Parameter dieser Verteilung nicht ändern. Im Gegensatz hierzu wird bei dem ORKF von einer Student-t Verteilung der Messfehler ausgegangen. Diese Verteilung misst groben Ausreißern mehr Wahrscheinlichkeit bei und soll so eine separate Behandlung von Ausreißern überflüssig machen. Hierfür wird bei jeder Filteraktualisierung eine Fixpunktiteration durchgeführt, um eine an das aktuelle Residuum angepasste Kovarianzmatrix für das Messrauschen zu bestimmen, mit der dann eine Filteraktualisierung ganz analog zu dem herkömmlichen Kalman-Filter durchgeführt werden kann.

Bild 6 zeigt das Bayes-Netz, das der Modellierung des ORKF zugrunde liegt. Das Netz ähnelt dem entsprechenden Bayes-Netz für das Kalman-Filter aus Bild 5 stark. Der wesentliche Unterschied besteht darin, dass die Knoten für die Beobachtungen




Bild 6: Bayes-Netz zu dem generativen Modell, das die dem Outlier Robust Kalman-Filter zugrundeliegenden Annahmen über den beobachteten Prozess beschreibt.

z_t von weiteren Knoten R_t abhängen. Diese enthalten die Parameter der Verteilung des Messrauschens.

Hierbei wird für das Messrauschen selbst eine mittelwertfreie Normalverteilung mit Kovarianzmatrix M_t angenommen. Diese Kovarianzmatrix wird allerdings ebenfalls als Zufallsvariable aufgefasst, deren Inverse Wishart-verteilt ist:

$$M_t^{-1} \sim W\left(\frac{R_t^{-1}}{p}, p\right) \quad (14)$$

Hierbei steht $W(X, f)$ für eine Wishart-Verteilung mit Präzisionsmatrix X und f Freiheitsgraden. Der Parameter p bestimmt, wie stark die Verteilung der Kovarianzmatrizen um ihren Mittelwert schwankt.

Falls der latente Zustand x_t bekannt ist, sind die Beobachtungen z_t Student-t-verteilt. Die a-posteriori Wahrscheinlichkeit $\rho(x_t|z_t, z_{t-1}, \dots, z_1)$ ist bei exakter Rechnung nach diesem Modell nicht mehr normalverteilt, wodurch eine effiziente rekursive Berechnung erschwert wird. Daher verwenden die Autoren in [26] eine möglichst optimale Approximation der wahren a-posteriori Verteilung durch eine Normalverteilung. Die Optimalität wird hierbei durch Minimierung der Kullback-Leibler Distanz zwischen der analytisch korrekten a-posteriori Dichte und ihrer Approximation erreicht. Bei der Kullback-Leibler Distanz handelt es sich dabei um eine Metrik auf dem Raum der Wahrscheinlichkeitsdichten.

Für die Berechnung der approximierten a-posteriori Verteilung wird der Erwartungswert $\Gamma_t = E[M_t]$ der Kovarianzmatrix des Messrauschens benötigt. In

[26] wird durch analytische Rechnung gezeigt, dass dieser durch folgende Formel gegeben ist:

$$\Gamma_t = \frac{pR + ss^T + H\Sigma_t H^T}{p + 1} \quad (15)$$

In obiger Gleichung ist s das Residuum vor Verarbeitung der Messung und Σ ist die Kovarianzmatrix der approximierten Verteilung. Da durch die Approximation für alle Zufallsvariablen wieder eine Normalverteilung angenommen werden kann, erfolgt die rekursive Zustandsschätzung im Wesentlichen wie bei dem üblichen Kalman-Filter, vergleiche Gleichungen (11)-(13):

$$K = P^-H^T(HP^-H^T + \Gamma)^{-1} \quad (16)$$

$$x^+ = x^- + K(z - Hx^-) \quad (17)$$

$$\Sigma = P^-(I - KH) \quad (18)$$

Im Unterschied zu den Gleichungen für die Aktualisierung des Standard-Kalman-Filters wird in Gleichung (16) der anhand des aktuellen Residuums mit Gleichung (15) berechnete Schätzwert Γ für das Messrauschen verwendet. In der tatsächlichen Implementierung werden die Schritte (15) bis (18) in einer Fixpunktiteration durchgeführt bei der die Schätzung für Γ_t ausgehend von dem Startwert $\Gamma^0 = R$ ständig verbessert wird. Die Iteration wird beendet, sobald eine Schätzung für die Wahrscheinlichkeit des Residuums einen Schwellwert überschreitet.

4.2.2 Bestimmung von Modellparametern mit dem Expectation-Maximization-Algorithmus

4.2.2.1 Allgemeinfeld des Expectation-Maximization-Algorithmus

Ein großer Vorteil der in Kapitel 4.2.1.1 vorgestellten Smoothing Splines ist, dass diese kein physikalisches Modell für das zu glättende Signal benötigen. Ein alternativer Ansatz hierzu besteht darin, ein Verfahren wie das Kalman-Filter zu verwenden, das ein solches Modell voraussetzt, die Parameter dieses Modells aber anhand eines Beispieldatensatzes automatisch zu bestimmen.

Der Expectation-Maximization-Algorithmus (EM-Algorithmus) [27] bietet eine Möglichkeit, diese unbekannten Parameter zu bestimmen. Ziel des Verfahrens ist die Optimierung einer Likelihood-Funktion $L(z, x, \theta) = p(z|x, \theta)$, die von Beobachtungen z , la-

zenten Zustandsvariablen x und Modellparametern θ abhängt, wenn nur die Beobachtungen gegeben sind. Auch wenn letztendlich nur die Modellparameter benötigt werden, müssen bei der Optimierung im Allgemeinen dennoch auch Schätzwerte für die latenten Zustandsvariablen bestimmt werden. Wenn Werte x^{opt} , θ^{opt} für Zustandsvariablen und Modellparameter gefunden wurden, für die die Likelihood-Funktion ein Maximum annimmt, können die Modellparameter später beispielsweise für die Implementierung eines Schätzverfahrens für die Zustände x' bei Vorliegen einer neuen Sequenz von Beobachtungen z' verwendet werden, während die geschätzten latenten Zustände verworfen werden.

Die Optimierung der Likelihood-Funktion ist oftmals schwierig, weil das zu Null setzen der Ableitungen nach Zustandsvariablen und Modellparametern zu einem Gleichungssystem für die beiden unterschiedlichen Parametertypen führt, das sich üblicherweise nicht auflösen lässt. Stattdessen werden bei dem EM-Verfahren abwechselnd neue Schätzwerte für die Zustandsvariablen und für die Modellparameter bestimmt. Hierfür werden die folgenden beiden Schritte abwechselnd ausgeführt:

- Berechnung der erwarteten Log-Likelihood $Q = E[\log(P(z|x, \theta))]_{\theta=\theta_k}$ für konstantes θ_k (Expectation-Schritt).
- Bestimmung eines neuen Schätzwertes für θ durch Maximieren der Log-Likelihood: $\theta_{k+1} = \operatorname{argmax}_{\theta}(Q)$.

Als Startwert für diese Iteration wird oftmals ein zufälliger Wert θ_0 gewählt. Die Iteration wird fortgesetzt, bis die als Gütemaß verwendete Log-Likelihood der Beobachtungen ausreichend groß ist. Es konnte gezeigt werden, dass das oben beschriebene EM-Verfahren konvergiert [28].

4.2.2.2 Der Expectation-Maximization-Algorithmus für lineare zeitinvariante Systeme

In [29] wird die Anwendung des EM-Algorithmus für die Bestimmung der Parameter linearer zeitinvarianter Systeme beschrieben. Dies ist genau der Typ von Systemen, der durch Zustandsübergangs- und Messgleichungen wie (5) und (6) beschrieben wird und für die das Kalman-Filter ein optimales Schätzverfahren ist.

Im Falle des beim Kalman-Filter angenommenen linearen, zeitinvarianten Modells kann die gemeinsame Dichte über Beobachtungen und latente Zu-

standsvariablen folgendermaßen faktorisiert werden:

$$P(z, x) = P(x_1) \prod_{t>1} p(x_t | x_{t-1}) \prod_t p(z_t | x_t) \quad (19)$$

Hierbei wurden Steuergrößen vernachlässigt. Die Log-Likelihood besteht dann aus folgender Summe quadratischer Formen:

$$\begin{aligned} 2 \cdot \log(P(z, x | \theta)) = & - \sum_{t>2} (x_t - Ax_{t-1})^T Q^{-1} (x_t - Ax_{t-1}) \\ & - \sum_t (z_t - Hx_t)^T R^{-1} (z_t - Hx_t) \\ & - (x_t - v)^T V^{-1} (x_t - v) \\ & - \chi(\det(Q), \det(R), \det(V)) \end{aligned} \quad (20)$$

wobei v und V der vorgegebene Wert für den ersten Zustand sowie dessen Unsicherheit bezeichnen und $\chi()$ für eine Funktion steht, die hauptsächlich von den Determinanten der Kovarianzmatrizen abhängt. Die Parameter θ beinhalten die Zustandsübergangsmatrix A , die Messmatrix H , die Kovarianzen Q und R sowie die Informationen über den Startzustand v , V .

Die Gütefunktion $Q = E[\log(P(z|x, \theta))]_{\theta=\theta_k}$ ist dann durch Gleichung (20), ausgewertet an den Erwartungswerten \hat{x} für die latenten Parameter, gegeben. Im Expectation-Schritt werden diese Schätzwerte durch Ausführen einer Kalman-Filterung mit anschließender Rückwärtsfilterung (Rauch Rekursion) auf allen Trainingsdaten berechnet. Im darauffolgenden Maximization-Schritt werden dann die berechneten Werte in (20) eingesetzt und die Ableitungen nach den Parametern gebildet. Diese werden dann gleich Null gesetzt und nach den gesuchten Parametern aufgelöst.

Zu beachten ist die Einschränkung, dass die vom EM-Algorithmus berechneten Abbildungs- und Kovarianzmatrizen in Gleichungen (19) und (20) nicht von der Zeit abhängen und damit bei jedem Zustandsübergang und jeder Aktualisierung mit neuen Messdaten gleich sind. Damit ist eine wesentliche Einschränkung gegenüber Verfahren gegeben, bei denen diese Parameter vom Zustand abhängen können, wie beispielsweise dem erweiterten Kalman-Filter.

In [26] wird eine speziell auf das dort vorgestellte ORKF zugeschnittene Version des EM-Algorithmus vorgestellt. Diese wurde in diesem Projekt jedoch nicht verwendet. Stattdessen wurde der hier vorgestellte EM-Algorithmus auf augenscheinlich ausreißerfreien Trainingsdaten angewandt.

4.2.3 Verfahren zur Detektion von Anomalien

Weil das ORKF die Messunsicherheit in jedem Filterschritt anpasst, können Verfahren zur Anomalieerkennung, die auf einem statistischen Test der Residuen gegen eine aus der Messunsicherheit abgeleitete Testgröße beruhen, nicht direkt angewandt werden. Dies gilt auch für Verfahren wie die Smoothing Splines, die eher geometrisch als statistisch motiviert sind (siehe hierzu aber beispielsweise auch [30], wo statistische Eigenschaften von Splines untersucht werden). Daher wurde in diesem Projekt in diesen Fällen auf zwei Verfahren zurückgegriffen, die keine explizite statistische Modellierung der Messunsicherheiten benötigen: CUSUM und GMA [31].

4.2.3.1 Anomalieerkennung auf Basis der geschätzten Unsicherheit

Die im Zuge der Berechnung ebenfalls bestimmte Unsicherheitsabschätzung für die geschätzten Zustände kann für die Detektion grober Messfehler bei der linearen Regression oder Kalman-Filterung verwendet werden. Die Ausreißererkennung basiert in diesem Fall auf einem statistischen Test der mit den geschätzten Unsicherheiten berechneten Mahalanobis-Norm der Residuen. Für das Kalman-Filter können hierfür die Innovationen und ihre Kovarianzen aus den Gleichungen (9) und (10) verwendet werden. Wenn die Voraussetzungen des Kalman-Filters erfüllt sind, ist die Mahalanobis-Norm der Residuen Chi-Quadrat verteilt:

$$T = s^T S^{-1} s \sim \chi_{n_z}^2 \quad (21)$$

Dabei bezeichnet $\chi_{n_z}^2$ die Chi-Quadrat-Verteilung mit n_z Freiheitsgraden und n_z ist die Dimension einer Messung. Eine Messung wird als Ausreißer angesehen, wenn die Testgröße T einen Schwellwert k überschreitet, der zuvor anhand der inversen Chi-Quadrat-Verteilung und der vorgegebenen Irrtumswahrscheinlichkeit α bestimmt wurde:

$$k = F^{-1}(\chi_{n_z}^2)(1 - \alpha) \quad (22)$$

Wobei $F^{-1}(\chi^2)$ die inverse Chi-Quadrat Verteilung ist. Diesem Test liegt die Nullhypothese zu Grunde, dass alle Annahmen über das Kalman-Filter, beispielsweise auch über die Linearität der Zustandsübergangs- und Messgleichung erfüllt sind. Weil das in der Praxis oftmals nicht der Fall ist, wird der Schwellwert k stattdessen häufig anhand einer Sta-

tistik der Norm der Residuen, die auf einem repräsentativen Datensatz erstellt wurde, gewählt.

4.2.3.2 GMA

Bei dem GMA (Geometric Moving Average) Verfahren handelt es sich um eine Methode zur rekursiven Berechnung eines geometrischen Mittels, die für dieses Projekt zum Zweck der Anomalieerkennung angepasst wurde. Das Verfahren verarbeitet eine Sequenz von Eingabedaten e_t und berechnet für jeden Wert einen Anomalieindikator I_t . Wenn dieser einen experimentell bestimmten Schwellenwert T überschreitet, wird davon ausgegangen, dass der gerade verarbeitete Wert auffällig ist.

Als Eingabesequenz werden die Beträge der Abweichungen zwischen Sensormesswerten und den gefilterten Daten verwendet:

$$e_t = |\hat{z}_t - z_t| \quad (23)$$

In obiger Formel ist \hat{z}_t der von dem Filter vorhergesagte Messwert und z_t der tatsächliche Messwert. Als Anomalieindikator dient das gewichtete Mittel zwischen dem aktuellen Eingabewert und dem zuletzt berechneten Wert des Anomalieindikators I_t . Dieser Wert kann rekursiv berechnet werden und entspricht einer Filterung der Eingabedaten mit einer exponentiell abfallenden Folge von Gewichten, deren Summe gegen eins konvergiert:

$$I_t = wI_{t-1} + (1 - w)e_t \quad (24)$$

Der Parameter $w \in (0,1)$ bestimmt dabei, wie stark länger zurückliegende Daten gewichtet werden.

Zur Detektion von Anomalien wird der Indikator zunächst mit 0 initialisiert. Dann wird ein Schätzverfahren, wie beispielsweise das ORKF, verwendet, um die Sensormesswerte zu filtern. Die Abweichungen zwischen den tatsächlichen und den gefilterten Werten gemäß Formel (23) werden rekursiv zur Berechnung eines Wertes des Anomalieindikators für jeden Zeitpunkt nach Formel (24) verwendet. Wenn dieser Wert den Schwellenwert T überschreitet, wird eine Anomalie ausgegeben und der Indikator wird zurückgesetzt.

4.2.3.3 CUSUM

Das CUSUM (Cumulative Sum) Verfahren ähnelt dem GMA Verfahren: Auch hier werden die Abweichungen zwischen Sensormesswerten und den Vorhersagen eines Filters verwendet, um einen In-

dikator zu bestimmen, der dann mit einem experimentell festgelegten Schwellenwert verglichen wird.

Der Hauptunterschied zwischen CUSUM und GMA ist die Berechnung des Indikators, die bei CUSUM auf der Annahme einer linearen Abnahme des Indikators beruht:

$$I_t = \max(I_{t-1} + e_t - d, 0) \quad (25)$$

Der Parameter d bestimmt dabei die Rate, mit der der Indikator auf den Ausgangswert zurückgeführt wird.

4.3 Plausibilisierung einzelner physikalischer Größen

4.3.1 Plausibilisierung von Temperaturdaten anhand von Smoothing Splines

Die in Kapitel 4.2.1 erläuterten Smoothing Splines wurden anhand von Daten des Temperatursensors MS6T1u des RTM Systems, mit welchem die Bauwerkstemperatur erfasst wird, und des Temperatursensors 1CBF4 des iBAST Systems, mit welchem die Lufttemperatur erfasst wird, evaluiert. Für den Elastizitätsparameter α wurde für alle Experimente der Wert $2,5e-5$ gewählt.

Bild 7 zeigt die Anpassung eines Smoothing Splines an einen Sensordatenausschnitt des Temperatursensors MS6T1u. Es ist deutlich zu erkennen, dass der Smoothing Spline die Messwerte glättet und dabei größtenteils mittig zwischen den größten Ausschlägen hindurchläuft. Die gute Anpassung des Smoothing Splines an die Daten kann erreicht werden, weil bei der Bestimmung der Parameter für den Spline alle Messwerte aus dem dargestellten Zeitbereich berücksichtigt wurden. Dies ist ein wesentlicher Unterschied zu rekursiv arbeitenden Ver-

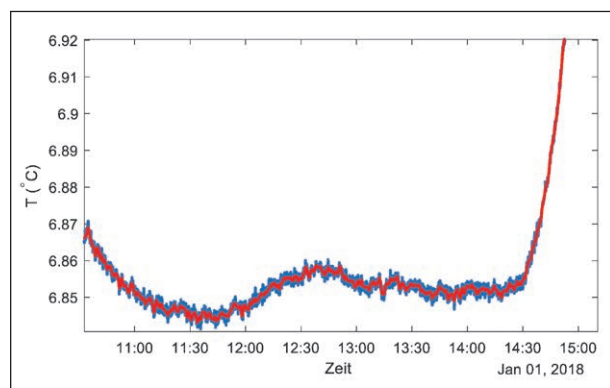


Bild 7: Von dem Sensor MS6T1u erfasster Temperaturverlauf (blau) und angepasster Smoothing Spline (rot)

fahren wie den in den Kapiteln 4.2.1.2 und 4.2.1.3 behandelten Kalman-Filter und ORKF.

Die in Bild 7 gezeigte Messreihe enthält keine Anomalien. Prinzipiell erfolgt die Anomalieerkennung mit Smoothing Splines auf Basis der Abstände zwischen dem Smoothing Spline und den zugrundeliegenden Datenpunkten. Hierfür bieten sich vor allem Verfahren an, die keine Informationen über die Unsicherheit der geglätteten Datenpunkte benötigen, beispielsweise das GMA aus Kapitel 4.2.3.2, oder das CUSUM-Verfahren aus Kapitel 4.2.3.3.

In Bild 8 bis Bild 15 sind die Ergebnisse der Glättung von Messwerten des Temperatursensors 1CBF4 mit jeweils einem Smoothing Spline und der anschließenden Ausreißererkennung mit dem GMA und dem CUSUM Verfahren dargestellt. Die Schwellwerte, die für die Erkennung der Anomalien benötigt werden, wurden auf separaten Trainingsdaten bestimmt. Dabei zeigen Bild 8 bis Bild 11 die Ergebnisse bei Verwendung von Trainingsdaten aus der Winterzeit, während Bild 12 bis Bild 15 die Ergebnisse bei Verwendung von Trainingsdaten aus der Sommerzeit zeigen. Ein Vergleich der bei-




Bild 8: Beispiel zur Anomaliedetektion bei dynamischen Daten (Smoothing Spline)




Bild 10: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (Smoothing Spline)




Bild 9: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (Smoothing Spline)




Bild 11: Beispiel zur Anomaliedetektion bei Vorliegen von Ausreißern (Smoothing Spline)

Bilder 8 – 11: Anomalieerkennung mit Smoothing Splines für verschiedene Szenarien.

Blaue Linie: Smoothing Spline, Grüne Linie: Original Sensordaten, Rote Kreuze: Ausreißer nach GMA, Rote Kreise: Ausreißer nach CUSUM. Die Schwellwerte für die Anomalieerkennung wurden anhand von Trainingsdaten aus der Winterzeit bestimmt.

den Bildreihen zeigt, dass die Verwendung repräsentativer Trainingsdaten sehr wichtig für die Bestimmung der Schwellwerte ist: Wenn die Schwellwerte basierend auf einem Datensatz, der in den Wintermonaten aufgezeichnet wurde, bestimmt werden, werden sehr viel mehr Datenpunkte als Anomalien bzw. Messausreißer eingestuft.

Zu den hier verwendeten Daten gibt es keine separat erstellte, zuverlässige Kennzeichnung der Ausreißer (Grundwahrheit). Daher kann nicht mit Sicherheit festgestellt werden, bei welcher der detek-

tierten Anomalien tatsächlich ein außergewöhnlicher Datenpunkt vorliegt, oder ob ein falsch-positives Ergebnis vorliegt, also ein korrekter Messwert fälschlicherweise als Anomalie eingestuft wurde.

Ein visueller Vergleich legt aber die Vermutung nahe, dass ein großer Teil der in Bild 8 bis Bild 11 gezeigten Anomaliedetektionen falsch-positive Ergebnisse sind. Vermutlich unterscheidet sich die kurzfristige Dynamik der Temperaturkurven zwischen den Winter- und den Sommermonaten. Dies führt im Sommer zu größeren Abweichungen zwi-

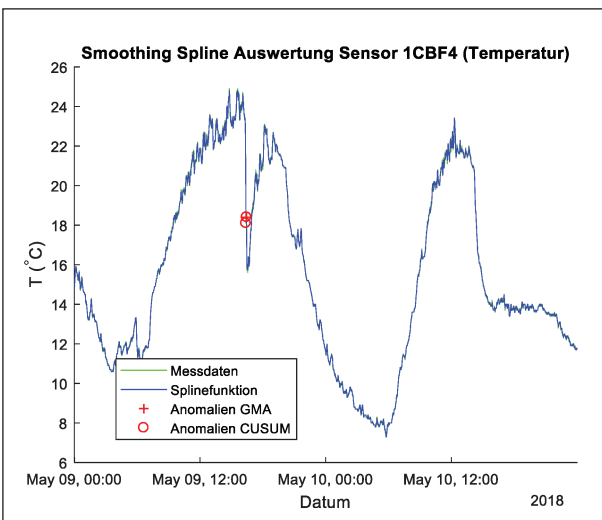


Bild 12: Beispiel zur Anomaliedetektion bei dynamischen Daten (Smoothing Spline)




Bild 14: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (Smoothing Spline)




Bild 13: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (Smoothing Spline)




Bild 15: Beispiel zur Anomaliedetektion bei Vorliegen von Ausreißern (Smoothing Spline)

Bilder 12 – 15: Anomalieerkennung mit Smoothing Splines für verschiedene Szenarien.

Blaue Linie: Smoothing Spline, Grüne Linie: Original Sensordaten, Rote Kreuze: Ausreißer nach GMA, Rote Kreise: Ausreißer nach CUSUM. Die Schwellwerte für die Anomalieerkennung wurden anhand von Trainingsdaten aus der Sommerzeit bestimmt.

schen der Splinekurve und den Messdaten als durch die Schwellwerte, die für die Wintermonate bestimmt wurden, toleriert wird.

Werden die Schwellwerte hingegen auf einem Trainingsdatenausschnitt aus den Sommermonaten bestimmt, werden insgesamt weniger Ausreißer detektiert. Dass im Bereich der kurzfristigen Temperaturveränderung in Bild 12 und um den Nullwert (höchstwahrscheinlich tatsächlich ein Ausreißer) in Bild 15 Anomalien erkannt werden, ist plausibel. Nachteilig erscheint hingegen die Tatsache, dass an den Rändern der Bereiche mit fehlenden Daten in Bild 13 und Bild 14 keine Ausreißer erkannt werden, während die in der Nähe einiger Maxima in Bild 13, Bild 14 und Bild 15 markierten Ausreißer höchstwahrscheinlich falsch-positiv sind.

Ein Nachteil der hier verwendeten Smoothing Splines ist, dass ihre Berechnung nicht rekursiv erfolgt. Dies erschwert deren Verwendung in Online Systemen zur Plausibilisierung oder Dateninterpolation. Ein möglicher Lösungsansatz könnte darin bestehen, Smoothing Splines auf teilweise überlappenden Segmenten der Sensordaten zu berechnen und die Ausreißerererkennung oder Interpolation ausschließlich auf den nicht überlappenden Teilstücken durchzuführen. Allerdings ist auch eine rekursive Implementierung von Smoothing Splines möglich [32].

Die hohe Zahl an falsch-positiv Detektionen und die Tatsache, dass die Berechnung bei den hier betrachteten Smoothing Splines nicht rekursiv erfolgt, lassen diesen Ansatz wenig attraktiv erscheinen.

4.3.2 Plausibilisierung von Temperaturdaten mit dem ORKF

4.3.2.1 Anwendung des ORKF mit gelernten Modellen

Bild 16 bis Bild 19 zeigen einige Beispiele zur Anomaliedetektion mit dem ORKF bei Verwendung eines gelernten Modells. Zur Demonstration wurden hier Messdaten des Temperatursensors 1CBF4 des iBASt-Systems verwendet.

Zunächst wurden die Parameter des Modells, das von dem ORKF verwendet wird, mithilfe des Expectation-Maximization-Algorithmus (siehe Kapitel 4.2.2) auf einem repräsentativen Ausschnitt der Messdaten gelernt. Dann wurde das ORKF mit diesen Parametern auf den gleichen Sensordatenaus-

schnitt angewandt, um Schätzwerte für die Sensormesswerte zu berechnen. Die Differenz zwischen den originalen Messdaten und diesen gefilterten Daten ergibt dann eine Sequenz von Residuen, für die die GMA und CUSUM Anomalieindikatoren bestimmt wurden. Diese Werte wurden schließlich herangezogen, um Statistiken zu bestimmen, mit denen die Schwellwerte für die Erkennung von Anomalien festgelegt werden.

Aufgrund der Erfahrung, die bei der Auswertung mit Smoothing Splines gemacht wurde (siehe Kapitel 4.2.1.1), wurde für die Bestimmung der Modellparameter mit dem EM Verfahren und der Schwellwerte für die Anomaliedetektion ein Datenausschnitt aus den Sommermonaten gewählt. Somit liegen die für das Training betrachteten Zeiträume ebenso wie die Evaluationsdatensätze in eher warmen Monaten.

Für die Auswertung wurden die Parameter des ORKF aus einer Datei gelesen und damit ein neues Filter initialisiert. Dieses wurde zur Glättung der unten gezeigten Messdatenausschnitte, die nicht mit den Trainingsdaten überlappen, herangezogen. Für die daraus bestimmten Residuensequenzen wurden schließlich die Anomalieindikatoren berechnet und mit den zuvor auf den Trainingsdaten bestimmten Schwellwerten ausgewertet.

Die Auswertung nach diesem Ansatz ist in Bild 16 bis Bild 19 dargestellt. Die Auswertung erfolgte auf den gleichen Datenausschnitten, die auch schon bei der Auswertung der Smoothing Splines in Kapitel 4.3.1 verwendet wurden. Ein Vergleich mit den Ergebnissen der Smoothing Splines aus Bild 12 bis Bild 15 zeigt, dass die beiden Verfahren hier insgesamt vergleichbare Ergebnisse liefern. Der ORKF mit gelerntem Modell scheint etwas stärker auf die in Bild 16 und Bild 12 gezeigte, sehr dynamische Situation zu reagieren. Auch bei dem in Bild 17 gezeigten Ausfall der Sensordaten werden von diesem Ansatz am Ende des Ausfalls mehr Anomalien erkannt, als bei Verwendung der Smoothing Splines (Bild 13). Beide Verfahren markieren einige Datenpunkte in der Nähe von Gipfelstellen als Anomalien, bei denen es sich vermutlich um falsch-positive Ergebnisse handelt, siehe vor allem Bild 19 und Bild 15. Hierbei ist interessant, dass die vermutlich falsch-positive Detektion im Fall des Smoothing Splines eher bei der Verwendung des CUSUM Algorithmus auftreten, während bei dem ORKF mit gelerntem Modell eher das GMA Verfahren zu Fehldetektionen zu neigen scheint.




Bild 16: Beispiel zur Anomaliedetektion bei dynamischen Daten (ORKF mit gelerntem Modell)




Bild 18: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (ORKF mit gelerntem Modell)




Bild 17: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (ORKF mit gelerntem Modell)




Bild 19: Beispiel zur Anomaliedetektion bei Vorliegen von Ausreißern (ORKF mit gelerntem Modell)

Bilder 16 – 19: Anomalieerkennung mit ORKF und gelerntem Modell für verschiedene Szenarien.

Blaue Linie: Ergebnis der Filterung durch das ORKF, Grüne Linie: Original Sensordaten, Rote Kreuze: Ausreißer nach GMA, Rote Kreise: Ausreißer nach CUSUM. Die Schwellwerte für die Anomalieerkennung wurden anhand von Trainingsdaten aus der Sommerzeit bestimmt.

Insgesamt scheint das ORKF mit gelerntem Modell etwas sensibler auf Ausreißer zu reagieren als der Smoothing Spline und daher besser zur Detektion von Anomalien geeignet zu sein. Allerdings hängt dies stark von den gewählten Parametern ab, sodass vermutlich von Fall zu Fall entschieden werden muss, welches Verfahren tatsächlich vorteilhaft ist.

4.3.2.2 Anwendung des ORKF mit vorgegebenen Modellen

Die relativ hohe falsch-positiv Rate bei Anwendung des ORKF für die Anomaliedetektion in Kapitel 4.3.2 kann vermutlich darauf zurückgeführt werden, dass das gelernte Modell nicht geeignet ist. Daher wurde das Verfahren auch mit einem vorgegebenen Modell durchgeführt.

Hierfür wurde ein Modell mit einem zweidimensionalen Zustand angenommen, der sowohl die gemessene Temperatur als auch einen Gedächtniszustand enthält. Dies ist durch die Vorstellung begründet, dass die gemessene Lufttemperatur im Gleichgewicht mit der Temperatur von Gegenständen in der Umgebung steht, wodurch abrupte Temperaturänderungen abgeschwächt werden. Beispielsweise würde ein Abkühlvorgang langsamer ablaufen, wenn das Erdreich aufgeheizt ist und noch Wärme an die Umgebung abgibt. Dies motiviert eine Modellierung durch einen Tiefpassfilter, wie in Kapitel 4.4.2 für den Fall des Temperaturtransportes durch eine Wand beschrieben.

In diesem Fall wird davon ausgegangen, dass die gemessene Temperatur einer unbekanntem Anregung folgt und sich dieser exponentiell asymptotisch annähert. Die Geschwindigkeit, mit der diese Annäherung erfolgt, wird durch eine Zeitkonstante beschrieben, die auf den Trainingsdaten händisch bestimmt wurde. Ebenso wurden die Werte für das angenommene Mess- und Prozessrauschen nach Inspektion der Daten händisch vorgegeben. Ein Startwert für das Messrauschen wird vom ORKF benötigt, obwohl dieses bei der Filterung online bestimmt wird. Das vorgegebene Messrauschen dient dem Verfahren als Startwert für die Optimierung (a-priori Annahme).

Bild 20 bis Bild 23 zeigen die Ergebnisse für die Anwendung des ORKF mit vorgegebenem Modell für die Anomaliedetektion. Zur Evaluierung wurden hier die gleichen Daten verwendet, die auch schon in Kapitel 4.3.2 für die Evaluierung des ORKF mit gelerntem Modell sowie in Kapitel 4.3.1 für die Evaluierung der Smoothing Splines verwendet wurden. Bis auf die Verwendung eines vorgegebenen Modells wurden die gleichen Verarbeitungsschritte wie bei der Verwendung eines gelerntem Modells durchgeführt, insbesondere wurden die Schwellwerte zur Anomaliedetektion auf den gleichen Trainingsdaten im Voraus bestimmt.

Ein Vergleich der Ergebnisse für die verschiedenen Szenarien aus Bild 16 bis Bild 19 mit denen aus Bild 20 bis Bild 23 zeigt, dass das ORKF mit vorgegebenem Modell besser in der Lage ist, zwischen Ausreißern und herkömmlichen Fehlern zu unterscheiden und daher besser zur Erkennung von Anomalien geeignet ist.

Der Verlauf der Messdaten in Bild 16 und Bild 20 weist zwei unübliche Situationen auf: An einem

Nachmittag fallen die gemessenen Temperaturen nachmittags zunächst stark ab, um dann sofort wieder anzusteigen. Zweitens gibt es einen starken Abfall der gemessenen Temperaturen am darauf folgenden Tag. In beiden Situationen ist die Temperaturveränderung außergewöhnlich, sodass hier eine Einstufung als Anomalie vernünftig erscheint.

Bei vorgegebenem Modell wird die erste Situation sowohl nach dem CUSUM als auch nach dem GMA Kriterium als Anomalie eingestuft, wohingegen die zweite Situation nur nach CUSUM als Anomalie eingestuft wird. Bei dem gelerntem Modell wird nur die erste Situation als Anomalie eingestuft, was vermutlich eher korrekt ist.

In Bild 17 und Bild 21 ist ein längerer Ausfall des Sensors zu sehen. Die Messwerte setzen zu einem späteren Zeitpunkt auf einem anderen Niveau wieder ein. Ob diese Situation als Anomalie klassifiziert wird, hängt hier wesentlich davon ab, ob das eingesetzte zeitliche Modell den Temperaturverlauf in der Zwischenzeit gut beschreiben kann. Da die Sensormesswerte hier auf einem deutlich unterschiedlichen Niveau wieder einsetzen und ein einfaches Systemmodell verwendet wird, ist die Klassifizierung als Anomalie durch das ORKF mit vorgegebenem Modell einleuchtend. Bei Verwendung des gelerntem Modells werden von dem GMA Verfahren wiederum einige nachfolgende Stellen als Anomalie klassifiziert, die vermutlich eher auf Temperaturschwankungen im Tagesverlauf zurückzuführen sind.

Bild 18 und Bild 22 zeigen ebenfalls einen Ausfall von Messungen über einen längeren Zeitraum. Hier setzen die Messungen allerdings auf einem ähnlichen Niveau wieder ein. Daher werden von dem ORKF bei Verwendung des vorgegebenen Modells hier keine Anomalien erkannt, während bei Verwendung des gelerntem Modells mit dem GMA Verfahren wiederum einige Stellen vor und nach dem Datenausfall vermutlich fälschlicherweise als Anomalie gekennzeichnet werden.

Bei der Situation in Bild 19 und Bild 23 handelt es sich um einen groben Ausreißer, da hier ein einzelner Sensormesswert Null ist. Dies wird von dem ORKF mit vorgegebenem Modell nur in Kombination mit dem GMA Kriterium erkannt. Die Verwendung des gelerntem Modells führt wieder zu vielen Alarmen. In der Nähe des groben Ausreißers schlagen hier jedoch sowohl der CUSUM als auch der GMA Indikator an.




Bild 20: Beispiel zur Anomaliedetektion bei dynamischen Daten (ORKF mit vorgegebenem Modell)

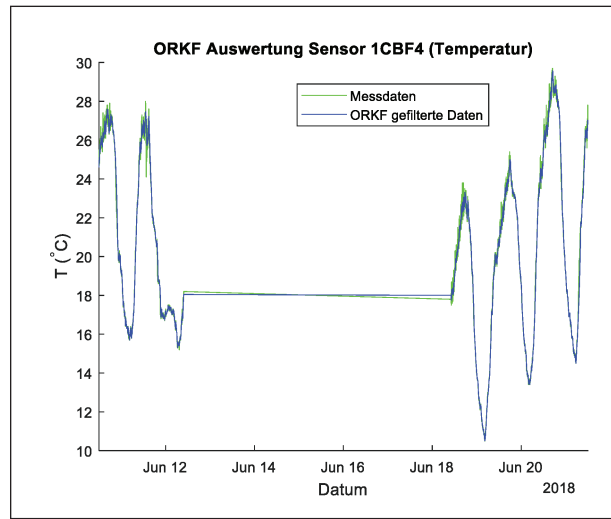


Bild 22: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (ORKF mit vorgegebenem Modell)




Bild 21: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (ORKF mit vorgegebenem Modell)




Bild 23: Beispiel zur Anomaliedetektion bei Vorliegen von Ausreißern (ORKF mit vorgegebenem Modell)

Bilder 20 – 23: Anomalieerkennung mit ORKF und vorgegebenem Modell für verschiedene Szenarien.
 Blaue Linie: Ergebnis der Filterung durch das ORKF, Grüne Linie: Original Sensordaten, Rote Kreuze: Ausreißer nach GMA, Rote Kreise: Ausreißer nach CUSUM.

4.4 Plausibilisierung zusammenhängender physikalischer Größen

4.4.1 Plausibilisierung von Temperatur und Luftfeuchte

Für die Plausibilisierung zusammenhängender physikalischer Größen wird in der Regel Wissen über die gegenseitige Abhängigkeit dieser Größen benötigt. Wenn dieses Wissen nicht explizit modelliert, sondern aus den Daten gelernt wird, wird an dieser Stelle, wie bereits in Kapitel 4.2.1.1, von modellfreien Methoden gesprochen.

Zunächst wurde die Plausibilisierung von Temperatur und Luftfeuchte untersucht. Diese Größen sind über physikalische Prozesse eng miteinander verknüpft. Allerdings ist die explizite Modellierung dieses Zusammenhangs aufwändig. Daher bietet es sich an, diese Größen als Beispiel für die Plausibilisierung zusammenhängender Größen ohne Verwendung eines physikalischen Modells heranzuziehen.

Hierfür wurden die Daten aus verschiedenen Monaten getrennt betrachtet und für jeden Monat der lineare Zusammenhang zwischen Temperatur und

Luftfeuchte mit linearer Regression bestimmt (Stratifizierung). Dann wurde untersucht, ob die Luftfeuchtigkeit so aus den Temperaturmessungen abgeleitet werden kann.

In Bild 24 bis Bild 27 sind die Ergebnisse der Schätzung der Luftfeuchtigkeit aus den Temperaturmessungen dargestellt. In den Wintermonaten scheint die relative Luftfeuchte nicht allein von der Temperatur abzuhängen (Bild 24). Daher kann die relative Luftfeuchte im Februar nicht mit dem linearen Temperaturmodell vorhergesagt werden (Bild 25). In

den Sommermonaten kann der Zusammenhang zwischen Temperatur und Feuchte eher durch eine Gerade angenähert werden, wie Bild 26 für den Monat Juli zeigt. Die mit dem so bestimmten Modell anhand der Temperatur vorhergesagte Feuchte weicht an manchen Tagen jedoch relativ stark von der gemessenen Feuchte ab (Bild 27).

Insgesamt wäre das hier beschriebene Vorgehen allenfalls in den Sommermonaten für eine gegenseitige Plausibilisierung von Temperatur- und Luftfeuchtemessungen geeignet.

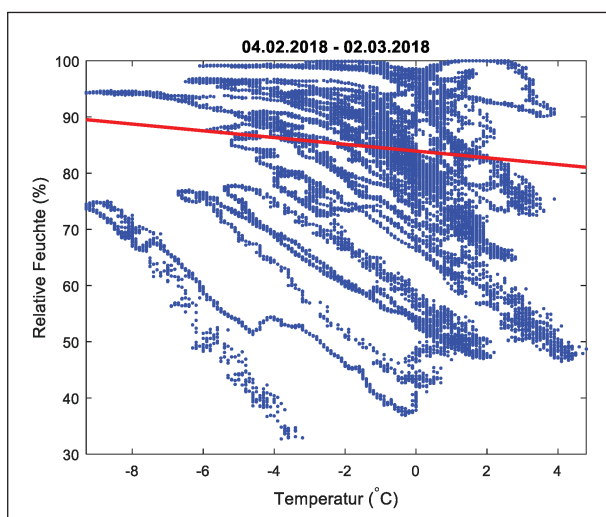


Bild 24: Scatterplot von Temperatur und Feuchte für den Monat Februar. Rote Linie: Mit Regression bestimmte Ausgleichsgerade

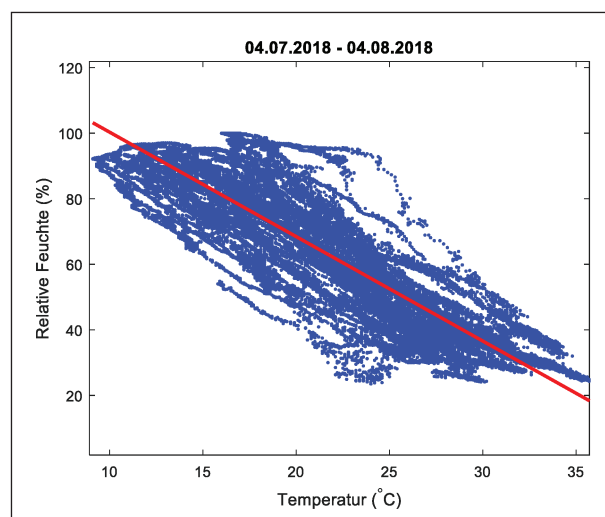


Bild 26: Scatterplot von Temperatur und Feuchte für den Monat Juli. Rote Linie: Mit Regression bestimmte Ausgleichsgerade




Bild 25: Schätzung der relativen Luftfeuchte anhand der Temperatur für den Monat Februar. Rot: Geschätzte Feuchte, Blau: Messwerte




Bild 27: Schätzung der relativen Luftfeuchte anhand der Temperatur für den Monat Juli. Rot: Geschätzte Feuchte, Blau: Messwerte

4.4.2 Explizite physikalische Modellierung: Temperatursensorenmodell

Für die Demonstration der Plausibilisierung zusammenhängender physikalischer Größen mit expliziter Modellierung wurde die gegenseitige Plausibilisierung verschiedener an der Versuchsbrücke angebrachter Temperatursensoren gewählt.

Bild 28 zeigt die Position der an der untersuchten Brücke installierten Temperatursensoren im Brückenquerschnitt. Mit den Temperatursensoren werden die Lufttemperaturen (1CBF4), die Betonoberflächentemperaturen außen (0CBF3) und innen (0CBEB und OCC14) sowie die Temperatur im Beton am Bewehrungsstahl (MS 6T2o, MS 6T1u) gemessen. Die Messwerte dieser Sensoren können im Allgemeinen nicht direkt miteinander verglichen werden, weil sich die Temperaturen innerhalb und außerhalb der Brücke sowie in den Wänden stark voneinander unterscheiden. Auch der Vergleich von Sensoren, die ausschließlich außerhalb der Brücke befestigt sind, kann schwierig sein, beispielsweise wenn diese unterschiedlichen Umgebungsbedingungen ausgesetzt sind. So könnten Sensoren auf der windabgewandten Seite andere Werte messen als auf der windzugewandten Seite.

Für die gegenseitige Plausibilisierung der Temperatursensoren wird daher ein Modell für die Temperaturausbreitung zwischen den Sensoren benötigt. In der hier vorgestellten Arbeit wurden hierfür verschiedene Varianten des in [33] beschriebenen Modells für den Wärmetransport in Gebäuden implementiert. Diese werden in den folgenden Kapiteln, ausgehend von dem Umfassendsten, das dann schrittweise vereinfacht wird, beschrieben.




Bild 28: Position der Temperatursensoren im Brückenquerschnitt

4.4.3 Modell für Wärmeaustausch zwischen Außenbereich, Hohlkastenwand und Hohlkasteninnern

Dieses Modell beschreibt den Wärmeaustausch zwischen dem Außenbereich, dem Innern der Hohlkastenwand und dem Inneren des Hohlkastens. Dies entspricht dem von den Sensoren 1CBF4 (iBASt), MS6T1u (RTMS) und 0CBEB (iBASt) gemessenen Temperaturverlauf.

In [33] wird der Wärmetransport zwischen zwei Bereichen mithilfe thermodynamischer Ersatzschaltbilder beschrieben. Dabei wird angenommen, dass das zu modellierende System in Komponenten aufgeteilt werden kann, die sich zusammengesetzt wie das Gesamtsystem verhalten und deren zeitliches Verhalten analog zu den Komponenten eines elektrischen Schaltkreises beschrieben werden kann. In diesem Modell werden thermische Isolatoren thermische Widerstände zugeordnet und Wärmespeichern thermische Kapazitäten. Diese entsprechen den elektrischen Widerständen und Kapazitäten in elektrischen Schaltbildern. Außerdem werden Temperaturunterschiede mit Spannungen identifiziert.

Für die Modellierung des Wärmeaustauschs wurde davon ausgegangen, dass die Bereiche, in denen eine Temperatur gemessen wird, eine bestimmte Wärmekapazität haben und durch Isolationsschichten voneinander abgetrennt sind. Im Hohlkasteninnern wird die Wärme beispielsweise von den umschließenden Betonwänden gespeichert, die zugleich auch eine Isolationsschicht und damit einen thermischen Widerstand darstellen. Diese Überlegungen führen zu einer Modellierung nach dem in Bild 29 gezeigten Ersatzschaltbild.




Bild 29: Ersatzschaltbild für die Modellierung des Wärmeaustauschs zwischen verschiedenen Komponenten einer Hohlkastenbrücke

Das Modell entspricht also einem elektrischen Schaltkreis aus zwei parallel geschalteten Kondensatoren mit Widerständen, die von einer externen Spannungsquelle (Außentemperatur) angeregt werden. Die im Beton bzw. im Hohlkasten gemessenen Temperaturen entsprechen den Spannungen, die über Kondensatoren mit entsprechenden Kapazitäten abfallen. Der durch Wärmestrahlung und Konvektion bedingte Wärmetransport wird in diesem Modell nicht berücksichtigt.

Mit den Bezeichnungen aus Bild 29 ergibt sich durch Anwendung der Regeln für elektrische Schaltkreise folgendes zeitliches Modell:

$$\dot{T}_a = 0 \quad (26)$$

$$\dot{T}_1 = \frac{1}{C_1 R_1} T_a - \left(\frac{1}{R_2 C_1} + \frac{1}{R_1 C_1} \right) T_1 + \frac{1}{R_2 C_1} T_2 \quad (27)$$

$$\dot{T}_2 = \frac{1}{C_2 R_2} (T_1 - T_2) \quad (28)$$

Die Parameter C_1, C_2, R_1, R_2 in obigen Gleichungen können durch die folgenden Konstanten ersetzt werden, die die Wärmeleitung und -Isolation zwischen den Brückenbauteilen, an denen die Temperatur gemessen wird, beschreiben:

$$\tau_1 = \frac{1}{R_1 C_1} \quad (29)$$

$$\tau_2 = \frac{1}{R_2 C_2} \quad (30)$$

$$\tau_{21} = \frac{1}{R_2 C_1} \quad (31)$$

Die Konstanten τ_1 und τ_2 wurden anhand der Sensordaten bestimmt, indem das Minimum der Fehlerfunktion

$$\epsilon_i = \left(\int_t^{t+\Delta t} \dot{T}_i dt + T_i(t) \right) - T_i(t + \Delta t) \quad (32)$$

durch Rastersuche (Grid Search) auf einem kleinen Teil der Daten bestimmt wurde. Die Konstante τ_{21} wurde dann durch den Mittelwert von τ_1 und τ_2 abgeschätzt.

Mit dem Zustand $T = [T_a \ T_1 \ T_2]$ können die Gleichungen in einer Matrix zusammengefasst werden, womit sich das zeitdiskrete, stochastische Prozess

modell für ein Kalman-Filter wie folgt bestimmen lässt:

$$A = \expm(F\tau) \quad (33)$$

$$T(t + \tau) = A \cdot T(t) + w \quad (34)$$

Wobei $\expm()$ die Exponentialabbildung für Matrizen und w ein Rauschterm mit Kovarianzmatrix Q sind. Da alle Zustandsgrößen direkt gemessen werden, ist das Messmodell des Filters einfach:

$$z(t) = T(t) + v \quad (35)$$

Hierbei ist v ein Rauschterm mit Kovarianzmatrix R . Die Einträge der Kovarianzmatrizen wurden nach Inspektion der Sensordaten händisch gewählt.

Gleichungen (33)-(35) definieren das Prozess- und Messmodell eines Kalman-Filters, das die Sensormessungen gemäß dem physikalischen Modell aus den Gleichungen (26)-(28) glättet. Zur Detektion von Anomalien wurden die Messwerte mit einem Kalman-Filter für dieses Modell gefiltert, die Mahalanobis-Norm der Residuen bestimmt und diese dann mit einem auf Testdaten bestimmten Schwellwert verglichen. Werte, die den Schwellwert überschritten haben, wurden als Ausreißer angenommen.

Die Ergebnisse der Ausreißerkennung, angewandt auf den Zeitraum Januar bis Juli 2018, sind in Bild 30 dargestellt. Die Bilder 31 und Bild 32 zeigen Ausschnitte aus dieser Sequenz. Insgesamt sind die Ergebnisse vergleichbar mit denen des ORKF mit vorgegebenem Modell aus Bild 20 bis Bild 23.




Bild 30: Plausibilisierung dreier Temperaturmessungen im Zeitraum Januar bis Juli 2018. Schwarze Kreuze kennzeichnen als Ausreißer markierte Messwerte.

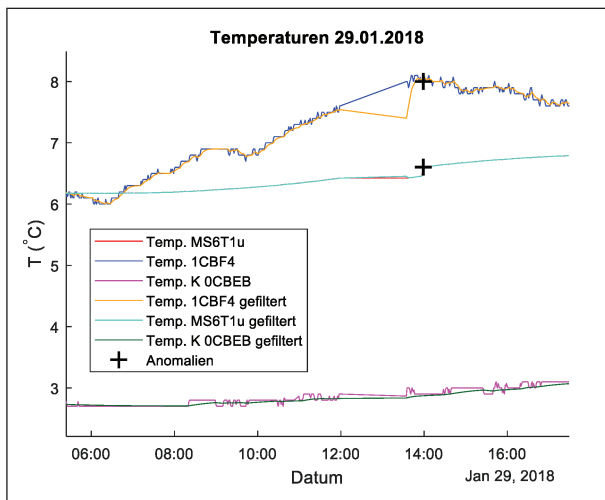


Bild 31: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit drei Zuständen für einen Zeitraum mit fehlenden Daten




Bild 32: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit drei Zuständen für einen Zeitraum mit einem groben Messfehler

Bilder 31 und 32: Ausschnitte der Kalman-Filter basierten Anomalieerkennung für drei Temperatursensoren von Januar bis Juli 2018

4.4.4 Modell für Wärmeaustausch zwischen Außenbereich und Hohlkastenwand

Das Modell für drei Temperatursensoren aus Kapitel 4.4.3 kann vereinfacht werden, um lediglich zwei Sensoren zu überwachen. Hierfür wurden zwei verschiedene Ansätze untersucht, die sich darin unterscheiden, wie die Außentemperatur durch das Filter verarbeitet wird. Im ersten Fall wird die Außentemperatur als zu schätzende Größe betrachtet, genauso wie die im Inneren des Gebäudes gemessenen Temperaturen. Zweitens besteht die Möglichkeit, die Außentemperatur als feste Eingangsgröße aufzufassen, die das System steuert.

4.4.4.1 Außentemperatur als zu schätzende Größe

Wenn die Außentemperatur als zu schätzende Größe aufgefasst wird, erfolgt die Modellierung analog zu der Darstellung in 4.4.3, nur dass eine Zustandsvariable wegfällt. Für die innere Temperatur erhält man so das zeitliche Modell

$$\dot{T}_1 = \frac{1}{\tau}(T_a - T_1). \quad (36)$$

In Bild 33 bis Bild 35 sind die Ergebnisse der Auswertung für die gleichen Zeiträume, die auch bei der Auswertung des Modells für drei Temperaturen in Bild 30 bis Bild 32 betrachtet wurden, dargestellt. Im

Wesentlichen werden dabei die gleichen Stellen als Anomalie erkannt. Dies liegt vermutlich daran, dass die auffälligen Sensormesswerte gerade von den Sensoren stammen, die auch in der Auswertung des zweidimensionalen Modells untersucht wurden.

4.4.4.2 Außentemperatur als externe Anregung

Das Modell vereinfacht sich weiter, wenn die Außentemperatur als externe Steuergröße verarbeitet wird, und nicht Teil des Filterzustandes ist. In diesem Fall ist der Zustand eindimensional und bei der Berechnung der Filterschritte sind nur skalare Größen beteiligt, wodurch der Rechenaufwand reduziert wird. In diesem Fall erhält man das untenstehende zeitdiskrete Modell:

$$T_1 = AT_1 + BT_a + w \quad (37)$$

$$A = \exp\left(-\frac{\Delta t}{\tau}\right) \quad (38)$$

$$B = 1 - A \quad (39)$$

In obigen Gleichungen ist w ein skalarer Rauschterm mit Varianz q . Die Ergebnisse der Auswertung mit obigem Modell sind in Bild 36 bis Bild 38 dargestellt. Ein Vergleich mit den Ergebnissen des zweidimensionalen Filters in Bild 33 bis Bild 35 zeigt, dass insgesamt mehr Situationen als Anomalie ein-




Bild 33: Plausibilisierung zweier Temperaturmessungen im Zeitraum Januar bis Juli 2018. Schwarze Kreuze kennzeichnen als Ausreißer markierte Messwerte.

gestuft werden. Dies kann vielleicht darauf zurückgeführt werden, dass hier die Anomaliedetektion nur auf den normierten Residuen des in der Wand liegenden Sensors durchgeführt wird. Diese Ungleichbehandlung der beiden beteiligten Sensoren kann dazu führen, dass Abweichungen in den Sensormessungen der beiden Sensoren unterschiedlich gewichtet werden, und dadurch die Anomaliedetektion verzerrt wird. Dieses Verfahren eignet sich daher eher zur Glättung von Messwerten als zur Detektion von Anomalien bei Verwendung mehrerer Sensoren.




Bild 34: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit zwei Zuständen für einen Zeitraum mit fehlenden Daten




Bild 35: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit zwei Zuständen für einen Zeitraum mit einem groben Messfehler




Bild 36: Plausibilisierung zweier Temperaturmessungen im Zeitraum Januar bis Juli 2018, wobei die Messungen des iBASt-Sensors 1CBF4 als Steuergröße aufgefasst wurden. Schwarze Kreuze kennzeichnen als Ausreißer markierte Messwerte.




Bild 37: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit zwei Zuständen für einen Zeitraum mit fehlenden Daten




Bild 38: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit zwei Zuständen für einen Zeitraum mit einem groben Messfehler

Bilder 37 und 38: Ausschnitte der Kalman-Filter basierten Anomalieerkennung für zwei Temperatursensoren von Januar bis Juli 2018, wobei die Außentemperaturmessungen des iBASt-Sensors 1CBF4 als Steuergröße aufgefasst wurden.

4.5 Zusammenfassung

In diesem Kapitel werden verschiedene Verfahren zur Plausibilisierung von Sensordaten vorgestellt. Diese lassen sich grob in modellfreie Verfahren, die entweder kein Modell voraussetzen (Smoothing Splines) oder Modellparameter in einer Trainingsphase ermitteln (ORKF mit Expectation Maximization), und modellbasierte Verfahren, die eine explizite Modellierung durch Experten erfordern, unterteilen. Die Anwendung der Verfahren wird anhand des Beispiels der Plausibilisierung von Temperaturdaten demonstriert.

Bei der Übertragung der Verfahren auf andere Sensortypen ist zu beachten, dass die vorgestellten modellfreien Verfahren eher für die Plausibilisierung einzelner physikalischer Größen oder einiger weniger zusammenhängender Größen geeignet sind. Zwar besteht auch die Möglichkeit, Splineflächen zur Approximation mehrdimensionaler Daten zu berechnen, hierfür liegen bei dieser Aufgabenstellung jedoch im Allgemeinen nicht genügend Datenpunkte vor, weil die Messreihen mehrerer Sensoren innerhalb eines kurzen Zeitraums zunächst nur eine Kurve im mehrdimensionalen Raum beschreiben, aus der keine approximierende Fläche abgeleitet werden kann, die den beobachteten Zusammenhang zwischen den Größen beschreibt.

Verfahren, bei denen zunächst ein Modell in einer Trainingsphase gelernt werden muss, benötigen mit wachsender Dimension der vorherzusagenden Da-

ten auch mehr Modellparameter, um die Zusammenhänge zwischen den Variablen abzubilden. Dadurch werden auch mehr Trainingsbeispiele benötigt, um die Parameter der Modelle zu bestimmen, vgl. [34]. Außerdem können mit dem für die Bestimmung der Modellparameter eingesetzten Expectation-Maximization-Algorithmus lediglich lineare Modelle mit konstanten Koeffizienten identifiziert werden, weshalb diese Verfahren nicht für die Modellierung komplexer Signalverläufe geeignet sind. In der Praxis sind diese Verfahren daher ebenfalls eher für die Plausibilisierung einzelner physikalischer Größen geeignet.

Weiterhin ist bei modellfreien Verfahren zu berücksichtigen, dass die Ergebnisse stark von repräsentativen Trainingsdaten abhängen. Für den Fall der Smoothing Splines verdeutlicht dies der Vergleich der in Bild 9 bis Bild 12 mit den in Bild 13 bis Bild 16 dargestellten Ergebnissen. Hier führt das Training (Bestimmung der Schwellwerte für die Anomalieerkennung) in den Wintermonaten zu vielen falsch-positiven Anomaliedetektionen.

Im Fall der Temperaturplausibilisierung konnten die besten Ergebnisse durch explizite Modellierung erzielt werden. Eine mögliche Fehlerquelle besteht bei diesen Verfahren darin, dass bestimmte Effekte nicht modelliert werden und daher von den Algorithmen als Anomalie erkannt werden. Deshalb ist auch hier in kritischen Fällen eine abschließende Beurteilung der detektierten Anomalien durch Experten anzuraten.

5 Gesamtkonzept für die algorithmisch gestützte Sensordatenanalyse für Brückenbauwerke

5.1 Einleitung

An einem mit Sensoren ausgerüsteten Brückenbauwerk können große Mengen heterogener Daten anfallen. Diese zu sichten und zu interpretieren kann auch erfahrene Ingenieure viel Zeit kosten. Daher wird angestrebt, diese Analysetätigkeit teilweise zu automatisieren, sodass Zusammenhänge zwischen verschiedenen Datenströmen leichter aufgedeckt werden können. Dabei kann neben den Daten, die direkt von an dem untersuchten Brückenbauwerk befestigten Sensoren aufgezeichnet werden, auch die Einbeziehung von Zusatzinformationen aus externen Datenquellen von Interesse sein, um Zusammenhänge zwischen Sensormessungen und externen Einflussgrößen zu identifizieren.

Neben der Möglichkeit zur Verarbeitung großer Datenmengen ist ein weiterer Vorteil der algorithmisch gestützten Auswertung, dass so unter Umständen Zusammenhänge erkannt werden können, die von den beteiligten Experten nicht erwartet und daher auch nicht gezielt untersucht werden.

Hier wird daher ein Konzept für die algorithmisch unterstützte Sensordatenanalyse vorgestellt, das Bauingenieuren helfen soll, Zusammenhänge zwischen Sensormessungen zu ermitteln.

Im Gegensatz zu den in vorangegangenen Kapiteln entwickelten Verfahren zeichnet sich die hier behandelte Problemstellung dadurch aus, dass die Strukturen, auf die die Daten hin untersucht werden, zu Beginn völlig unbekannt sind. Dadurch ist eine explizite Modellierung durch ein physikalisches Modell, wie beispielsweise die Modellierung des Wärmeaustauschs zwischen Brückenteilen durch eine Differentialgleichung, hier ausgeschlossen.

Weiterhin soll nicht vorausgesetzt werden, dass die Daten vor der Verarbeitung klassiert wurden. Eine solche Klassierung liegt beispielsweise vor, wenn zu bei Fahrzeugüberfahrten erfassten Dehnungsmessungen separat auch Fahrzeugtypen aufgezeichnet werden, um dann in einem zweiten Schritt abzuleiten, wie aus der Signalform von Dehnungsmessungen auf Fahrzeugtypen geschlossen werden kann. Ein weiteres Beispiel wäre die Aufzeich-

nung von Daten an Bauwerken, an denen bestimmte Teile der Konstruktion absichtlich beschädigt wurden, um solche Beschädigungen später zu erkennen.

In beiden Fällen werden in möglicherweise recht zeit- und kostenintensiven Experimenten gezielt Zusatzinformationen erhoben, um später allein aufgrund der Sensormessungen Aussagen über die Größen von Interesse zu erhalten.

Demgegenüber wird im Folgenden davon ausgegangen, dass solche Klasseninformationen nicht vorliegen. Verfahren, die in diesem Fall angewandt werden, bezeichnet man auch als unüberwachte Lernverfahren. Diese lassen sich grob in zwei Klassen aufteilen:

- Verfahren, die eine Dimensionsreduktion durchführen, um wichtige von unwichtiger Information zu unterscheiden (Kompressionsverfahren).
- Gruppierungsverfahren (Clustering-Verfahren), die zueinander ähnliche Datenpunkte einer Klasse zuordnen.

In Kapitel 5.2 wird das im Rahmen dieses Projektes entwickelte Konzept für die algorithmisch unterstützte Sensordatenanalyse vorgestellt. Dabei wird der algorithmische Ablauf im Groben erläutert, um die Zusammenhänge zwischen den verwendeten Verfahren zu verdeutlichen. Die Details der einzelnen Verfahren, die gewissermaßen die Bausteine des Konzepts darstellen, werden später in Kapitel 5.3 erläutert.

5.2 Beschreibung des algorithmischen Ablaufs

Bild 39 stellt den Ablauf der algorithmisch unterstützten Sensordatenanalyse schematisch dar. Der hier vorgestellte Ablauf ist durch die Veröffentlichungen [35] sowie [36] motiviert.

Es gibt zwei Datenquellen: Erstens das an der Brücke angebrachte Sensornetz und zweitens eine Datenbank mit Zusatzinformationen, die es ermöglicht Sensordaten mit externen Daten, die nicht an der Brücke erhoben werden und eventuell auch nicht im Voraus bekannt sind, zu vergleichen.

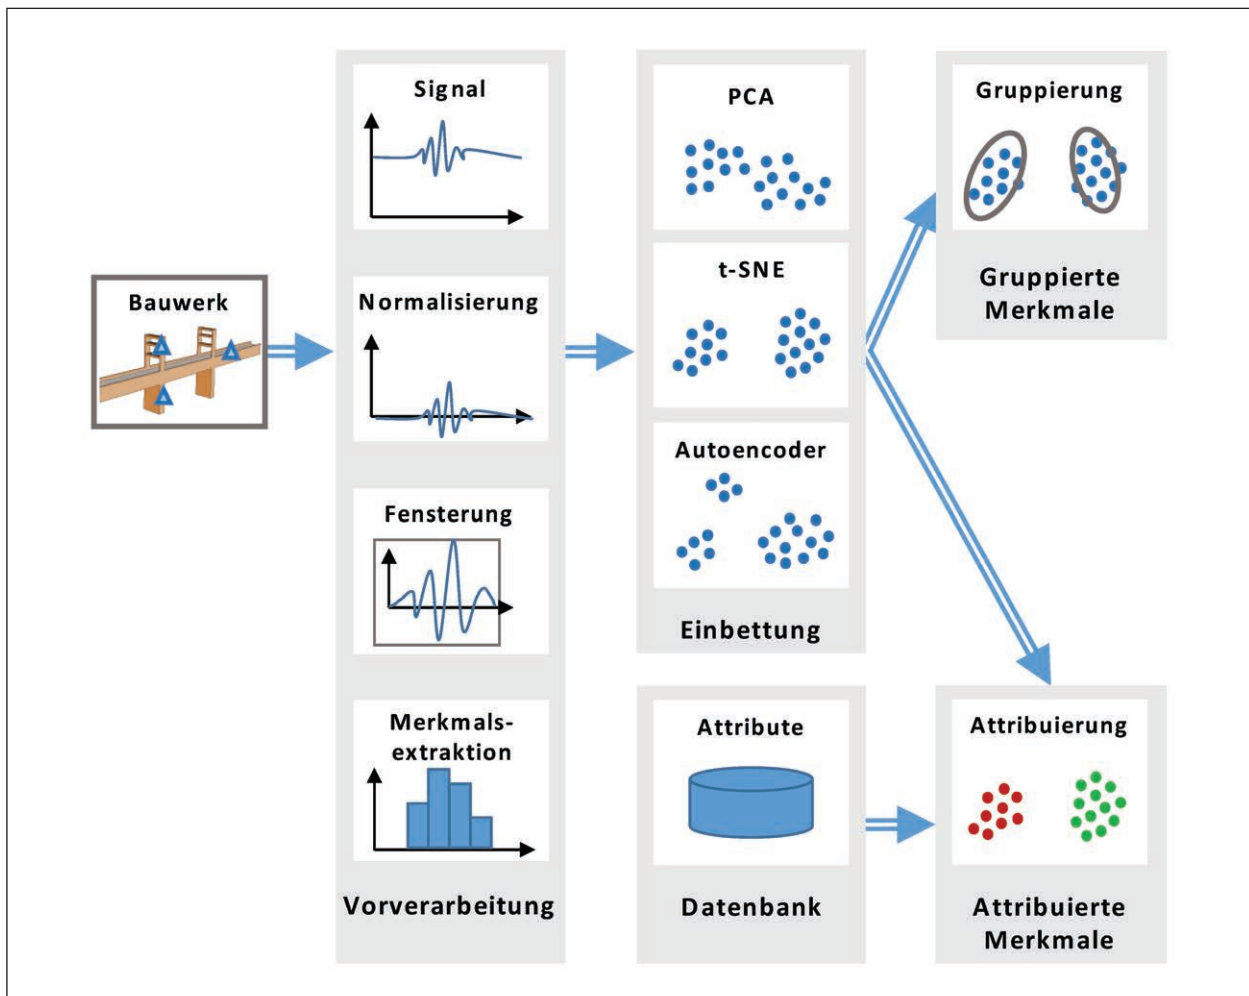


Bild 39: Schematische Darstellung des Ablaufs der algorithmisch Unterstützten Sensordatenanalyse

5.2.1 Datenerfassung

Zunächst müssen die Sensordaten an dem Brückenbauwerk erfasst werden. Hierfür muss an dem Bauwerk ein Sensornetzwerk installiert sein, das eine synchrone Erfassung der Messdaten oder zumindest deren nachträgliche Synchronisierung ermöglicht. Außerdem sollte dieses Sensornetzwerk die erfassten Daten für die weitere Verarbeitung zwischenspeichern und schließlich weiterleiten. Hierbei ist wichtig, dass die Daten in ein einheitliches Format mit gemeinsamer Zeitbasis überführt werden.

Im Folgenden wird davon ausgegangen, dass von dem Sensornetzwerk verschiedene unabhängige eindimensionale Signale erfasst werden, die dann für die algorithmische Weiterverarbeitung zur Verfügung stehen. Natürlich ist anzunehmen, dass die erfassten Signaldaten aufgrund der beobachteten

physikalischen Prozesse Ähnlichkeiten aufweisen. Unabhängigkeit bedeutet in diesem Fall daher, dass die auf die Signale wirkenden Störeinflüsse nicht voneinander abhängen. Wenn die Störsignale als stochastische Prozesse aufgefasst werden, heißt das, dass diese als stochastisch unabhängig aufzufassen sind. Ein Gegenbeispiel hierfür wären zweidimensionale Bilddaten, bei denen die einzelnen Kanäle aufgrund der Erfassung mit dem gleichen Bildsensor voneinander abhängen.

5.2.2 Vorverarbeitung

In einem ersten Verarbeitungsschritt nach der Sensordatenerfassung findet eine Vorverarbeitung der Sensordaten statt, deren Ziel die Generierung von aussagekräftigen Merkmalen für die weitere Verarbeitung mit den Verfahren des unüberwachten Lernens ist.

5.2.2.1 Allgemeine Aspekte der Merkmalsextraktion für die Signalanalyse

Ein Merkmal beschreibt markante Eigenschaften von Teilsequenzen eines untersuchten Signals, die dann in einem als Merkmalsdeskriptor bezeichneten Vektor zusammengefasst werden können. Die Motivation für die Verwendung von Merkmalen anstatt des Originalsignals ist, dass die Ereignisse oder Prozesse, für deren Untersuchung Sensoren installiert werden, oftmals nur sporadisch auftreten und daher bei einem typischen Signalverlauf über lange Zeit hinweg nur die Störeinflüsse eines Rauschprozesses gemessen werden.

Beispielsweise bedingen Fahrzeugüberfahrten auf Brückenbauwerken Bauwerksreaktionen, die bei an dem Tragwerk befestigten Dehnungs- und Kraftsensoren üblicherweise zu starken Ausschlägen führen. Der Signalverlauf in der Nähe dieser Ausschläge kann neben Informationen über die überfahrenden Fahrzeuge auch Informationen über den Bauwerkszustand beinhalten.

Die Datenreduktion durch diese Beschränkung auf „interessante“ Teile eines Signalverlaufs führt üblicherweise zu einer deutlichen Verringerung von Rechenaufwand und Speicherbedarf. Dies gilt natürlich nur, wenn die als „interessant“ eingestufteten Teilsequenzen insgesamt einen kleinen Anteil an den Signaldaten haben.

Allerdings besteht bei der Verwendung von Merkmalen auch die Gefahr, dass eine systematische Verzerrung (Bias) eingeführt wird. Dies ist der Fall, wenn bei der Auswahl von interessanten Teilsequenzen solche, die von einer bestimmten Gruppe von Ereignissen herrühren, nicht beachtet werden. Bei dem Beispiel der Fahrzeugüberfahrten könnte dies geschehen, wenn nur um die Überfahrten von schweren Lastkraftwagen herum Merkmale generiert werden. Die Informationen, die eventuell nur in den Bauwerksreaktionen von leichteren Fahrzeugen vorhanden sind, gehen dann verloren.

Für die Gewinnung aussagekräftiger Merkmale müssen daher zunächst die „interessanten“ Stellen in einem Signal bestimmt werden. Diesen Schritt bezeichnet man auch als Merkmalsdetektion. Um diese Stellen herum wird dann eine Teilsequenz des betrachteten Signals ausgeschnitten, die die benötigten Informationen enthält. Dieser Schritt wird als Fensterung bezeichnet. Vor der weiteren Verarbeitung können die zu den Fenstern gehörenden Teil-

sequenzen normalisiert werden, beispielsweise indem der Median des Signals über das Fenster abgezogen wird, oder indem das Fenster mit der Standardabweichung skaliert wird. Diese Normalisierung ist jedoch optional und hängt auch davon ab, welche Phänomene untersucht werden und welche Algorithmen später in der Verarbeitungskette eingesetzt werden. Schließlich werden auf den extrahierten Fenstern die eingangs erwähnten Merkmalsdeskriptoren berechnet, die alle relevanten Informationen einer Teilsequenz enthalten sollten. Im einfachsten Fall besteht ein solcher Merkmalsdeskriptor nur aus dem ausgeschnittenen Signal, ohne dass eine weitere Transformation darauf angewandt wird. Dies hat den Vorteil, dass alle in dem Fenster vorhandenen Informationen für die spätere Verarbeitung zur Verfügung stehen. Allerdings werden so unter Umständen viele redundante Informationen extrahiert und es ist für die in der Verarbeitungskette folgenden Algorithmen eventuell nicht möglich, aus dem reinen Signalverlauf charakteristische Eigenschaften zu extrahieren, anhand derer eine Gruppierung oder Korrelation mit anderen Signalen durchgeführt werden kann. Ein Ansatz, um die Redundanz der Merkmalsdeskriptoren zu verringern und dabei die Daten erheblich zu komprimieren ist, bei der Deskriptorberechnung auf einfache Statistiken, wie Mittelwert, Median, Standardabweichung oder die Anzahl von Gipfelstellen zurückzugreifen. Für die Gewinnung charakteristischer, aussagekräftiger Merkmale bietet sich die Transformation eines Signals in eine neue Darstellungsform an, in der die gesuchten Eigenschaften besonders hervortreten. Für die Analyse von Schwingungsmustern könnte dies beispielsweise durch eine diskrete Fourier-Transformation (DFT) erfolgen, die mit dem FFT-Algorithmus effizient berechnet werden kann. Alternativ bietet sich auch die Verwendung von Wavelets an, die mit der diskreten Wavelet Transformation bestimmt werden können. Wavelets haben den Vorteil, dass sie im Gegensatz zu den bei der Fourier-Transformation verwendeten Basisfunktionen lokalisiert sind und somit neben Frequenzinformationen auch Ortsinformationen enthalten. [37] gibt einen Überblick über verschiedene Methoden zur Bestimmung von Deskriptoren mit deren Vor- und Nachteilen, speziell für die Frequenzanalyse.

5.2.2.2 Merkmalsdetektion und Fensterung für Brückenbauwerke

Für die Analyse von an Brückenbauwerken erhobenen Signalen hat sich eine einfache heuristische Herangehensweise zur Detektion und Extraktion von Merkmalen als zweckmäßig erwiesen. Hierbei werden die Signale zunächst einer gleitenden Medianfilterung unterzogen. Dabei wird von jedem Messwert der Median aller Messwerte aus einem Fenster um diesen herum abgezogen. Dieser kann rekursiv berechnet werden wobei die Dauer eines Verarbeitungsschrittes bei naiver Implementierung logarithmisch von der Fensterlänge abhängt. Diese erste Medianfilterung dient dazu, die Einflüsse sich zeitlich langsam verändernder Prozesse herauszurechnen. Dabei wurden gute Erfahrungen mit einer Fensterlänge von ca. 10 Minuten gemacht. So können beispielsweise bei Dehnungsmessungen die kurzzeitigen Signalverläufe aufgrund von Fahrzeugüberfahrten um die sich langsam ändernden Temperatureinflüsse bereinigt werden, wodurch es möglich wird, zeitlich weiter auseinander liegende Signalausschnitte zu vergleichen.

Nach erfolgter Medianfilterung werden lokal-dominante Maxima in dem gefilterten Signal bestimmt. Ein lokal-dominantes Maximum ist dabei ein Maximum, das alle anderen Maxima in einer bestimmten Umgebung überragt, und einen Schwellwert überschreitet. Die Berechnung dieser lokal-dominanten Maxima erfolgt durch Vergleich der Messwerte mit einem gleitenden Maximum und kann ebenfalls rekursiv durchgeführt werden. Der Schwellwert für die Detektion relevanter Merkmale legt die minimale Höhe eines lokalen Maximums fest und wird anhand eines kurzen Beispieldatensatzes für jeden Sensor individuell festgelegt, bevor die eigentliche Verarbeitung von Messdaten beginnt. Als zweiter Schwellwert muss vor der Verarbeitung der Mindestabstand zwischen lokal-dominanten Maxima definiert werden. Gute Ergebnisse konnten hier erzielt werden, wenn dieser etwa auf die Länge der extrahierten Fenster gesetzt wurde.

Nachdem die Merkmale an Stellen lokal-dominanter Maxima detektiert wurden, erfolgt die Fensterung, indem Teilsignale symmetrisch um die Maxima herum ausgeschnitten werden. Hierfür wird die Fenstergröße im einfachsten Fall so gewählt, dass die erwartete Dauer der Überfahrt eines Sattelzuges an einem Punkt der Fahrbahn in dem Fenster enthalten ist. Allerdings hat sich gezeigt, dass die so festgelegten Fenstergrößen bei manchen Sensoren nicht ausreichen, um ausreichend hoch auf-

gelöste Spektren zu erhalten. Daher wurde ergänzend ein Verfahren zur automatischen Bestimmung der Fenstergrößen entwickelt, das auf einer Skalensraumanalyse der untersuchten Signale beruht. Wichtig ist, dass die Fensterextraktion hier auf dem originalen, ungefilterten Signal erfolgt und nicht auf dem zur Detektion interessanter Stellen verwendeten gefilterten Signal.

Optional erfolgt nach der Fensterung eine Normalisierung, beispielsweise durch Abziehen des Median oder Division durch die Standardabweichung der Fensterwerte.

5.2.2.3 Merkmalsextraktion für Brückenbauwerke

Nach der im vorigen Kapitel beschriebenen Extraktion von Signalfenstern werden auf diesen Deskriptoren berechnet, die die für die weitere Verarbeitung benötigten Informationen aus dem Signalfenster herausstellen sollen, d. h. in eine Form überführen sollen, mit der die folgenden Algorithmen gut zu recht kommen. Da bei der Bauwerksanalyse die Untersuchung des Schwingungsverhaltens von Bauwerken eine wichtige Rolle spielt (vgl. beispielsweise [38]), wird hierfür eine diskrete Fourier-Transformation eingesetzt, die mit dem FFT-Algorithmus effizient berechnet werden kann (siehe [39]).

Ein wichtiger Aspekt bei der Berechnung der diskreten Fourier-Transformation ist die Verwendung geeigneter Fenstergrößen. Einerseits sollten die Fenster die Signalverläufe von Bauwerksreaktionen aufgrund bestimmter Ereignisse, wie z. B. Überfahrten von Sattelzügen, enthalten. Andererseits sollte auch eine bestimmte spektrale Auflösung erreicht werden, sodass alle Eigenfrequenzen, die in der Bauwerksreaktion angeregt werden, erfasst werden. Da die spektrale Auflösung antiproportional zu der verwendeten Fenstergröße und proportional zu der Abtastfrequenz des Sensors ist, erfordern höhere spektrale Auflösungen auch größere Fenster. Insgesamt wird daher das Maximum der Anzahl Samples, die für die Erfassung der relevanten Ereignisse, und der Anzahl der Samples, die für die Erreichung einer vorgegebenen spektralen Auflösung erforderlich sind, als Fenstergröße verwendet. Erste Untersuchungen legen den Schluss nahe, dass eine spektrale Auflösung von 0,5 Hz ausreichend ist, um aussagekräftige Merkmale zu erhalten.

Da die in diesem Projekt untersuchten Signale reellwertig sind, sind die berechneten Spektren symme-

trisch zum Ursprung. Außerdem sind die Spektren aufgrund der enthaltenen Phaseninformation komplexwertig. Für die weitere Verarbeitung werden daher nur die Beträge der einseitigen Amplitudenspektren für positive Frequenzen verwendet, wodurch die Phaseninformation verloren geht. Die einzelnen Amplitudenspektren werden schließlich normiert, indem alle Werte durch die maximale Amplitude geteilt werden. Dadurch soll erreicht werden, dass sich ähnlich geformte Spektren unabhängig von der Signalstärke auch in ihren Amplituden ähneln.

Da die Fenstergröße in Abhängigkeit der Abtastrate so bestimmt wird, dass eine gewünschte spektrale Auflösung erreicht wird, und die Abtastraten je Sensor von Datensatz zu Datensatz etwas variieren, sind die berechneten Spektren nicht unbedingt auf dem gleichen Frequenzbereich definiert. Um die spätere Verarbeitung zu vereinfachen, wird daher im Anschluss an die Berechnung der Spektren eine Anpassung der Spektren auf einen einheitlichen Definitionsbereich durchgeführt, wodurch sich für jeden Sensor Spektren einheitlicher Länge ergeben.

Die im Rahmen dieses Projektes untersuchten Messwerte der Beschleunigungssensoren der Fahrbahnübergangskonstruktion zeichnen Daten mit einer Abtastrate von etwa 2.500 Hz auf. Bei einer gewünschten spektralen Auflösung von 0,5 Hz ergeben sich somit Spektren mit insgesamt etwa 5.000 Einträgen.

Da davon auszugehen ist, dass ein Großteil der in den Spektren enthaltenen Informationen redundant ist, kann es sinnvoll sein, eine Reduktion der Daten auf die wesentlichen Komponenten vorzunehmen. Dies hat den Vorteil, dass alle darauffolgenden Rechenschritte beschleunigt werden. Außerdem können dadurch die Unterschiede zwischen verschiedenen, in den Signalen enthaltenen Mustern unter Umständen verstärkt werden, was bei einer späteren Gruppierung hilfreich sein kann (siehe Kapitel 5.2.4). Hier wurden zwei Verfahren zur Datenreduktion eingesetzt: Pooling und Hauptkomponentenanalyse (Principal Component Analysis, PCA).

Beim Pooling werden aufeinanderfolgende Spektralbereiche aggregiert und durch den aggregierten Wert ersetzt. Als Aggregatfunktion wurde in diesem Projekt hauptsächlich das Maximum verwendet, und zwar über drei bis fünf aufeinanderfolgende Amplitudenwerte. Insgesamt wird die Länge des Merkmalsvektors so um den Faktor drei bis fünf reduziert. Die

Aggregation führt neben der Dimensionsreduktion auch zu einer erhöhten Robustheit gegenüber kleinen Verschiebungen des Spektrums.

Im Anschluss an das Pooling kann eine weitere Reduktion der Datenmenge durch Hauptkomponentenanalyse (PCA) erreicht werden. Dabei handelt es sich um ein Verfahren zur Datenkompression, bei dem die wesentlichen informationstragenden Richtungen im Merkmalsraum durch eine Eigenwertzerlegung der Kovarianzmatrix bestimmt werden. Die einzelnen Merkmale werden dann auf die Eigenvektoren zu den größten Eigenwerten projiziert, wodurch sich die Dimensionsreduktion ergibt. Diesem Verfahren liegt die Annahme zugrunde, dass die kleinen Eigenwerte den Rauschkomponenten des Signals entsprechen.

Voraussetzung für das Pooling ist eine weitere Normalisierung der Merkmalsvektoren. Üblicherweise werden diese dabei standardisiert, indem der Mittelwert abgezogen wird und komponentenweise durch die Standardabweichung geteilt wird. Für Spektren wird gelegentlich vorgeschlagen, lediglich die Mittelwerte abzuziehen. Dieser Ansatz wurde auch in diesem Projekt verfolgt.

5.2.3 Einbettung

Das Ziel dieses Verarbeitungsschrittes ist es, die zuvor bestimmten Merkmalsdeskriptoren so zu transformieren, dass die darin enthaltene Struktur von den im nächsten Schritt folgenden Gruppierungsmethoden gut erkannt werden kann. Weil die Leistungsfähigkeit vieler Gruppierungsmethoden abnimmt, je größer die Dimension der Eingangsdaten ist (vgl. [40]), sollte vorher eine Dimensionsreduktion stattfinden.

Bei dem hier vorgestellten Konzept zur algorithmisch unterstützten Signalanalyse ist es zudem wichtig, dass die der späteren Gruppierung zugrundeliegende Struktur auch für den bearbeitenden Ingenieur sichtbar ist. Für die dafür notwendige Visualisierung der Daten ist eine Transformation in den zwei- oder dreidimensionalen Raum erforderlich. Hier wurde eine Transformation in den zweidimensionalen Raum durchgeführt.

Im Unterschied zu der Dimensionsreduktion bei der Merkmalsreduktion aus Kapitel 5.2.2.3 steht hier also nicht die Trennung von Nutzsignal und Rauschen im Vordergrund, sondern die Hervorhebung und Sichtbarmachung der in den Daten verborgenen Zusammenhänge. Trotzdem wird die hier auch

bei der Merkmalsextraktion verwendete Hauptkomponentenanalyse häufig Algorithmen zur Gruppierung, besonders dem K-means Algorithmus, vorgeordnet. Dies kann mit einer engen systematischen Verbindung zwischen den beiden Verfahren begründet werden [41].

Die Hauptkomponentenanalyse ist dadurch limitiert, dass es sich um ein lineares Verfahren handelt. Dies erschwert die Gruppenbildung im darauffolgenden Schritt, wenn die Zusammenhänge nicht-linearer Natur sind. Ein nicht-lineares Einbettungsverfahren, das sich in jüngster Zeit großer Beliebtheit für die Visualisierung hochdimensionaler Daten erfreut, ist t-SNE (t-Distributed Stochastic Neighbor Embedding, siehe [42]). Der Grundgedanke hierbei ist, hochdimensionale Merkmalsvektoren so in den niedrigerdimensionalen Zielraum abzubilden, dass sich über Paare von Merkmalen definierte Wahrscheinlichkeitsdichten ähneln. Im niedrigdimensionalen Raum wird dabei eine Wahrscheinlichkeitsdichte angenommen, die größere Abstände zwischen Punkten erlaubt. Dadurch werden die Nachbarschaftsbeziehungen zwischen den Datenpunkten im hochdimensionalen Raum bei der Abbildung in den niedrigerdimensionalen Raum gut erhalten. Deshalb ist t-SNE besonders für die Einbettung in zwei- und dreidimensionale Räume geeignet, wodurch es sich für das hier präsentierte Konzept für die interaktive Sensordatenanalyse besonders empfiehlt. Ein Nachteil von t-SNE ist, dass die für eine bestimmte Punktmenge bestimmte Abbildung nicht ohne weiteres auf neue Punkte angewandt werden kann.

Autoencoder sind ein weiteres Verfahren des unüberwachten Lernens, das eine Datenkompression mit Dimensionsreduktion durchführt (siehe

[43]). Dieses Verfahren basiert auf mehreren Schichten eines neuronalen Netzwerkes, das darauf trainiert wird, die als Eingabedaten vorgegebenen Merkmalsvektoren zu reproduzieren. Die komprimierten und dimensionsreduzierten Merkmale sind nach dem Lernvorgang in einer Schicht des Netzes kodiert. Durch die Verwendung mehrerer Schichten können so auch nicht-lineare Zusammenhänge abgebildet werden.

5.2.4 Gruppierung

Bei der Gruppierung sollen die zuvor in den zweidimensionalen Raum eingebetteten Merkmale automatisch in verschiedene Gruppen eingeteilt werden. Dabei wird jedem der eingebetteten Merkmale ein Gruppenindex so zugeordnet, dass einander ähnliche Merkmale zu einer gemeinsamen Gruppe gehören. Dadurch wird die in den Daten vorhandene Struktur aufgedeckt und steht für die Auswertung zur Verfügung. Wenn bei dem Gruppierungsschritt beispielsweise drei klar abgetrennte Gruppen erkannt werden, legt dies die Vermutung nahe, dass drei unterschiedliche Prozesse abgelaufen sind, die diese Struktur erzeugt haben. Außerdem kann die zuvor erzeugte Einbettung mit Hilfe der Gruppierung bewertet werden, indem überprüft wird, inwiefern sie tatsächlich zu scharf abgetrennten Gruppen geführt hat.

Ein Standardverfahren zur Gruppierung, das häufig in Kombination mit PCA eingesetzt wird, ist k-means, siehe [23]. Hierbei werden die Eingabevektoren k Gruppenzentren so zugewiesen, dass die quadratischen Abweichungen zwischen den Eingabevektoren und den Gruppenzentren minimal ist. Die Anzahl der Gruppen muss dem Algorithmus




Bild 40: k-means




Bild 41: DP-means




Bild 42: DBSCAN

Bilder 40 – 42: Ergebnisse der Gruppierung eingebetteter Merkmalsvektoren mit verschiedenen Verfahren. Die Farben kodieren die Gruppenzuordnung.

als Parameter mitgegeben werden, wodurch sich der Name k-means erklärt.

Eine Variante von k-means, bei der die Anzahl der Gruppen nicht im Voraus bekannt sein muss, ist Dirichlet-Process means (DP-means, siehe [44]). Dieses Verfahren basiert auf der Annahme, dass die Merkmalsvektoren einer Gaußmischverteilung entstammen, deren Gewichte wiederum Dirichlet-verteilt sind. So kann ein iteratives Gruppierungsverfahren hergeleitet werden, das k-means ähnelt, abgesehen davon, dass bei der Iteration neue Gruppen erstellt werden, sobald der Abstand eines Merkmalsvektors zu der nächsten Gruppe einen Strafparameter λ überschreitet. Da neue Gruppen während des Ablaufs des DP-means Algorithmus erstellt werden, muss deren Anzahl nicht zu Beginn festgelegt werden. Allerdings muss ein Wert für den Strafparameter λ vorgegeben werden.

Sowohl k-means als auch DP-means modellieren die Clusterentstehung durch Sampling (zufälliges ziehen einer Stichprobe) aus einer Gaußmischverteilung. Daher eignen Sie sich besonders für die Gruppierung von Merkmalsvektoren, deren geometrische Lage im Merkmalsraum ungefähr durch kugelförmige Anhäufungen gegeben ist. Im Gegensatz hierzu macht der DBSCAN-Algorithmus (Density-based spatial clustering of applications with noise, siehe [45]) keine a-priori Annahmen über die geometrische Lage der Merkmalsvektoren. Stattdessen werden bei diesem Verfahren Merkmalsvektoren, in deren Nachbarschaft viele weitere

Merkmalsvektoren liegen, zu Clustern zusammengefasst und einzelne Merkmalsvektoren ohne Nachbarn als Ausreißer markiert.

5.2.5 Attribuierung

Bei der Attribuierung werden die eingebetteten Merkmalsvektoren anhand von weiteren Datenquellen, beispielsweise der Temperatur oder Verkehrslasten, eingefärbt. Dies soll den bearbeitenden Ingenieur Hinweise darauf geben, welcher Prozess für die Bildung bestimmter Cluster verantwortlich ist. Bild 43 bis Bild 46 zeigen die Einfärbung von eingebetteten Merkmalsvektoren nach verschiedenen Attributen. Die für die Einfärbung verwendeten Attribute können entweder aus den vorhandenen Daten algorithmisch abgeleitet werden oder sie werden aus einer weiteren Datenbank gelesen. Die Zuordnung der Attribute zu den eingebetteten Merkmalsvektoren erfolgt über Zeitstempel. Daher ist eine ausreichende Zeitsynchronisierung für diesen Schritt wichtig.

Da die Gruppierung der Daten in Kapitel 5.2.4 im Gegensatz zu der Einfärbung mit Attributen ausschließlich aufgrund der Sensorsignale erfolgt, ergänzen sich die beiden Verfahren. Ein Vergleich der bei der Gruppierung identifizierten Gruppen mit den Einfärbungen aufgrund der Attribute kann Hinweise darauf geben, welche Attribute tatsächlich mit einer charakteristischen Veränderung in den untersuchten Signalen zusammenhängen.




Bild 43: Merkmale nach Einbettung




Bild 45: Einfärbung nach Wochentag




Bild 44: Einfärbung nach Temperatur




Bild 46: Einfärbung nach Verkehrsdichte

Insgesamt kann so beispielsweise die Identifikation von Sensoren, die am besten zur Vorhersage von Ereignissen geeignet sind, unterstützt werden.

Vor der Bearbeitung einer bestimmten Aufgabenstellung können zunächst in einer Lernphase aus einer großen Menge an Eingabedaten Stichproben gezogen werden, die für die Berechnung der Hauptkomponenten sowie der Abbildung für die Einbettung verwendet werden. Wenn anschließend ein konkretes Ereignis untersucht werden soll, müssen auf den zugehörigen Eingabedaten, deren Umfang in der Regel deutlich geringer sein wird als in der Lernphase, lediglich neue Merkmale extrahiert werden, die dann mit der vorberechneten Abbildung eingebettet werden. Dann kann die Attribuierung entsprechend den für die Aufgabenstellung benötigten Zusatzinformationen erfolgen. Durch diese Vorberechnung in der Lernphase können unterschiedliche Szenarien untersucht werden, ohne die zeitaufwändigen Berechnungen der Lernphase jedes Mal erneut durchzuführen, wodurch die der Arbeitsablauf beschleunigt wird.

Für die Berechnung der Zwischenergebnisse in den verschiedenen Verarbeitungsschritten können jeweils unterschiedliche Algorithmen mit spezifischen Vor- und Nachteilen eingesetzt werden. Je nach Aufgabenstellung ist eventuell eine bestimmte Kombination von Algorithmen für die Analyse vorzuziehen. Daher ist es ratsam, die einzelnen Verarbeitungsschritte letztendlich in austauschbaren Schichten zu organisieren, sodass es einfacher wird verschiedene Varianten durchzuspielen bis eine geeignete Kombination von Algorithmen gefunden wurde.

5.2.6 Kombinierte Auswertung mehrerer Sensorsignale

Die Ergebnisse der Auswertung einzelner Sensorsignale können als Ausgangspunkt für die kombinierte Analyse mehrerer Signale dienen. Falls die Sensoren komplementäre Aspekte des Bauwerksverhaltens abbilden, können durch die kombinierte Auswertung zusätzliche Informationen abgeleitet werden. Andernfalls ermöglicht die kombinierte Auswertung mehrerer Sensoren zumindest noch eine Reduktion der Ungenauigkeiten durch Ausnutzen der Korrelationen zwischen den Signalen. Die im Rahmen dieses Projektes gewählte Herangehensweise dient eher der Extraktion zusätzlicher Informationen.

Bild 47 stellt die in diesem Projekt gewählte Herangehensweise für die kombinierte Auswertung mehrerer Sensorsignale vor. Die Verarbeitung lässt sich in drei Schritte aufteilen, die voneinander abhängen und in Bild 47 zeilenweise dargestellt sind. Jede der drei Zeilen beschreibt die Schritte, die zur Generierung eines Zwischenergebnisses (erste und zweite Zeile) oder des Endergebnisses (unterste Zeile) durchgeführt werden. Da das Endergebnis von den Ergebnissen der beiden anderen Verarbeitungssequenzen abhängt, werden die Schritte aus der untersten Zeile zuletzt ausgeführt. Umgekehrt werden die Ergebnisse der Gruppierung in den anderen Zeilen verwendet, weshalb die Schritte der zweiten Zeile zuerst durchgeführt werden.

Als Eingabe dienen in jedem Fall die in verschiedenen Zeitabschnitten extrahierten Merkmale. Die Merkmalsextraktion verläuft dabei ganz analog zu dem Vorgehen aus Kapitel 5.2.2, das auch für die Untersuchung einzelner Sensorsignale verwendet wird. Am Anfang stehen daher die Detektion interessanter Signalausschnitte und die Berechnung von Merkmalen auf geeignet gewählten Fenstern.

Im ersten Schritt (zweite Zeile in Bild 47) erfolgt dann die Einbettung (Dimensionsreduktion) mit anschließender Gruppierung, wie bereits in Bild 39 dargestellt. Für die Berechnung der Einbettung und der Gruppierung haben sich das t-SNE-Verfahren und der DBSCAN-Algorithmus als besonders geeignet erwiesen. Durch die Gruppierung werden automatisch Muster in den für einzelne Sensoren extrahierten Merkmalen erkannt und die Merkmale werden entsprechend gekennzeichnet. Da hierfür kein Vorwissen notwendig ist, entspricht dies einem unüberwachten Lernverfahren. Die Ergebnisse der Gruppierung werden dann in den darauffolgenden Arbeitsschritten wiederverwendet, um die extrahierten Merkmale direkt einer der zuvor identifizierten Gruppen zuzuordnen, ohne eine erneute Einbettung und Gruppierung durchzuführen. Zu diesem Zweck werden die Kennzeichnungen der Merkmale aus der Gruppierung verwendet, um einen Klassifikator zu trainieren. Mit diesem können dann die in den folgenden Schritten extrahierten Merkmale einer der zuvor identifizierten Gruppen zugeordnet werden. Hierfür wird ein Nearest-Neighbor-Klassifikator mit Nachbarschaftsgröße fünf verwendet, siehe [23]. Somit können die Ergebnisse des unüberwachten Lernverfahrens durch Verwendung eines überwachten Lernverfahrens wiederverwendet werden.

Der Klassifikator wird im zweiten Schritt (erste Zeile in Bild 47) verwendet, um die extrahierten Merkmale direkt einer der Gruppen zuzuordnen. Dabei wird den extrahierten Fenstern ein Kennzeichen entsprechend ihrer Gruppenzugehörigkeit zugewie-

sen, siehe Bild 48. Für die spätere Verarbeitung werden diese Kennzeichnungen one-hot-kodiert. Dabei wird die Gruppenzugehörigkeit durch einen Vektor dargestellt, der für jede mögliche in den Sensordaten vorkommende Gruppe einen Eintrag be-

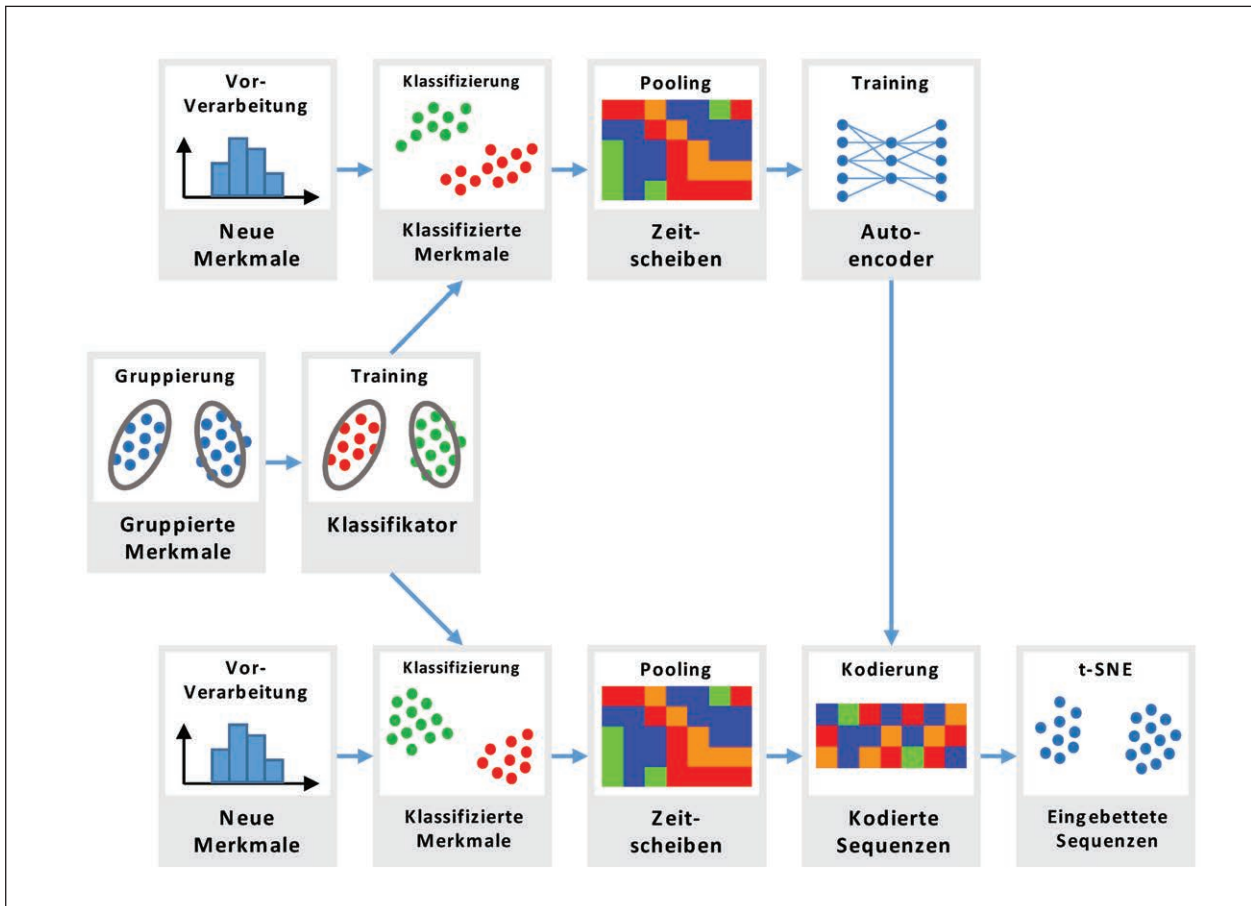


Bild 47: Erweiterung des Gesamtkonzepts zur Sensordatenauswertung für mehrere Kanäle

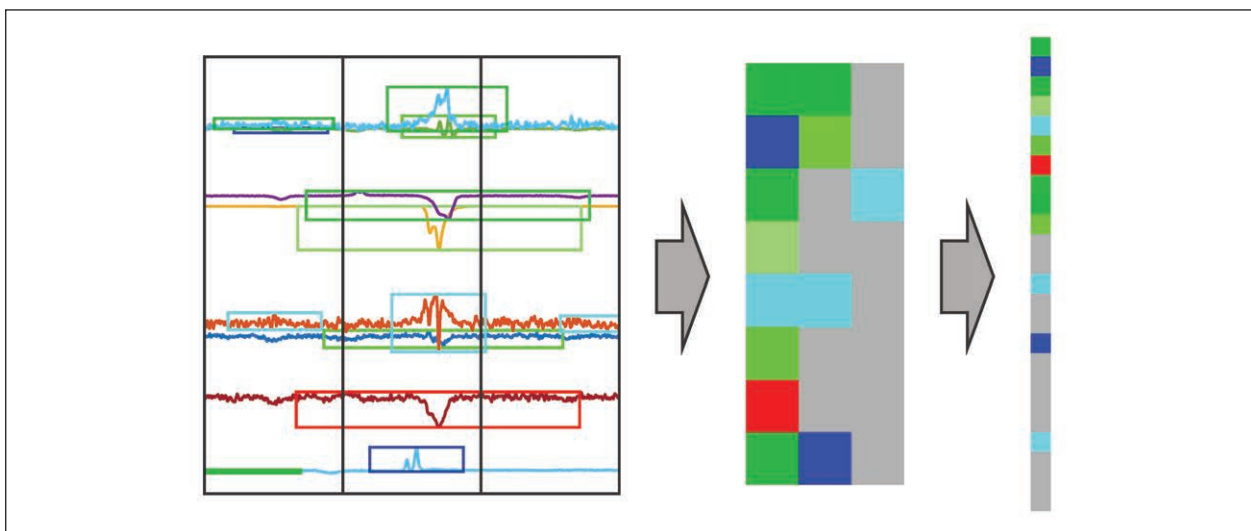


Bild 48: Schematische Darstellung des Pooling-Schrittes: Zuerst werden die Gruppenindizes der in einem Zeitabschnitt detektierten Fenster in Vektoren zusammengefasst. Diese werden dann aneinander gehängt, um längere Sequenzen zu kodieren.

sitzt, der nur die Werte Null oder Eins annehmen kann. Um eine bestimmte Gruppenzugehörigkeit zu kodieren, wird in diesem Vektor an der entsprechenden Stelle eine Eins eingetragen, während alle anderen Einträge zu Null gesetzt bleiben.

Danach werden die von verschiedenen Sensoren stammenden Merkmale zusammengefasst. Hierfür wird die Zeitachse in äquidistante Abschnitte eingeteilt und für jeden dieser Zeitabschnitte ein Vektor erstellt, der wiederum aus aneinander gehängten Vektoren besteht, welche die one-hot-kodierten Gruppenindizes enthalten. Dabei wird für jeden Sensor der Gruppenindex des ersten in dem zugehörigen Zeitabschnitt liegenden Fensters eingetragen. Um auch den Fall, dass in einem Zeitabschnitt kein Fenster erstellt wurde, behandeln zu können, werden die Vektoren, die die Gruppenzugehörigkeit kodieren, um einen Eintrag erweitert, der gewissermaßen die leere Klasse beschreibt. Da bei diesem Vorgehen auf jedem Kanal nur das erste von mehreren Fenstern betrachtet wird, handelt es sich hierbei um ein einfaches Pooling-Verfahren.

Die so erstellten Vektoren kodieren die Gruppenzugehörigkeit der Fenster, die auf allen betrachteten Kanälen in einem bestimmten Zeitabschnitt erstellt wurden. Eine feste Anzahl solcher zu aufeinanderfolgenden Zeitabschnitten erstellten Vektoren wird nun aneinander gefügt. So entstehen Vektoren, die die zeitliche Abfolge von Merkmalen auf mehreren Kanälen beschreiben. Um dabei möglichst alle vorkommenden Sequenzen zu erfassen, werden diese zeitlich überlappend erstellt.

Schließlich werden die auf diese Weise kodierten Informationen über die Abfolge von detektierten Merkmalen auf allen betrachteten Kanälen verwendet, um einen Autoencoder zu trainieren (siehe Kapitel 5.3.4.3). Durch den Autoencoder werden die one-hot-kodierten diskreten Gruppenzugehörigkeiten in eine würfelförmige Untermenge eines niedriger dimensional reellen Vektorraums abgebildet. Der Grundgedanke dabei ist es, so die Verarbeitung durch das t-SNE Verfahren (Kapitel 5.3.4.2) zu unterstützen.

Im letzten Schritt (dritte Zeile in Bild 47) wird der zuvor trainierte Autoencoder verwendet, um neue, one-hot-kodierte Zeitsequenzen in einen niedriger dimensional Vektorraum zu überführen. Die kodierten Sequenzen dienen als Eingabe für die Einbettung in den zweidimensionalen Raum durch das t-SNE-Verfahren. So sollen wiederkehrende,

kanalübergreifende Erregungsmuster, die sich über mehrere Zeitabschnitte erstrecken, aufgedeckt werden.

5.3 Detaillierte Beschreibung der einzelnen Algorithmen

5.3.1 Zuordnung von zu unterschiedlichen Zeitpunkten extrahierten Signalfenstern zu einzelnen Fahrzeugüberfahrten

Bei der Implementierung der Attribuierung mit Fahrspurdetektionen hat sich gezeigt, dass die Signale unterschiedlicher Sensoren zum Teil zeitverschoben zueinander sind. Die Ursache hierfür ist vermutlich, dass die Sensoren an unterschiedlichen Stellen längs der Fahrbahn angebracht sind, sodass sie von den Fahrzeugen zu unterschiedlichen Zeitpunkten passiert werden. Da Fahrzeugüberfahrten einen Großteil der Ereignisse ausmachen, für die zu Beginn der in Kapitel 5.2.2 beschriebenen Verarbeitungskette Signalfenster ausgeschnitten werden, sind die Fenster, die zu der Überfahrt eines bestimmten Fahrzeugs gehören, zeitlich etwas zueinander verschoben. Dadurch werden beispielsweise die Ergebnisse der Einfärbung nach Fahrspurdetektionen (siehe Kapitel 5.5.2) beeinträchtigt.

Daher wurde nach einem Verfahren gesucht, mit dem zu unterschiedlichen Zeitpunkten detektierte Ereignisse, die derselben Ursache zugeschrieben werden können, aufeinander abgebildet werden können. Dabei geht es hier vor allem um die Zuordnung von Ereignissen, die von Überfahrten desselben Fahrzeugs an zwei unterschiedlichen Sensoren längs der Fahrbahn herrühren. Dieses Szenario ist in Bild 49 dargestellt. Es wird angenommen, dass der Verkehr auf dem betrachteten Brückenabschnitt gleichmäßig fließt, sodass die Geschwindigkeit der Fahrzeuge hier nahezu konstant ist. Dann sollte der zeitliche Abstand zwischen aufeinanderfolgenden Ereignissen bei beiden Sensoren ungefähr gleich sein. Allerdings muss davon ausgegangen werden, dass sich die durchschnittliche Geschwindigkeit des Verkehrsflusses mit der Zeit ändert, sodass nicht von einer konstanten Verschiebung zwischen den Ereignissen ausgegangen werden kann. Erschwerend kommt außerdem hinzu, dass manche Ereignisse unter Umständen nur in einem der betrachteten Sensorsignale erkannt werden.

Die von zwei Sensoren detektierten Ereignisse können als Knoten in einem bipartiten Graphen aufge-

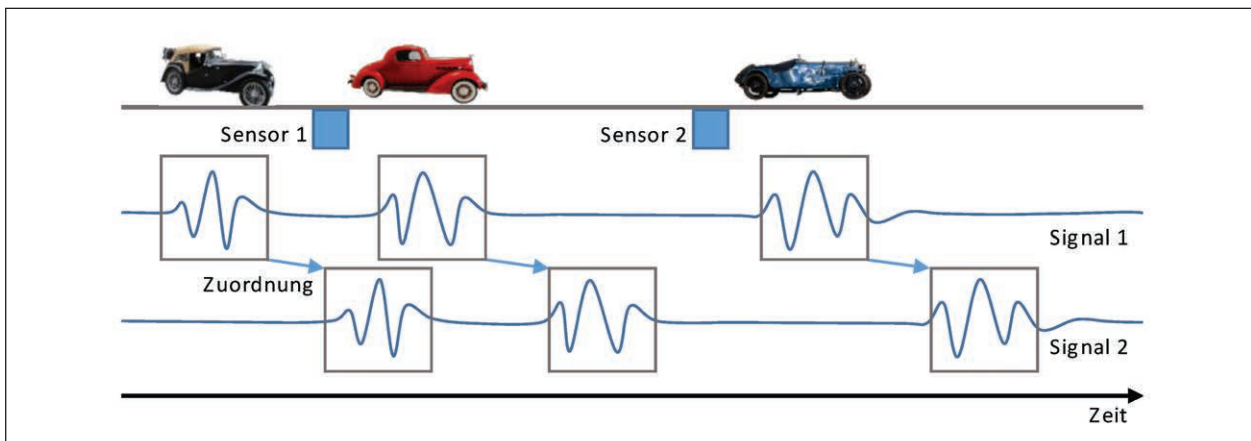


Bild 49: Ereignisse, die von Sensoren längs der Fahrbahn detektiert wurden, müssen einander zeitlich zugeordnet werden

fasst werden. Das Synchronisationsproblem besteht dann darin die Knoten, die zu einem Sensor gehören, den Knoten des anderen Sensors eindeutig zuzuordnen. Dieses Problem wird in der Graphentheorie auch als maximales bipartites Matching bezeichnet (siehe [39]). Allerdings kann bei einfachen Lösungsverfahren für das maximale bipartite Matching nicht berücksichtigt werden, dass die Zuordnung bestimmte Bedingungen erfüllen muss. Eine Möglichkeit solche Bedingungen zu berücksichtigen ist, den Zuordnungen zwischen den Signalen Kosten zuzuweisen und das Matching zu bestimmen, das die Gesamtkosten für alle Zuweisungen minimiert. Dadurch können auch Ausreißer behandelt werden, die beispielsweise daher kommen, dass ein Ereignis von einem der Sensoren nicht erkannt wird, solange die Kosten für eine nicht erfolgte Zuweisung durch geringere Gesamtkosten kompensiert werden. Diese um Zuweisungskosten erweiterte Variante des Matching-Problems heißt auch lineares Zuordnungsproblem (linear assignment problem, siehe [46]) und kann beispielsweise mit dem Jonker-Volgenant Algorithmus gelöst werden.

Aus der hier behandelten Problemstellung ergeben sich folgende Bedingungen:

- Liegt ein Sensor in Fahrtrichtung vor einem anderen Sensor, so müssen die zugewiesenen Ereignisse zeitlich nachfolgen.
- Die einander zugeordneten Ereignisse sollten zeitlich nicht zu weit auseinander liegen.
- Die Zeitdifferenzen zu benachbarten Ereignissen sollten sich bei einander zugewiesenen Ereignissen ähneln.

Anhand dieser Bedingungen können jeder möglichen Zuordnung Kosten zugewiesen werden. Diese Kosten werden in eine Matrix eingetragen, die als Eingabe für den Jonker-Volgenant Algorithmus dient. Für die ersten beiden Bedingungen wird hierbei ein fester Schwellwert definiert, bei dessen Überschreiten der entsprechende Eintrag in der Kostenmatrix auf unendlich gesetzt wird, sodass gewährleistet ist, dass solche unmöglichen Bedingungen ausgeschlossen sind. Für die dritte Bedingung wird jedem auf einem Signal detektierten Ereignis ein Vektor mit den Zeitdifferenzen zu benachbarten Ereignissen zugeordnet. Die euklidische Distanz zwischen diesen Vektoren wird dann in die Kostenmatrix eingetragen.

Bild 50 zeigt das Ergebnis der Zuordnung von anhand der Dehnungsmessstreifen MS17 und MS20 detektierten Fahrspurzuordnungen zu dominanten Maxima des Beschleunigungssignals B3. Die grünen Linien kennzeichnen hier Zuordnungen zwischen Beschleunigungsmaxima und aus den Dehnungsmessungen (MS17) abgeleiteten Überfahrten, während die schwarzen Linien Zuordnungen zwischen Beschleunigungsmaxima und von Sensor MS20 detektierten Überfahrten markieren. In dem mit einem grünen Haken markierten Bereich stimmen die algorithmisch bestimmten Zuordnungen gut mit den Zeitdifferenzen zwischen den Peaks überein, sodass hier davon ausgegangen werden kann, dass die Zuordnungen korrekt sind. Demgegenüber markiert das rote Kreuz einen Bereich, in dem das durch die Abfolge dominanter Peaks definierte Muster durch die Zuordnung nicht erhalten wird. Die Ursache ist hier vermutlich, dass das mit einem roten Kreis markierte Beschleunigungsmaximum nicht zugeordnet wurde, wodurch sich die Zuordnung der nachfolgenden Ereignisse verschiebt.




Bild 50: Ergebnis der Zuordnung von Fahrspurzuordnungen zu dominanten Beschleunigungsmaxima mit dem Jonker-Volgenant Algorithmus

5.3.2 Skalenraumanalyse zur Bestimmung der Fenstergrößen

5.3.2.1 Ziel der Skalenraumanalyse

Die um lokale Maxima herum ausgeschnittenen Fenster sollten die Signalverläufe von Bauwerksreaktionen auf bestimmte Ereignisse, wie Überfahrten von Sattelzügen, enthalten. Wenn angenommen werden kann, dass die Dauer einer Bauwerksreaktion ungefähr der Dauer der entsprechenden Anregung entspricht, und wenn die Anregungsdauer gut abgeschätzt werden kann, erhält man so eine Abschätzung für die Fenstergröße. Somit können beispielsweise die Fenstergrößen für Sensoren, die in Fahrbahnnähe installiert sind, durch die ungefähre Dauer einer Lastwagenüberfahrt abgeschätzt werden.

Allerdings hat sich gezeigt, dass die anhand der Dauer von Überfahrten abgeschätzten Fenstergrößen beispielsweise für Sensoren, die an dem Lager befestigt sind (MS27v, MS28v, MS29v sowie MS30h), zu klein sind, um typische Signalverläufe zu erfassen. Um trotzdem für jeden Sensor eine Abschätzung für die Fenstergröße zu erhalten, wird zunächst eine Abschätzung der charakteristischen Skala auf einem Beispieldatensatz für jeden Sensor bestimmt. Bei der charakteristischen Skala handelt es sich wiederum um eine Heuristik, die mit der typischen Dauer der in einem Signal enthaltenen Strukturen korrespondiert. Das Konzept stammt

aus der Bildverarbeitung und wurde dort ebenfalls für die Extraktion interessanter Strukturen in Bildern entwickelt [47].

Mithilfe der charakteristischen Skalen können die Fenstergrößen für individuelle Sensoren anhand des Verhältnisses bezüglich der charakteristischen Skala eines Referenzsensors geschätzt werden, siehe Kapitel 5.3.2.3.

5.3.2.2 Heuristik zur Bestimmung der charakteristischen Skala

Den in diesem Projekt betrachteten Sensorsignalen soll eine charakteristische Skala zugeordnet werden, die mit der typischen Dauer der von dem Sensor erfassten physikalischen Prozesse verknüpft ist. Hierfür wird auf die in [47] vorgestellte Methode zur Bestimmung einer charakteristischen Skala für charakteristische Bildbereiche zurückgegriffen.

Der Skalenraum ist ein Ansatz, mit dem die Erfahrung, dass unterschiedliche, von Sensoren erfasste physikalische Prozesse oftmals nur in bestimmten Zeitbereichen und Auflösungen erfasst und beschrieben werden können, abgebildet wird. Hierfür wird das Sensorsignal um eine weitere Dimension erweitert, die verschiedene Auflösungen des Signals enthält. Für den Fall eindimensionaler Signale ergibt sich so der zweidimensionale Skalenraum. An einen Skalenraum werden oftmals folgende Anforderungen gestellt:

- Linearität:
Der Skalenraum soll mit einem linearen Filter aus dem Signal abgeleitet werden können.
- Verschiebungsinvarianz:
Bei einer Verschiebung des Signals verschiebt sich der Skalenraum auf die gleiche Weise.
- Beim Übergang von kleinen zu großen Skalen dürfen keine neuen Details hinzukommen.

Unter diesen Bedingungen ist der Skalenraum eindeutig definiert und kann durch Faltung mit einem Gauss-Kernel bestimmt werden:

$$L(t, s^2) = h(t, s^2) * f(t) \quad (40)$$

In obiger Gleichung stellt $L(t, s^2)$ den Skalenraum dar, der durch Faltung eines zeitabhängigen Signals $f(t)$ mit Gausskernen $h(t, s^2)$ verschiedener Varianzen s^2 generiert wird. Je nach Zusammenhang wird manchmal die Varianz s^2 oder die Standardabweichung s als Skalenparameter verwendet.

Weil Ableitungen höherer Ordnung zur Rekonstruktion eines Signals in der Umgebung eines Punktes verwendet werden können, liegt es nahe, diese auch für die Merkmalsdetektion einzusetzen. Daher werden für die Detektion und Beschreibung von Merkmalen in mehrdimensionalen Signalen oftmals Linearkombinationen höherer Ableitungen verwendet, siehe [47], [48]. Dabei stellt sich das Problem, dass die Gradienten mit zunehmender Skala kleiner werden, was eine Konsequenz aus der Forderung ist, dass bei Übergang zu größeren Skalen keine Details hinzukommen dürfen. Deshalb können Maxima, die auf verschiedenen Skalenebenen eines Signals berechnet werden, nicht direkt verglichen werden. Um bei der Merkmalsextraktion trotzdem eine Auswahl der am stärksten ausgeprägten Maxima vornehmen zu können, müssen diese daher entsprechend ihrer Skala normiert werden. Hierfür werden in [47] skalennormalisierte Ableitungen eingeführt:

$$\partial_{norm} = s^2 \partial \quad (41)$$

In Gleichung (41) bezeichnet ∂_{norm} den modifizierten Ableitungsoperator zur Berechnung der skalennormalisierten Ableitungen.

Mit dem modifizierten Ableitungsoperator aus Gleichung (41) können für beliebige, auf Linearkombinationen von Ableitungen basierende Merkmals-

detektoren Skalenraumdarstellungen berechnet werden. Die lokalen Extremstellen in den so berechneten Skalenräumen spiegeln dann die charakteristische Ausdehnung der entsprechenden Strukturen im Signal wider.

Für die Untersuchung von eindimensionalen Signalen wurde hier die zweite Ableitung als Grundlage für die Merkmalsdetektion ausgewählt, woraus bei Anwendung auf den Skalenraum der Laplacian-of-Gaussians (LoG) Detektor entsteht:

$$\begin{aligned} & \frac{\partial^2}{\partial t^2_{norm}} (h(t, s^2) * f(t)) \\ &= \underbrace{\left(\frac{\partial^2}{\partial t^2_{norm}} h(t, s^2) \right)}_{LoG} * f(t) \end{aligned} \quad (42)$$

In Gleichung (42) wird ausgenutzt, dass die Faltungsoperation mit der Differenzierung kommutiert. Durch Ableitung der Gaussglocke entsteht so die Laplacian-of-Gaussian Funktion:

$$LoG(t, s^2) = \frac{\frac{t^2}{s^2} - 1}{s^2 \sqrt{2\pi s^2}} \exp\left(\frac{-t^2}{2s^2}\right) \quad (43)$$

Bild 51 zeigt eine diskretisierte Version des LoG-Operators aus Gleichung (43). Durch Faltung mit solchen Kernen, die mit unterschiedlichen Varianzen erstellt werden, entsteht der Skalenraum zu einem Signal. Bild 52 zeigt exemplarisch die Filterantworten bei der Anwendung des LoG-Filters auf eine Gaussglocke für verschiedene Werte des Parameters s^2 . Hier ist zu sehen, dass aufgrund der charakteristischen Form des LoG-Filters der Betragswert der Filterantwort an der Stelle des Maximums der Gaussglocke ebenfalls maximal ist. Dies gilt für alle Skalen. Ein Vergleich der Filterantworten für verschiedene Filterparameter zeigt, dass das Maxi-




Bild 51: Laplacian-of-Gaussian-(LoG)-Filterkernel ($s^2 = 16$)




Bild 52: Ergebnis der Faltung verschiedener Filterkernel mit einer Gaussglocke ($\sigma^2 = 4$). Die Farbe kodiert den Wert des Parameters s^2 des LoG-Kernels von $s^2 = \sqrt{2}$ (rot) bis $s^2 = 16$ (gelb). Die Filterantwort ist für den Wert $s^2 = 5.66$ maximal.

zum des Betragswertes für einen Parameter angenommen wird, bei dem die Übereinstimmung zwischen der Form des Filterkernels und der Form der Gaussglocke maximal ist. Dies entspricht der charakteristischen Skala dieses Merkmals. Allgemein spricht der LoG-Filterkernel auf ausgedehnte Extremstellen oder Ausschläge im Signal an. Merkmalsdetektoren mit dieser Eigenschaft werden auch Blob-Detektoren genannt.

Die Parameter zur Erzeugung der Filterantwort auf dem Skalenraum werden so gewählt, dass die logarithmischen Abstände zwischen aufeinanderfolgenden Skalen konstant sind. Hierzu wird der zu untersuchende Skalenbereich in Schichten eingeteilt, die jeweils einer Halbierung der Auflösung entsprechen. Diese Schichten werden wiederum je nach gewünschter Genauigkeit weiter in eine feste Zahl von Unterebenen eingeteilt.

Die Formel zur Bestimmung des Parameters für den Kernel zur Berechnung der insgesamt k -ten Skalenebene lautet:

$$s_k^2 = 4^{l+1} \quad (44)$$

In Formel (44) bezeichnet k den Index der Skalenraumebene und l die Anzahl der Ebenen, die einer Halbierung der Auflösung entsprechen.

Anhand Formel (44) können die Filterkernel für verschiedene Skalen bestimmt werden. Die Anwendung dieser Filterkernel auf das zu untersuchende Sensorsignal ergibt eine zweidimensionale diskretisierte Näherung an die Filterantwort auf dem Skalenraum. Die lokalen Maxima der Betragswerte dieser Funktion von zwei Veränderlichen entsprechen




Bild 53: Skalenspace-Darstellung für einen Ausschnitt auf-gezeichneter Daten von Sensor MS27v des RTM Systems (Wegsensor). Rote Kreuze markieren die Maxima im zweidimensionalen Skalenraum.

den detektierten Merkmalen und ihrer Skala. In der Regel werden auf allen Skalenebenen Merkmale erkannt, die Verteilung der Merkmale auf die Skalenebenen variiert jedoch.

Um dem Sensor eine charakteristische Skala zuzuordnen, wird zunächst ein Schwellwert für den Betrag der Maxima der normalisierten LoG-Filterantworten bestimmt. Nur Maxima der Filterantworten, deren Betrag über diesem Schwellwert liegt, werden als signifikant angesehen. Dann werden für jede Skala die Maxima der LoG-Filterantworten, die diesen Schwellwert überschreiten, gezählt. So erhält man die Anzahl signifikanter Maxima der Filterantworten in Abhängigkeit der entsprechenden Skala. Diese Werte werden durch die maximale Zahl der Maxima von Filterantworten über alle Skalen geteilt. Schließlich wird die größte Skala, bei der dieses Verhältnis einen festen Wert, beispielsweise 0,45, überschreitet, als charakteristische Skala angenommen.

Dieses Vorgehen wird in Bild 53 bis Bild 56 illustriert. Bild 53 zeigt den zweidimensionalen Skalenraum mit den detektierten Maxima. Bild 54 zeigt die LoG-Filterantworten für den gleichen Datenausschnitt für verschiedene Skalen. Es ist deutlich zu erkennen, dass die Filterantworten auf höheren Skalen weiter ausgedehnten Strukturen in dem Signal entsprechen, während die Filterantworten auf niedrigen Skalen eher kurzzeitigen Fluktuationen oder Rauschen entsprechen. Bild 55 und Bild 56 zeigen die Anzahl signifikanter Skalenraummaxima in Abhängigkeit der Skala sowie die zugewiesene charakteristische Skala. Die Verteilung der signifikanten Skalenraummaxima über die Skalen unterscheidet sich deutlich zwischen den beiden Sensoren.

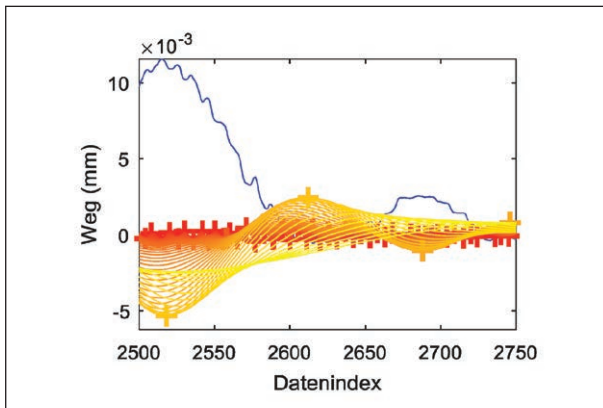


Bild 54: LoG-Filterantwort für den auch im linken Bild dargestellten Datenausschnitt des Wegsensors MS27v. Das Signal ist blau eingezeichnet, die Filterantworten sind entsprechend der Skala von rot (niedrigste Skala) bis gelb (höchste Skala) eingefärbt. Die Kreuze markieren die detektierten Skalenraummaxima.

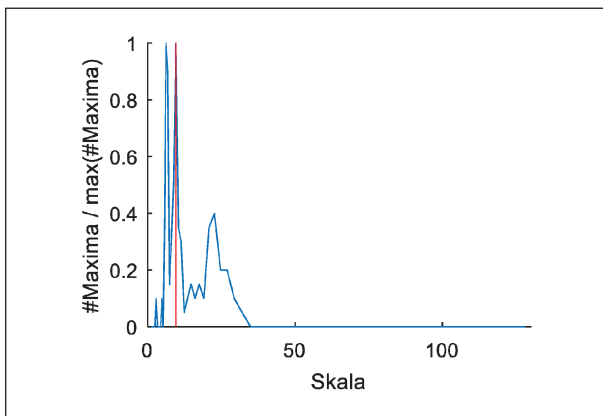


Bild 55: Auswahl der charakteristischen Skala für den Sensor MS7L des RTM Systems (Blau: Anzahl der signifikanten Skalenraummaxima für jede Skala, geteilt durch den Maximalwert. Rot: Zugewiesene charakteristische Skala)




Bild 56: Auswahl der charakteristischen Skala für den Sensor MS27v des RTM Systems (Blau: Anzahl der signifikanten Skalenraummaxima für jede Skala, geteilt durch den Maximalwert. Rot: Zugewiesene charakteristische Skala)

5.3.2.3 Bestimmung der Fenstergröße anhand der charakteristischen Skala

Nachdem die charakteristische Skala für die einzelnen Sensoren anhand eines Beispieldatensatzes geschätzt wurde, siehe Kapitel 3.2.2, erfolgt die Festlegung der Fenstergrößen durch Vergleich der charakteristischen Skalenwerte mit dem für einen als Referenzsensor herausgegriffenen Sensor bestimmten Skalenwert durch Skalierung der für den Referenzsensor gewählten Fenstergröße mit dem Verhältnis der Skalen:

$$\Delta_{Neu} = \frac{s}{s_{Referenz}} \Delta_{Referenz} \quad (45)$$

In Formel (45) sind Δ_{Neu} und $\Delta_{Referenz}$ die anhand des Skalenverhältnisses geschätzte Fenstergröße sowie die für den Referenzsensor festgelegte Fenstergröße. Außerdem bezeichnen s und $s_{Referenz}$ die charakteristischen Skalen des betrachteten Sensors und des Referenzsensors.

Bild 57 zeigt einen Ausschnitt der Sensordaten für zwei verschiedene Sensoren mit den detektierten Fenstern. Hier ist zu sehen, dass die angepassten Fenster besser zu den typischen Signalverläufen der Sensoren passen. Würde die für das blaue Signal gewählte Fenstergröße für das grüne Signal verwendet, würden die Fenster nur einen kleinen Teil der typischen Struktur erfassen. Ein Vergleich der Spektren in Bild 58 und Bild 59 zeigt daher, dass die durch die Verwendung größerer Fenster erhöhte spektrale Auflösung tatsächlich zusätzliche Details hervortreten lässt.




Bild 57: Ergebnis der Fenstergrößenanpassung anhand der charakteristischen Skala. Blaue Linie und durchgezogene Rechtecke: Signal des Dehnungssensors MS17 am Brückenüberbau mit detektierten Fenstern. Grüne Linie mit gestrichelten Rechtecken: Signal des Wegsensors MS27v an einem Lager des Bauwerks und Fenster.




Bild 58: Einseitige Leistungsspektren für Sensor MS27v ohne Anpassung der Fenstergröße (Blau: Auf einzelnen Fenstern berechnete Spektren. Rot: Gemitteltes Spektrum)




Bild 59: Einseitige Leistungsspektren für Sensor MS27v nach Anpassung der Fenstergröße (Blau: Auf einzelnen Fenstern berechnete Spektren. Rot: Gemitteltes Spektrum)

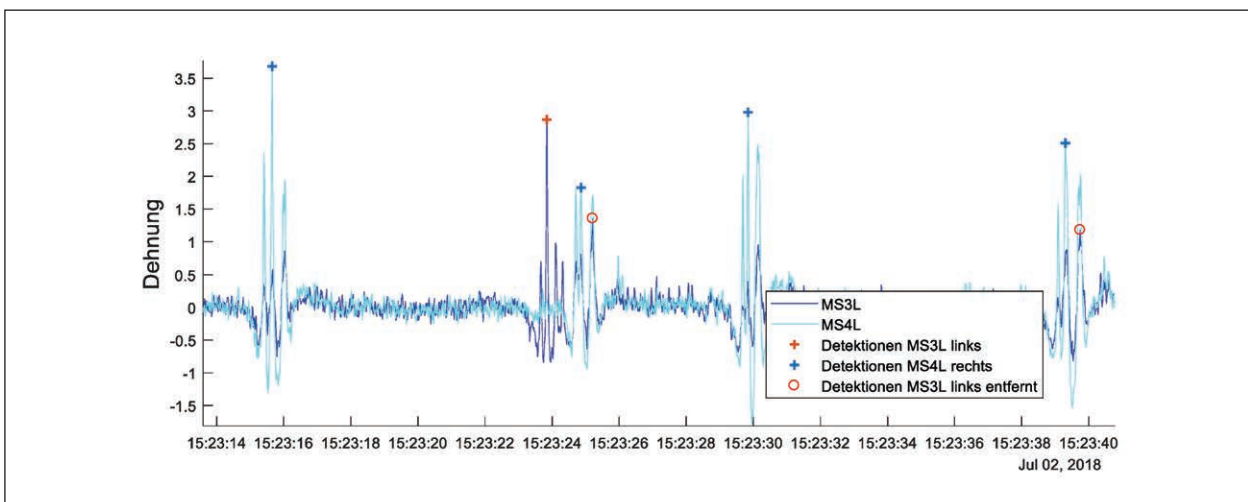


Bild 60: Detektion von Überfahrten und Fahrspurzuordnung mit den Dehnungssensoren MS32 und MS4L des RTM Systems

5.3.3 Fahrspurdetektionen

Ziel der Fahrspurdetektionen ist es, Fahrzeugüberfahrten zu erkennen und zu entscheiden, ob es sich um eine Überfahrt über den rechten oder den linken Fahrstreifen handelt.

Hierfür werden zunächst zwei in Fahrtrichtung nahe beieinander, beispielsweise innerhalb eines Messquerschnitts, liegende Sensoren ausgewählt, die jeweils aufgrund ihrer Anordnung einem Fahrstreifen zugeordnet werden können. In den Signalen dieser Sensoren werden die lokal dominanten Maxima bestimmt, nachdem jeweils ihr gleitender Median abgezogen wurde. Anschließend werden die Maxima für beide Signale einander zugeordnet. Aufgrund der räumlichen Nähe der Sensoren ist es hierfür nicht notwendig, einen besonderen Zuordnungsalgorithmus, wie etwa in Kapitel 5.3.1 beschrieben, zu verwenden. Stattdessen werden die Maxima eines Sensors einfach den zeitlich nächsten Maxima

des zweiten Sensors zugewiesen. Wenn dabei ein Schwellwert für die maximale Zeitdifferenz überschritten wird, werden die Maxima als separate Detektionen behandelt. Dabei wird davon ausgegangen, dass Parallelfahrten, bei denen die Maxima innerhalb der gewählten Zeitdifferenz liegen vernachlässigbar selten auftreten und daher insgesamt nicht zu einer signifikanten Verzerrung führen.

Die Bestimmung der Fahrspur erfolgt schließlich durch direkten Vergleich der zugeordneten Maxima. Wenn das größere der beiden Maxima von dem Sensor unter der linken Fahrspur stammt, wird die linke Fahrspur zugewiesen, andernfalls die rechte.

Bild 60 zeigt die Detektion von Überfahrten und die anschließende Fahrspurzuordnung anhand der Dehnungssensoren MS3L und MS4L des RTM Systems. Diese Dehnungssensoren wurden gewählt, weil Dehnungsmessungen in Längsrichtung laut Literatur besonders zur Identifikation von Verkehrs-




Bild 61: Anhand der Fahrspurdetektionen abgeleitete Verkehrsdichte im Wochenverlauf

lasten geeignet sind [16]. Die blauen Kreuze kennzeichnen lokal dominante Maxima des Signals MS4L, die roten Kreuze solche des Signals MS3L. An zwei Stellen wurde ein Maximum auf dem linken Fahrstreifen durch das zugeordnete Maximum auf dem rechten Fahrstreifen übertroffen, sodass hier eine Detektion auf dem rechten Fahrstreifen gemeldet wurde.

Die Summe der Überfahrten beider Fahrspuren in einem bestimmten Zeitintervall entspricht der Verkehrsdichte. Diese kann ebenfalls zur Attribuierung von eingebetteten Merkmalen verwendet werden. Die so für eine Woche geschätzten Verkehrsdichten sind in Bild 61 dargestellt. Hier ist deutlich ein von einem Tagesrythmus überlagerter Wochenrythmus erkennbar.

5.3.4 Einbettung

5.3.4.1 Hauptkomponentenanalyse (PCA)

Bei der Hauptkomponentenanalyse handelt es sich um ein lineares Verfahren, bei dem aus einer Stichprobe die Richtungen größter Varianz im Merkmalsraum bestimmt werden (siehe [23]). Die Richtungen größter Varianz entsprechen dabei den zu den größten Singulärwerten gehörenden Basisvektoren. Nachdem diese Basis einmal bestimmt wurde, können auch neue Merkmalsvektoren in dieser Basis dargestellt werden. Durch die Projektion auf die größten Basisvektoren wird Information in dazu orthogonalen Richtungen verworfen. Dies geschieht unter der Annahme, dass diese Richtungen keine relevanten Informationen, sondern lediglich Rauschen enthalten. Insgesamt werden die Merkmalsvektoren durch die Hauptkomponentenanalyse also komprimiert und gefiltert.

Für die spätere Einbettung durch ein nicht-lineares Verfahren wie t-SNE kann insbesondere diese Filtereigenschaft vorteilhaft sein, weil dadurch die relevanten Strukturen hervorgehoben werden kön-

nen. Durch die Dimensionsreduktion infolge der Projektion in eine niedrigdimensionale Basis kann die Berechnung der Einbettung zudem beschleunigt werden.

Die Berechnung der Hauptkomponenten erfordert eine Standardisierung der Merkmalsvektoren, indem die Komponenten der um ihren Mittelwert bereinigten Merkmalsvektoren durch ihre Varianz geteilt werden. Die Division durch die komponentenweise Varianz kann entfallen, wenn die Einträge der Merkmalsvektoren die gleichen Einheiten besitzen. Für die Verarbeitung von Spektren bei dem in Kapitel 5.2 erläuterten algorithmischen Ablauf wurden beispielsweise auf die Division durch die komponentenweise Varianz verzichtet.

Sei X eine Matrix, deren Zeilen N standardisierte Merkmalsvektoren, also beispielsweise mittelwertfreie Spektren, enthalten. Die Hauptkomponenten können dann durch Singulärwertzerlegung der aus X gebildeten Kovarianzmatrix Σ abgeleitet werden:

$$\Sigma = \frac{1}{N} X^T X \quad (46)$$

$$[U \quad S \quad V] = \text{svd}(\Sigma) \quad (47)$$

Die Singulärwertzerlegung in Gleichung (47) berechnet eine Diagonalmatrix mit Singulärwerten S und zwei orthogonale Matrizen U und V , sodass $\Sigma = USV^T$. Da die Singulärwerte auf der Diagonale von S absteigend geordnet sind, bilden die ersten k Spalten von V eine Basis der k wichtigsten Hauptkomponenten. Sei $B = V(:, 1:k)$ die Matrix mit den so bestimmten Basisvektoren. Die Projektion auf diese Basis ergibt dann die dimensionsreduzierten und gefilterten Merkmalsvektoren:

$$X' = XB \quad (48)$$

In obiger Gleichung ist X' eine $(N \times k)$ Matrix, deren Zeilen die gesuchten transformierten Merkmalsvektoren enthält.

Die Singulärwerte einer Kovarianzmatrix können als Varianzen in Richtung der durch V vorgegebenen Basisvektoren interpretiert werden. Typischerweise reichen wenige Hauptkomponenten aus, um einen Großteil der Varianz zu erklären. Beispielsweise zeigt Bild 62 die logarithmierten Singulärwerte einer Kovarianzmatrix Absteigender Reihenfolge, so wie sie auch auf der Diagonalen von S stehen. In dem hier gezeigten Fall reichen die ersten 24 von insgesamt 580 Hauptkomponenten aus, um 99 % der Varianz zu erklären.




Bild 62: Logarithmischer Plot der Varianzen für die durch Singulärwertzerlegung (SVD) bestimmten Hauptkomponenten. In diesem Beispiel erklären die ersten 24 Komponenten 99 % der Varianz.

5.3.4.2 t-SNE

t-SNE (siehe [42]) verwendet ein Maß für die Ähnlichkeit zwischen Dichtefunktionen, um eine Einbettung zu bestimmen, die die in den Eingabedaten enthaltenen Strukturen möglichst beibehält. Im Gegensatz zu der Hauptkomponentenanalyse handelt es sich bei t-SNE um ein nicht-lineares Verfahren, das komplexe Beziehungen zwischen Datenpunkten besser abbilden kann. Ein wichtiges Einsatzgebiet von t-SNE ist die Visualisierung hochdimensionaler Daten. Daher steht hier eine Einbettung in den drei- oder zweidimensionalen Raum im Vordergrund.

Die Einbettung wird in zwei Schritten bestimmt: Zuerst wird für jedes Paar von Eingabevektoren eine Maßzahl für deren Ähnlichkeit berechnet. Die eingebetteten Punkte werden dann so angeordnet, dass ein an den neuen Raum angepasstes Ähnlichkeitsmaß die ursprünglich bestimmten Ähnlichkeiten widerspiegelt.

Als Maß für die Ähnlichkeit zwischen zwei Punkten im ursprünglichen Merkmalsraum wird eine an die Normalverteilung angelehnte Wahrscheinlichkeitsdichte über Paare x_i, x_j von hochdimensionalen Merkmalsvektoren definiert:

$$p_{ij} = \frac{\exp(-\|x_i - x_j\|^2 / 2\sigma^2)}{\sum_{k \neq l} \exp(-\|x_k - x_l\|^2 / 2\sigma^2)} \quad (49)$$

Entsprechend wird ein Ähnlichkeitsmaß für die eingebetteten Merkmale im niedriger dimensionalen Raum wie folgt definiert:

$$q_{ij} = \frac{(1 + \|y_i - y_j\|)^{-1}}{\sum_{k \neq l} (1 + \|y_k - y_l\|)^{-1}} \quad (50)$$

In Gleichung (50) sind die y_n die Bilder der Eingabevektoren nach der Einbettung. Während das im

hochdimensionalen Raum verwendete Ähnlichkeitsmaß aus (49) auf einer schnell abfallenden Gaussdichte beruht, wird die Ähnlichkeit zwischen Punkten in Gleichung (50) anhand der Dichte einer Student-t Verteilung gemessen. Dadurch wird dem großen Unterschied in der Dimensionalität zwischen dem ursprünglichen Raum und dem Einbettungsraum Rechnung getragen.

Die Koordinaten der eingebetteten Punkte y_n werden dann so bestimmt, dass das folgende Distanzmaß zwischen den durch (49) und (50) definierten Ähnlichkeitsmaßen minimiert wird:

$$D(P \parallel Q) = \sum_{i \neq j} p_{ij} \log \left(\frac{p_{ij}}{q_{ij}} \right) \quad (51)$$

Das in Gleichung (51) verwendete Distanzmaß ist die Kullback-Leibler Divergenz zwischen den durch die Ähnlichkeitsmaße definierten Dichten P und Q . Dieses Minimierungsproblem ähnelt strukturell der Minimierung der Gesamtenergie eines Feder-Masse-Systems, in dem die Massepunkte durch die y_i repräsentiert werden und die Kräfte durch die Unterschiede in den entsprechenden Ähnlichkeitsmaßen p_{ij} und q_{ij} . Die Minimierung erfolgt durch Gradientenabstieg in Richtung der resultierenden Gesamtkraft bis das System einen stationären Zustand erreicht hat.

Solche Minimierungsprobleme für Vielkörpersysteme sind in der Kosmologie häufig anzutreffen. Dementsprechend wurden dort effiziente Lösungsverfahren entwickelt, die auch für das hier vorliegende Einbettungsproblem eingesetzt werden können. Ein Beispiel ist die Barnes-Hut Approximation, bei der Gruppen nahe beieinanderliegender Punkte (Merkmale) zusammengefasst werden und wie ein einzelner Punkt behandelt werden. Dadurch kann die Berechnung für große Punktmengen beschleunigt werden, sodass der Aufwand in der Größenordnung von $O(N \log(N))$ liegt.

Für die Verarbeitung der hochdimensionalen Spektraldaten in diesem Projekt wurde die Kosinusdistanz anstatt der in den Gleichungen (49)-(50) verwendeten euklidischen Distanz verwendet. Diese misst effektiv den Winkel zwischen Spektren und ist besser zur Verarbeitung hochdimensionaler Daten geeignet. Die Kosinusdistanz ist folgendermaßen definiert:

$$D_{\cos}(x, y) = 1 - \frac{\langle x, y \rangle}{\|x\| \|y\|} \quad (52)$$

5.3.4.3 Autoencoder

Autoencoder sind vielschichtige neuronale Netze, die ebenfalls für Dimensionsreduktion, Visualisierung und explorative Datenanalyse entwickelt wurden. Sie wurden ursprünglich als nicht-lineare Hauptkomponentenanalyse eingeführt (siehe [43]) und sollen wie diese Korrelation zwischen Variablen aufdecken und entfernen. Im Gegensatz zur linearen Hauptkomponentenanalyse sollen sie jedoch auch beliebige nicht-lineare Zusammenhänge zwischen Variablen erkennen können.

Üblicherweise besitzen Autoencoder-Netze neben je einer Ein- und Ausgabeschicht zusätzlich drei innere Schichten, von denen die mittlere eine deutlich geringere Knotenzahl aufweist. In der Trainingsphase werden die Eingabedaten sowohl an die Eingabeschicht, als auch an die Ausgabeschicht angelegt, sodass das Netzwerk die identische Abbildung lernt. Aufgrund des Flaschenhalses in der mittleren Schicht ist das Netzwerk dabei gezwungen, eine dimensionsreduzierte Repräsentation der Eingabedaten zu erstellen. Der so erstellte Code ist daher nach der Lernphase durch die mittlere Schicht gegeben.




Bild 63: Schematische Darstellung eines Autoencoder-Netzwerkes mit zwei verborgenen Schichten (E: Eingabeschicht, A: Abbildungsschicht, C: Code-Schicht, R: Rückabbildungsschicht, O: Ausgabeschicht)

5.3.5 Gruppierung

5.3.5.1 k-means

Der k-means Algorithmus ordnet die Elemente einer Menge von Eingabepunkten k Gruppen so zu, dass der quadratische Abstand jedes Punktes zu dem Mittelwert der ihm zugewiesenen Gruppe minimal ist. Dadurch wird der Merkmalsraum in konvexe Gebiete, sogenannte Voronoi-Zellen, aufgeteilt und die Streuung (Varianz) der Punkte innerhalb der Gruppen wird minimiert.

Die optimale Lösung dieses Problems ist NP-Schwer und daher nach derzeitigem Stand der Informatik nur mit Algorithmen, die eine exponentiell mit der Anzahl der Datenpunkte ansteigende Rechenzeit aufweisen, exakt lösbar siehe [39]. Allerdings existieren effiziente Heuristiken. Häufig wird ein iteratives Verfahren eingesetzt, bei dem die Eingabepunkte zunächst zufällig k Gruppen zugeordnet werden. Dann werden abwechselnd Zuordnungsschritte und Aktualisierungsschritte durchgeführt. In der Zuordnungsphase wird jeder Punkt dem Gruppenmittelpunkt mit dem kleinsten quadratischen Abstand zugewiesen. Dann erfolgt die Neuberechnung der Gruppenmittelpunkte auf Basis der neuen Zuordnungen. Die Iteration endet, sobald sie die Gruppenzuweisungen nicht mehr ändern. Bei diesem Verfahren ist nicht garantiert, dass das Optimum tatsächlich gefunden wird.

Bild 64 bis Bild 66 zeigen die Ergebnisse einer Gruppierung durch den k-means Algorithmus für mit t-SNE eingebettete spektrale Merkmale, die vor der Einbettung mittels PCA auf 24 Dimensionen reduziert wurden, wodurch 99 % der Varianz erhalten wurden. Für kleine Gruppenanzahlen stimmt das




Bild 64: k = 4




Bild 65: k = 8




Bild 66: k = 24

Gruppierungsergebnis noch gut mit der räumlichen Verteilung der Punkte überein. Mit steigender Gruppenszahl werden räumlich zusammenhängende Punkthaufen jedoch zunehmend unterschiedlichen Gruppen zugeordnet, wodurch nach der Einfärbung der Eindruck zerschnittener Punkthaufen entsteht.

5.3.5.2 DP-means

Der DP-means Algorithmus (siehe [44]) ist eine Modifikation des k-means Algorithmus, bei der die Zahl der Gruppen nicht vorgegeben werden muss, sondern während der Iteration aus den Daten geschätzt wird.

Für die Herleitung des Verfahrens werden die Datenpunkte x_k als Zufallsstichprobe aus einer Gaußmischverteilung mit identischen Varianzen σ aufgefaßt:

$$x_k \sim \sum_i^N w_i N(x | \mu_i, \sigma I) \quad (53)$$

Wobei $N(x | \mu, \sigma I)$ die Dichte einer Normalverteilung mit Mittelwert μ und Kovarianzmatrix σI ist und w_i die Gewichte der Gaußmischverteilung sind. Ziel ist es, die Anzahl der Gruppen N , die Gewichte w_i , die Gruppenzentren μ_i und die Gruppenzugehörigkeiten zu bestimmen. Dafür wird ein Bayessches Modell definiert, in dem Vorwissen über die w_i und μ_i in Form einer Dirichlet beziehungsweise einer Normalverteilung mit großer Varianz angenommen wird. Daraus wird ein iteratives Gibbs-Sampling Verfahren für die Bestimmung der unbekannt Parameter und der Gruppenzugehörigkeiten abgeleitet, das zunächst mit einer Gruppe startet und iterativ neue Gruppen hinzufügt sobald ein Punkt nicht

durch die bestehenden Gruppen erklärt werden kann. Der DP-means Algorithmus entsteht schließlich aus diesem Samplingverfahren durch Betrachtung des Grenzfalles kleiner Gruppenvarianzen $\sigma \rightarrow 0$. Dabei wird ein Strafterm λ eingeführt, der den maximal erlaubten quadratischen Abstand eines Datenpunktes zu bestehenden Gruppen definiert. Wenn dieser für einen Punkt überschritten wird, wird eine neue Gruppe erstellt.

Der so bestimmte Algorithmus entspricht der Iteration bei k-means, mit dem Unterschied, dass mit lediglich einer Gruppe gestartet wird und während der Iteration bei Überschreiten des Strafterms neue Gruppen erstellt werden.

In Bild 67 bis Bild 69 sind die Ergebnisse einer Gruppierung mit dem DP-means Algorithmus für verschiedene Werte des Strafterms λ dargestellt. Hierbei wurden die gleichen Datenpunkte wie bei der Gruppierung durch k-means in Kapitel 5.3.5.1 verwendet. Verglichen mit dem k-means Algorithmus passen die bestimmten Gruppen etwas besser zu der geometrischen Verteilung der Punkte.

5.3.5.3 DBSCAN

Im Gegensatz zu k-means und DP-means ist DBSCAN ein dichtebasiertes Verfahren, dem weder Annahmen über die räumliche Verteilung der zu gruppierenden Punkte noch über die Anzahl der Gruppen zugrunde liegen [45]. Dadurch kann der Algorithmus beliebig geformte Gruppen erkennen.

Der Algorithmus besitzt zwei Eingabeparameter: Den Nachbarschaftsradius ε , der die Ausdehnung der Umgebung jedes Punktes beschreibt, in der während der Gruppierung nach Nachbarn gesucht




Bild 67: $\lambda = 125$, 3 Gruppen



Bild 68: $\lambda = 375$, 9 Gruppen







Bild 69: $\lambda = 1.500$, 4 Gruppen

Bild 70: $k = 1$, 18 GruppenBild 71: $k = 4$, 10 GruppenBild 72: $k = 17$, 7 Gruppen

Bilder 70 – 72: Ergebnisse einer Gruppierung durch den DBSCAN Algorithmus für verschiedene Nachbarschaftsgrößen (k)

wird, und die Nachbarschaftsgröße k , die angibt wie viele Punkte in der Nachbarschaft eines Punktes liegen müssen, damit dieser zum Innern einer Gruppe gezählt wird. Alle Punkte, die über eine Kette benachbarter, innerer Punkte miteinander verbunden werden können, werden einer Gruppe zugeordnet. Die so definierten Gruppen bestehen daher aus inneren Punkten und Randpunkten, die weniger als k Nachbarn besitzen, aber trotzdem durch innere Punkte mit der Gruppe verbunden sind. Während die Zuordnung von inneren Punkten zu Gruppen deterministisch ist, können die Randpunkte eventuell mehreren Gruppen zugeordnet werden. In diesem Fall ist das Ergebnis zufällig. Punkte, die weder innere Punkte noch Randpunkte sind, werden von dem Verfahren als Ausreißer gekennzeichnet.

Da bei der Implementierung dieses Verfahrens jeder Punkt prinzipiell nur einmal besucht wird, ist der Aufwand linear. Aufgrund der Untersuchung der Nachbarschaft jedes Punktes ist die Laufzeit insgesamt jedoch eher Vergleichbar mit der Laufzeit quadratischer Verfahren.

Die beiden Eingabeparameter können anhand der Daten geschätzt werden. Im Rahmen der hier präsentierten Untersuchungen wurde die Nachbarschaftsgröße k vorgegeben und der Nachbarschaftsradius anhand der Daten bestimmt.

Bild 70 bis Bild 72 zeigen die Ergebnisse einer Gruppierung durch den DBSCAN Algorithmus für verschiedene Nachbarschaftsgrößen. Die durch den Algorithmus bestimmten Gruppen stimmen gut mit der geometrischen Verteilung der Punkte überein. Insbesondere ergeben sich bei Verkleinerung der Nachbarschaft schrittweise kleinere Gruppen, ohne dass bestehende Gruppen praktisch geteilt

werden, wie es bei k -means beobachtet wurde (siehe Bild 66).

5.4 Interpretation der Streudiagramme

5.4.1 Auswertung einzelner Sensoren

Bei der Interpretation der Streudiagramme spielt die Identifikation von zusammenhängenden Haufen (Clustern) eingebetteter Merkmale eine große Rolle, denn diese entsprechen höher dimensionalen Merkmalsvektoren, die bei der Durchführung des t-SNE-Verfahrens als nahe beieinander liegend eingestuft wurden und daher auch einen ähnlichen Signalverlauf beziehungsweise eine ähnliche Bauwerksreaktion repräsentieren. Deren Zuordnung zu äußeren Einwirkungen, beispielsweise Temperaturveränderungen, geschieht durch die Einfärbung mit entsprechenden Attributen. Wenn dabei gleichmäßig eingefärbte Flächen entstehen, deren Ausdehnung gut mit den Clustern übereinstimmt, weist dies auf einen starken Zusammenhang zwischen dem entsprechenden Niveau des für die Einfärbung verwendeten Attributs und dem durch den Cluster repräsentierten Signalverlauf hin. Wenn bei der Einfärbung größere Flächen entstehen innerhalb derer sich die Farbe scheinbar kontinuierlich ändert (beispielsweise von dunkelgrün nach hellgrün), dann deutet dies immerhin noch darauf hin, dass sich die Signalform in Abhängigkeit von dem Attributwert kontinuierlich ändert. Entstehen dabei jedoch ungleichmäßig eingefärbte, unzusammenhängende Flächen, dann ist kein Zusammenhang zwischen dem für die Einfärbung verwendeten Attribut und den extrahierten Signalverläufen entsprechenden Bauwerksreaktionen erkennbar. Dies zeigt dann

nicht, dass ein solcher Zusammenhang nicht existiert, sondern kann auch durch die gewählte Vorverarbeitung, das Verfahren der Merkmalsextraktion oder die Normalisierung der Merkmale begründet sein.

Die zusätzliche Gruppierung, beispielsweise mithilfe des DBSCAN-Algorithmus, soll dazu dienen, die Identifikation zusammenhängender Haufen zu objektivieren. Je nach verwendetem Clustering-Verfahren und den eingestellten Parametern können so verschiedene nachvollziehbare Methoden zur algorithmischen Identifikation signifikanter Cluster ausgewählt werden. Je größer der Überlapp zwischen diesen algorithmisch identifizierten Clustern der Einbettung und gleichmäßig eingefärbten Flächen, die bei der Einfärbung mit Attributen entstanden sind, ist, desto eher kann davon ausgegangen werden, dass ein bestimmtes Niveau der für die Einfärbung verwendeten äußeren Einwirkung mit einer entsprechenden charakteristischen Signalform oder Bauwerksreaktion korrespondiert.

5.4.2 Kombinierte Auswertung mehrerer Sensoren

Bei der in Kapitel 5.2.6 beschriebenen Methodik für die kombinierte Auswertung mehrerer Sensoren werden die Ergebnisse einer zuvor für mehrere Kanäle jeweils einzeln durchgeführten Klassifikation zusammengefasst und mit einem Autoencoder kodiert. Auf die kodierten Sequenzen wird schließlich nochmals das t-SNE-Verfahren angewandt, um als Ergebnis schließlich die Streudiagramme zu erhalten.

Die in diesen Streudiagrammen identifizierten Gruppen (Cluster), entsprechen hier also nicht einzelnen, sich ähnelnden Signalverläufen, sondern sich ähnelnden Ergebnissen der Kodierung. Weil die Kodierung die Ergebnisse der zuvor durchgeführten Klassifikation für mehrere Kanäle und Zeitabschnitte zusammenfasst, repräsentieren die Kodewörter Erregungsmuster, die sich über mehrere Kanäle und längere Zeitabschnitte erstrecken. Somit deuten auch die Gruppen in den Streudiagrammen auf sich wiederholende Erregungsmuster in mehreren Kanälen und über längere Zeitabschnitte hin.

Ein solches Muster könnte beispielsweise entstehen, wenn Sensoren, die auf Fahrzeugüberfahrten reagieren, in bestimmten Abständen entlang einer Fahrbahn platziert werden. Bei der Überfahrt ein-

zelner Fahrzeuge mit gleicher Geschwindigkeit, würden diese Sensoren der Reihe nach angeregt, was zur Extraktion entsprechender Merkmale in unterschiedlichen Zeitfenstern und Kanälen führen würde, ähnlich wie in Bild 48 gezeigt. Wenn viele solcher Überfahrten stattfinden, sollten diese bei der Kodierung ähnlich kodiert werden und daher später bei der Einbettung einen Cluster bilden. Wenn verschiedene Fahrzeugklassen mit charakteristischen Geschwindigkeiten (etwa Lkw und Pkw) vorliegen, würden bei der Einbettung dementsprechend zwei Cluster entstehen.

5.5 Anwendungsfälle

Im Folgenden werden drei Szenarien beschrieben, in denen das in Kapitel 5.2 beschriebene Gesamtkonzept für die algorithmisch gestützte Sensordatenanalyse eingesetzt wurde, um Zusammenhänge zwischen Bauwerksreaktionen und externen Einwirkungen bei dem Brückenbauwerk BW 402e zu untersuchen, das Bestandteil des Autobahnkreuzes Nürnberg ist. Das Bauwerk wurde zu Forschungszwecken mit unterschiedlichen, teils redundanten Messsystemen ausgestattet. Für die ersten beiden hier dargestellten Szenarien wurden zwei an der Fahrbahnübergangskonstruktion installierte Sensoren ausgewählt. In dem dritten Szenario wurden Messdaten von Sensoren eines der Kalottenlager sowie der Querkontraktionssensoren am Fahrbahnübergang herangezogen.

5.5.1 Untersuchung von Temperatureinflüssen

Zur Untersuchung des Einflusses von Temperaturschwankungen auf die Messwerte des Dehnungssensors MS18 des RTMS wurde eine Variante des in Bild 39 dargestellten Ablaufs eingesetzt, bei der der Median im Rahmen der Vorverarbeitung nicht von den Fenstern abgezogen wurde und die berechneten Spektren nicht durch ihre maximale Amplitude geteilt wurden. Die berechneten Spektren wurden dann mit der PCA-Methode auf die sieben wichtigsten Hauptkomponenten projiziert. Diese Merkmale wurden dann mit dem t-SNE Verfahren in die Ebene abgebildet und anhand der Temperatur eingefärbt. Parallel wurden die in die Ebene abgebildeten Merkmale mit dem DBSCAN Algorithmus gruppiert und anhand der Gruppierung eingefärbt. Für die Gruppierung wurde die Nachbarschaftsgröße neun vorgegeben und der Radius der Umgebung, der die Nachbarschaft definiert, aus




Bild 73: Eingebettete Merkmale des Dehnungssensors MS18 eingefärbt nach Temperaturmessungen. Die Temperaturskala variiert hier von dunkelblau (ca. 1,1 °C) bis dunkelrot (ca. 26 °C).



Bild 74: Eingebettete Merkmale des Dehnungssensors MS18 eingefärbt nach Gruppierung durch den DBSCAN Algorithmus (Nachbarschaftsgröße: 9). Hier wurden keine Ausreißer erkannt.

den Daten geschätzt. Die Streudiagramme in Bild 73 und Bild 74 zeigen die Ergebnisse.

Mit den hier gewählten Vorverarbeitungsschritten entsteht bei der Einbettung eine Vielzahl von Inseln nahe beieinander liegender Merkmale, die relativ gut mit den Einfärbungen durch die Temperaturmessungen und die Gruppierung übereinstimmen. Bei der Gruppierung durch den DBSCAN Algorithmus wurden 27 Gruppen erstellt und es wurden keine Merkmale als Ausreißer eingestuft. Es wird vermutet, dass die hier beobachtete Gruppenbildung hauptsächlich durch den Gleichanteil der durch die Temperaturunterschiede hervorgerufenen Ausdehnung des Bauwerkes begründet ist.

5.5.2 Untersuchung der Einflüsse von Fahrzeugüberfahrten

In diesem Szenario wurden die Beschleunigungsmessungen des an der Fahrbahnübergangskonstruktion befestigten Sensors B3 untersucht. Dabei wurden verschiedene Varianten des in Bild 39 gezeigten Ablaufs verwendet, um die Auswirkungen

der Dimensionsreduktion durch die Hauptkomponentenanalyse (PCA) bei der Merkmalsgenerierung besser zu verstehen.

Zunächst wurde eine Variante ohne Hauptkomponentenanalyse untersucht. Im Gegensatz zu dem Vorgehen in Kapitel 5.5.1 wurde bei den ausgeschnittenen Signalfenstern dabei jedoch der Median abgezogen und die berechneten Spektren wurden jeweils durch ihr Maximum geteilt. Die so normalisierten Spektren wurden dann direkt als Eingabe für das t-SNE Verfahren verwendet. Schließlich wurden die so in die Ebene abgebildeten Merkmalsvektoren entsprechend der dem Ereignis mit dem in Kapitel 5.3.3 beschriebenen Verfahren zugeordneten Fahrbahn und den bei der Gruppierung zugeordneten Gruppen eingefärbt.

Bei Verwendung der Hauptkomponentenanalyse wurde von den ausgeschnittenen Fenstern ebenfalls der Median abgezogen und die Spektren wurden wieder durch ihre maximale Amplitude dividiert. Dann wurde das mittlere Spektrum aller so bestimmten Spektren berechnet und von allen Spektren abgezogen. Die mittelwertfreien Spektren dienten als Eingabe für die Berechnung der Hauptkomponenten. Schließlich wurden die Spektren auf die Hauptkomponenten zu den größten Eigenwerten projiziert. Dies wurde einmal für die drei größten und einmal für die zehn größten Hauptkomponenten durchgeführt. Danach erfolgte die Einbettung und Einfärbung der so reduzierten Merkmale wie oben bereits für den Fall ohne Hauptkomponentenanalyse beschrieben.

Die Bilder 75 bis 80 zeigen die Ergebnisse, wobei die Zeilen die verschiedenen Möglichkeiten der Vorverarbeitung mit PCA enthalten, während die beiden Spalten die Einfärbung nach der den untersuchten Fenstern zugeordneten Fahrbahn (linke Spalte) sowie nach den bei der Gruppierung automatisch festgestellten Gruppen (rechte Spalte) enthalten.

Wird die Einbettung nach der Projektion auf die zehn wichtigsten Hauptkomponenten durchgeführt (zweite Zeile), ähnelt das Ergebnis stark dem Ergebnis, das man nach einer Einbettung ohne Projektion auf die Hauptkomponenten erhält (erste Zeile). Dies legt die Vermutung nahe, dass die ersten zehn Hauptkomponenten hier noch den Großteil der in den Merkmalen enthaltenen Informationen kodieren, zumindest soweit diese bei der Einbettung berücksichtigt wird. In beiden Fällen führt die Einbettung zu der Herausbildung zweier abgetrenn-




Bild 75: Ohne PCA




Bild 76: Ohne PCA




Bild 77: PCA mit 10 Komponenten




Bild 78: PCA mit 10 Komponenten




Bild 79: PCA mit 3 Komponenten




Bild 80: PCA mit 3 Komponenten

Bilder 75 – 80: Eingebettete Merkmale des Beschleunigungssensors B3

Zeilen: Ergebnis für verschiedene Möglichkeiten der Dimensionsreduktion durch PCA.

Linke Spalte: Merkmale eingefärbt nach Fahrzeugüberfahrten. Grün: Überfahrt links, Blau: Überfahrt rechts, Rot: Nicht zugeordnet. Rechte Spalte: Merkmale eingefärbt nach Gruppierung durch den DBSCAN Algorithmus (Nachbarschaftsgröße: 9). Rote Punkte wurden als Ausreißer eingestuft.

ter Gruppen von Merkmalen, die ungefähr jeweils entweder einer Überfahrt auf dem linken oder rechten Fahrstreifen entsprechen (linke Spalte). Diese Einteilung stimmt sehr gut mit den in der rechten Spalte gezeigten Ergebnissen der automatischen Gruppierung überein. Die vorherige Projektion auf die zehn wichtigsten Hauptkomponenten scheint hier den positiven Aspekt zu haben, dass die zwei Gruppen stärker voneinander separiert werden, was hier also für die Verwendung der Hauptkomponentenanalyse spricht.

Führt man allerdings eine weitere Reduktion der Merkmalsdimension durch, indem man vor der Einbettung nur auf die drei stärksten Hauptkomponenten projiziert (dritte Zeile), so sind die beiden zuvor deutlich getrennten Gruppen nach der Einbettung miteinander verbunden und bei der automatischen Gruppierung wird nur noch eine große Gruppe erkannt. Allerdings ist an der Einfärbung nach der zugeordneten Fahrbahn noch erkennbar, dass die Einbettung die Ähnlichkeit der Merkmale trotzdem erhält. Dies zeigt, dass durch die Projektion auf die Hauptkomponenten ein wichtiger Teil der in den Merkmalen enthaltenen Strukturinformation verloren geht, die bei der Einbettung durch t-SNE noch erhalten bleibt, obwohl die Einbettung in einen Raum noch geringerer Dimension, nämlich die zweidimensionale Ebene, erfolgt.

In Bild 81 bis Bild 83 wird der Einfluss von Maximum-Pooling im Frequenzbereich auf das Einbettungsergebnis gezeigt. Dabei wurde nach dem Pooling eine Projektion auf die 10 wichtigsten Hauptkomponenten durchgeführt, bevor die Einbettung berechnet wurde. Starkes Pooling bewirkt ein Zusammenrücken der Gruppen, die so zunehmend schwerer zu trennen sind.

5.5.3 Untersuchung des Zusammenhangs zwischen Messdaten von Sensoren am Lager und von in Querrichtung zur Fahrbahn messenden Sensoren

In diesem Anwendungsszenario wurden die Messungen der an dem kurveninneren Kalottenlager des Brückenbauwerkes befestigten Sensoren MS27v, MS28v, MS29v und MS30h und die Messungen der am Brückenüberbau in Querrichtung zur Fahrbahn messenden Sensoren auf mögliche charakteristische Muster hin untersucht.

Der Lagersensor MS30h misst die Verschiebung des Überbaus in horizontaler Richtung. Die am gleichen Lager befestigten Sensoren MS27v, MS28v und MS29v liegen senkrecht zur Fahrbahn und messen die vertikale Verschiebung des Bauwerks. Erfahrungsgemäß kann aus den Messungen der Wegsensoren in Querrichtung auf die Achslasten überfahrender Fahrzeuge geschlossen werden. Daher kann davon ausgegangen werden, dass ein Zusammenhang zwischen den Messungen dieser Sensoren besteht, insbesondere zwischen den in vertikaler Richtung messenden Wegaufnehmern am Lager und den in Querrichtung messenden Sensoren am Überbau.

Bei der Auswertung der Sensordaten wurde wie in Kapitel 5.2.6 beschrieben vorgegangen. Bild 84 zeigt die Ergebnisse der Klassifikation der auf den betrachteten Kanälen extrahierten Fenster für einen Ausschnitt einer längeren Zeitreihe. Für die Klassifikation wurde ein zuvor mit den auf einer anderen Zeitreihe extrahierten und gruppierten Merkmalen trainierter Nearest-Neighbor-Klassifikator eingesetzt. Die Zeitreihe wurde dann in Zeitabschnitte mit einer Länge von etwa 2,5 Sekunden eingeteilt und




Bild 81: Pooling mit Fenstergröße 5




Bild 82: Pooling mit Fenstergröße 9




Bild 83: Pooling mit Fenstergröße 17

Bilder 81 – 83: Einfluss des Maximum Poolings auf das Einbettungsergebnis. Hier wurde nach dem Pooling im Frequenzbereich eine Projektion auf die 10 wichtigsten Hauptkomponenten durchgeführt bevor die Einbettung berechnet wurde.

die von dem Klassifikator zuvor zugewiesenen Gruppenindizes der jeweils ersten Fenster in jedem Zeitabschnitt in einen Vektor eingetragen. Diese Vektoren entsprechen den Spalten der in Bild 84 gezeigten Matrix. Die Spaltenvektoren wurden dann one-hot-kodiert und jeweils fünf von ihnen aneinandergehängt. So entstanden Vektoren, die jeweils ungefähr 12,5 Sekunden lange Abschnitte der Sensordaten beschreiben. Ein zuvor trainiertes Autoencoder-Netzwerk wurde dann verwendet, um daraus die in Bild 85 gezeigte Kodierung zu berechnen. Jede Spalte der in Bild 85 gezeigten Matrix stellt daher eine Kodierung eines Zeitabschnittes von 12,5 Sekunden Länge durch sieben reelle Zah-

len dar. Diese wurde dann als Eingabe für das t-SNE-Verfahren verwendet (Kapitel 5.3.4.2). Die dabei berechnete Einbettung ist in Bild 86 dargestellt. Bild 87, Bild 88 und Bild 89 zeigen die Ergebnisse einer analogen Auswertung für eine andere Zeitreihe. Für beide Auswertungen wurden dabei der gleiche zuvor trainierte Nearest-Neighbor-Klassifikator und das gleiche, ebenfalls zuvor trainierte Autoencoder-Netzwerk verwendet.

Die in Bild 86 und Bild 89 gezeigten Einbettungen der kodierten Sequenzen durch t-SNE zerfallen jeweils in mehrere Gruppen. Dies weist auf das Vorhandensein sich wiederholender Muster in den ko-




Bild 84: Klassenindizes der gruppierten Fenster für jeden Kanal (Ausschnitt 1)




Bild 87: Klassenindizes der gruppierten Fenster für jeden Kanal (Ausschnitt 2)




Bild 85: Kodierte Sequenzen (Ausschnitt 1)




Bild 88: Kodierte Sequenzen (Ausschnitt 2)




Bild 86: Ergebnisse der Einbettung der kodierten Sequenzen durch t-SNE (Ausschnitt 1)




Bild 89: Ergebnisse der Einbettung der kodierten Sequenzen durch t-SNE (Ausschnitt 2)

dierten Sequenzen hin, die wiederum auf charakteristische Erregungsmuster des Bauwerkes infolge von Fahrzeugüberfahrten zurückzuführen sein könnten.

6 Softwarearchitekturen für die Brückenüberwachung

Im Folgenden werden Systemarchitekturen hinsichtlich des Daten- und Informationsflusses für die Überwachung mehrerer Brücken vorgestellt.

6.1 Komponenten

Ein Komplettsystem kann grob in die in Bild 90 gezeigten Komponenten aufgeteilt werden. In einem Sensornetzwerk am Bauwerk werden Daten erhoben und an ein Gateway weitergeleitet. Das Gateway ist zu diesem Zweck direkt mit dem Sensornetz verbunden und befindet sich daher auch bei dem zu überwachenden Bauwerk. Die Hauptaufgaben des Gateways bestehen in der Überwachung des Sensornetzes sowie der Zwischenspeicherung und Weiterleitung der Sensordaten. Daneben können auf dem Gateway auch einfache Algorithmen zur Datenreduktion oder -aggregation ausgeführt werden. Diese werden über ein Netzwerk an ein zentrales Informationssystem weitergeleitet, wo der Hauptteil der Datenverarbeitung stattfindet. Das zentrale Informationssystem speichert auch die Ergebnisse dieser Auswertung und stellt die Daten für

Abfragen der Nutzer zusammen. Diese Abfragen werden von einem Abfragesystem vom Nutzer an das Informationssystem weitergeleitet. Das Abfragesystem ist für die grafische Darstellung der Abfrageergebnisse und die Kommunikation mit dem zentralen Informationssystem zuständig und kann entweder über das Netzwerk oder direkt als zusätzliche Programmkomponente an das zentrale Informationssystem angeschlossen sein.

6.2 Anpassung der Architektur an verschiedene Anforderungen

Die oben beschriebene Architektur kann an unterschiedlichen Stellen angepasst werden, um auf verschiedene Anforderungen einzugehen. Dies wird im Folgenden näher erläutert.

6.2.1 Toleranz gegenüber Netzwerkausfall

Die Gateways an den Brücken müssen mit einem Netzwerk verbunden sein, über das Daten an das zentrale Informationssystem weitergeleitet werden können. Da Brücken häufig auch in dünn besiedelten und damit schlecht an Infrastruktur angeschlossenen Gebieten stehen, bietet sich eine Anbindung über bestehende Mobilfunknetzwerke an. Diese fallen jedoch gelegentlich aus, beispielsweise bedingt durch eine Wartung der Antennen.

Um mit solchen Ausfällen umgehen zu können, sollten die angefallenen Sensordaten für einen festen Zeitraum zwischengespeichert werden. Außerdem

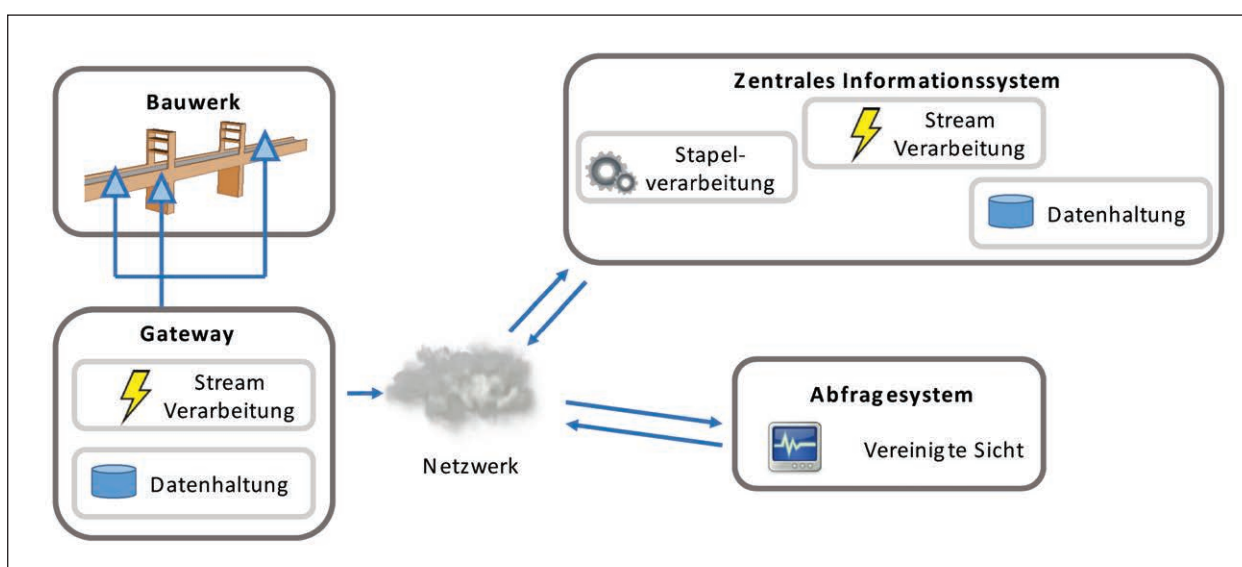


Bild 90: Komponenten eines Systems für die Brückenüberwachung

sollte die Übertragungskapazität größer als die im Betrieb anfallende Datenrate gewählt werden, um ausgefallene Daten zeitnah nachsenden zu können.

6.2.2 Anpassung an beschränkte Netzwerkbandbreite und Speicherplatz

Wenn die Netzwerkverbindung über einen längeren Zeitraum gestört ist oder wenn von vornherein nur eine niedrige Datenrate zur Verfügung steht, können eventuell nicht alle von dem Sensornetzwerk erhobenen Daten weitergeleitet oder gespeichert werden. In diesem Fall muss auf dem Gateway bereits eine Datenreduktion stattfinden.

Diese Datenreduktion kann durch eine Aggregation von Daten, wobei viele Datenpunkte durch einen einzelnen Wert, z. B. den Mittelwert, ersetzt werden, erreicht werden. Außerdem besteht die Möglichkeit, charakteristische Merkmale der Zeitreihen (z. B. reduzierte Spektren) bereits auf dem Gateway zu berechnen und anschließend nur mit diesen weiterzuarbeiten. Diese Verfahren zur Datenreduktion empfehlen sich selbstverständlich nur, wenn die benötigten Merkmale genau bekannt sind. Ansonsten besteht die Gefahr, dass hier interessante und wichtige Informationen verworfen werden.

6.2.3 Echtzeit- und Stapelverarbeitung

Die Architektur des zentralen Informationssystems ist durch die sich widersprechenden Bedürfnisse nach schneller Verfügbarkeit von Informationen einerseits und andererseits der Notwendigkeit, rechenaufwändige Analyseverfahren, wie die Finite-Elemente-Methode, durchzuführen, bestimmt.

Solche rechenaufwändige Analyseverfahren greifen in der Regel auf eine lange Historie an Daten zurück und werden daher als Stapelverarbeitungsprozesse realisiert. Im Gegensatz hierzu sind echtzeitfähige Verfahren meist als inkrementelle Algorithmen implementiert, die nur auf die letzten Daten zurückgreifen.

Will man sowohl Stapelverarbeitungsprozesse als auch Echtzeitverarbeitung unterstützen, bietet sich die in Bild 91 gezeigte Lambda-Architektur an [49], [50]. Hierbei werden alle empfangenen Daten zunächst in einer gemeinsamen Eingangsdatenwarteschlange (Queue) abgelegt. Von dort aus werden die Daten, die von Stapelverarbeitungsprozessen benötigt werden, in eine Datenbank geschrieben. Die Stapelverarbeitungsprozesse können hier die benötigten Daten abholen, ihre Berechnungen durchführen und die Ergebnisse anschließend in eine eigene Ergebnisdatenbank schreiben. Für die Echtzeitverarbeitung können die Daten entweder direkt aus der Eingangswarteschlange gelesen werden oder es findet noch eine Zwischenspeicherung in einer weiteren Warteschlange statt, die beispielsweise zusätzlich eine Speicherung der Daten (Persistenz) unterstützen kann. Zuletzt werden die Ergebnisse beider Verarbeitungswege zusammengeführt und beispielsweise über eine von einem Webserver bereitgestellte Rest-API für das Abfragesystem bereitgestellt.

Die Lambda Architektur ist relativ komplex, weil in den Programmteilen, die für die Stapelverarbeitung zuständig sind, oftmals andere Schnittstellen verwendet werden als in den Programmteilen, die die Echtzeitdatenverarbeitung durchführen. Dadurch wird sowohl die Implementierung als auch die Wartung des Programms recht aufwendig.

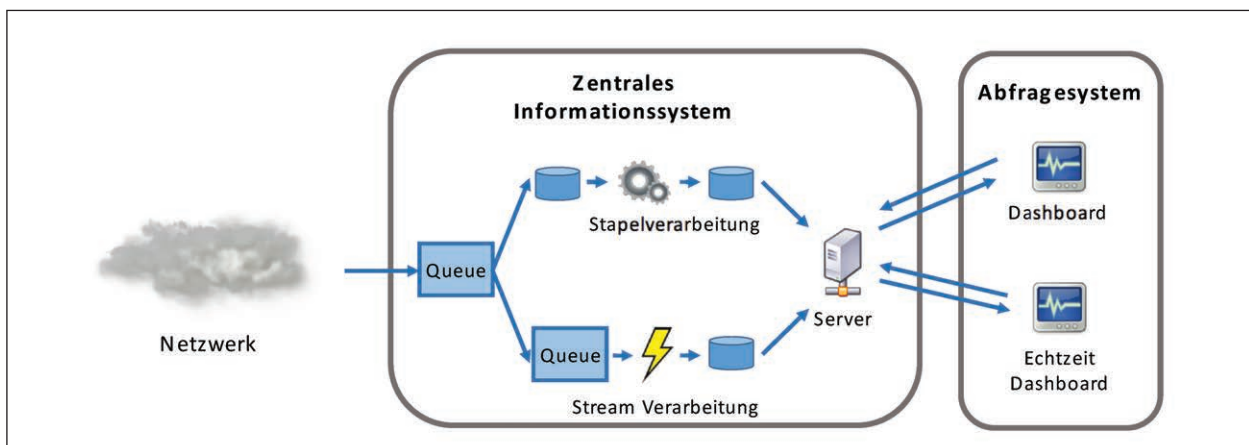


Bild 91: Lambda-Architektur für Stapel- und Echtzeitdatenverarbeitung

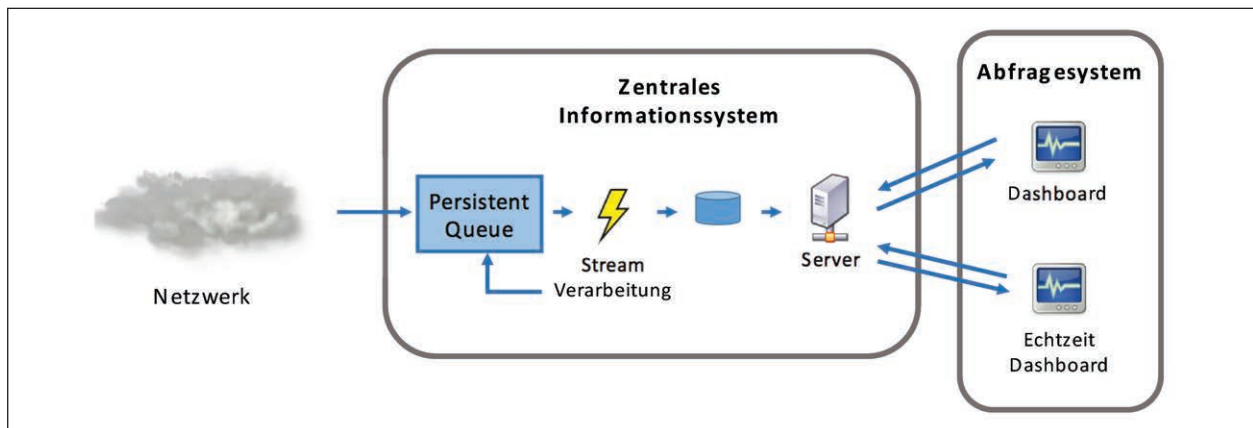


Bild 92: Kappa-Architektur für Echtzeitdatenverarbeitung

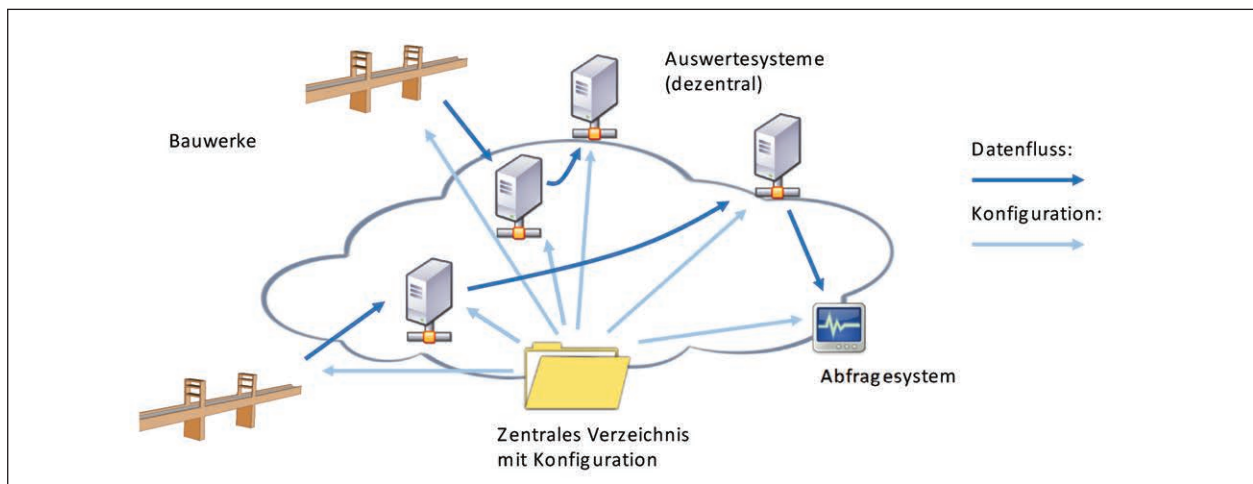


Bild 93: Datenfluss im Netzwerk mit dezentralen Vermittlungsstellen

Außerdem können aufgrund der Fortschritte in der Rechnertechnologie immer mehr Probleme quasi inkrementell gelöst werden. Daher wird die von der Lambda-Architektur vorgesehene Stapelverarbeitung immer seltener benötigt. Als Alternative wurde die sogenannte Lamba-Architektur vorgestellt [51], die in Bild 92 gezeigt ist. Hierbei werden alle Daten zunächst in eine persistente Warteschlange geschrieben, von wo sie direkt von den Algorithmen zur Echtzeitdatenverarbeitung gelesen werden. Zwischenergebnisse der Verarbeitung können wieder in einer persistenten Datenschlange abgelegt werden, sodass auch komplexere Berechnungen durchgeführt werden können. Schließlich müssen die Ergebnisse für das Abfragesystem bereitgestellt werden, wie oben für die Lambda-Architektur bereits beschrieben.

Auf den ersten Blick erscheint die Kappa-Architektur wie eine vereinfachte Lambda-Architektur ohne die Möglichkeit zur Stapelverarbeitung. Ein Unterschied, der in den Schaubildern nicht deutlich wird,

liegt allerdings auch in den verwendeten Komponenten: Bei der Lambda-Architektur wird die persistente Eingangswarteschlange oft nur mit Schreibzugriff realisiert und in der Echtzeitdatenverarbeitungskomponente wird häufig ein funktionales Programmiermodell verwendet. Da allerdings auch bei der Lambdaarchitektur viele verschiedene Technologien eingesetzt werden können, sind die Unterschiede auch hier fließend.

6.2.4 Skalierbarkeit

Wenn viele Brückenbauwerke überwacht werden sollen, kann eine Architektur, wie Bild 93 in gezeigt, verwendet werden. Hier werden die Daten von den einzelnen Brücken zunächst zu Vermittlungsstellen geschickt. Diese entscheiden an welches Auswertesystem die Daten dann weitergeleitet werden. Die hierfür benötigten Informationen sind in einer zentralen Konfiguration gespeichert, die allen Teilnehmern zur Verfügung gestellt wird. Das Abfragesys-

tem ist als vollständig eigenständiges System an das Netzwerk angeschlossen und erhält die Information, aus welchem zentralen Informationssystem Daten zu einer bestimmten Brücke abgerufen werden können, ebenfalls aus der zentralen Konfiguration.

Dieser Systemaufbau vermeidet einen Flaschenhals und ermöglicht so eine sehr gute Skalierung mit der Anzahl überwachter Brücken vorausgesetzt, dass die an den Brücken erhobenen Daten getrennt voneinander verarbeitet werden können.

6.3 Übersicht vorhandener Technologien

Tabelle 1 gibt eine Übersicht über aktuelle Big-Data Technologien, die für die Realisierung eines Systems zur Brückenüberwachung herangezogen wer-

den könnten. In Bild 94 wird eine Auswahl dieser Technologien für eine Realisierung der Lambda-Architektur gezeigt.

Das zentrale Konfigurationsverzeichnis wird hier mit dem Programm „ZooKeeper“ der Apache Foundation realisiert. Für das Senden der Daten zu den Informationssystemen, in denen die Berechnungen durchgeführt werden, wurde das Programm „ZeroMQ“ gewählt, das eine effiziente Implementierung von Warteschlangenmodellen ermöglicht. Die Verteilung und Bereitstellung der Daten innerhalb der zentralen Informationssysteme erfolgt mit dem Programm „kafka“, das ebenso wie das für die Verarbeitung von Stapel- und Echtzeitdaten verwendete Spark auch von der Apache Foundation bereitgestellt wird.

Message Broker	Datenbank	Stapelverarbeitung	Streamverarbeitung	Ressourcenverwaltung
kafka.	CASSANDRA	Spark	Spark	Apache Mesos
RabbitMQ	HBASE		Apache Flink	kubernetes
ØMQ	mongoDB.		kafka.	Zookeeper
mosquitto	Postgresql		STORM	

Tab. 1: Auswahl populärer Big Data Technologien

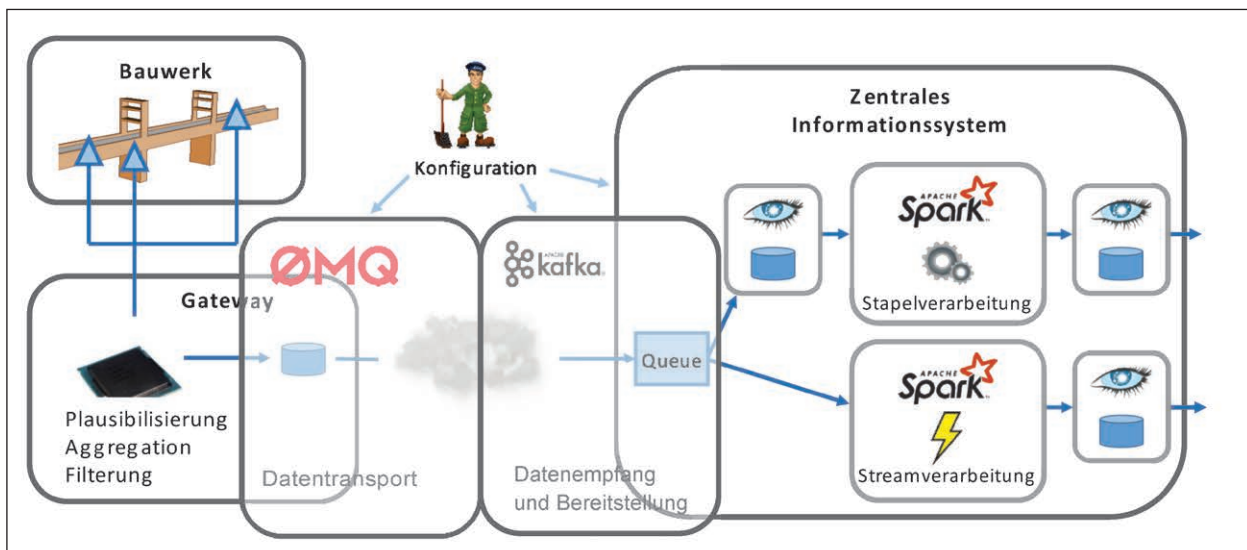


Bild 94: Mögliche Technologieauswahl für die Brückenüberwachung

7 Zusammenfassung und Ausblick

Die Literaturübersicht in Kapitel 2 erläutert den aktuellen Stand der automatischen Überwachung von Tragwerken. Dabei treten zwei verschiedene Lösungsansätze hervor: Einerseits Verfahren, die mit den Methoden des maschinellen Lernens ein Normal-Modell erstellen, um dieses dann zur Erkennung von Abweichungen der während des Betriebs erfassten Daten von den aufgrund des Modelles erwarteten Messdaten zu verwenden. Andererseits Verfahren, bei denen ein Finite-Elemente-Modell der Struktur herangezogen wird, um Veränderungen am Bauwerk zu detektieren. In diesem Projekt wurden größtenteils Verfahren zur automatischen Auswertung von Sensordaten, die an Brücken erfasst wurden, untersucht, die kein physikalisches Modell benötigen.

Bei einer ersten Untersuchung der Sensordaten in Kapitel 3 wurde eine grobe Abschätzung der für verschiedene Anwendungsszenarien benötigten Datenraten und des Speicherbedarfs erstellt, die in die Überlegungen zur Realisierung möglicher Softwarearchitekturen in Kapitel 6 eingeflossen ist.

In Kapitel 4 werden verschiedene Verfahren zur Plausibilisierung von Sensordaten vorgestellt und ihre Anwendung am Beispiel der Plausibilisierung von Temperaturdaten erläutert. Für die Plausibilisierung einzelner physikalischer Größen wurde der Einsatz modellfreier Verfahren, nämlich von Smoothing Splines sowie linearer Filter, deren Koeffizienten mit dem Expectation-Maximization-Algorithmus bestimmt wurden, demonstriert. Als Nachteil der modellfreien Verfahren wurde die Einschränkung auf einfache Modelle niedriger Dimension und die starke Abhängigkeit von repräsentativen Trainingsdaten identifiziert. Hier könnten zukünftige Arbeiten anknüpfen, beispielsweise indem alternative Methoden des Deep-Learnings, etwa Long-Short-Term-Memory (LSTM), zur Vorhersage von Zeitreihen untersucht werden, siehe [52].

Das in Kapitel 5 vorgestellte Verfahren zur algorithmisch gestützten Sensordatenanalyse für Brückenbauwerke beruht auf der Kombination eines Einbettungsverfahrens zur Dimensionreduktion und Visualisierung mit Gruppierungs- und Klassifizierungsverfahren. Dadurch soll die Analyse des Zusammenhangs zwischen externen Einwirkungen und resultierenden Bauwerkreaktionen unterstützt werden. Dieses Konzept könnte durch die Verwen-

dung zusätzlicher Merkmalstypen in aufbauenden Arbeiten erweitert werden (siehe [36]). Außerdem wäre eine Untersuchung alternativer Methoden zur Bestimmung der Fenstergrößen oder anderer Methoden zur Multiskalenanalyse, beispielsweise der Einsatz der diskreten Wavelet-Transformation (DWT), denkbar. In einem weiteren Schritt könnte das Verfahren weiter automatisiert werden, indem die Übereinstimmung der in den Daten vorgefundenen Gruppen (Cluster) mit der Einfärbung durch die Attribuierung untersucht wird.

Falls eine Vielzahl von Brücken mit Messsystemen ausgestattet wird, müssen die anfallenden Daten effizient transportiert und gespeichert werden. Mögliche geeignete Softwarearchitekturen hierfür werden in Kapitel 7 vorgestellt. Ein weitergehender Softwareentwurf sollte erst auf Basis konkreter Anforderungen an die Funktionalität und die notwendigen, hierfür einzusetzenden Algorithmen erfolgen.

Literatur

- [1] V. K. F. B. Felix SAWO, „Intelligente Bauwerke – Anforderungen an die Aufbereitung von Messgrößen und ihrer Darstellungsform,“ BAST, Karlsruhe, 2014
- [2] K. WORDEN, C. R. FARRAR, G. MANSON und G. PARK, „The fundamental axioms of structural health monitoring,“ Proceedings of the Royal Society, pp. 1639-1664, 3 April 2007
- [3] K. WORDEN und G. MANSON, „The application of machine learning to structural health monitoring,“ Philosophical Transactions of the Royal Society, pp. 515-53, December 2006
- [4] H. SOHN, C. R. FARRAR, F. HEMEZ und J. CZARNECKI, „A Review of Structural Health Monitoring Literature 1996-2001,“ Los Alamos National Laboratory, 2003
- [5] K. WORDEN, H. SOHN und C. FARRAR, „Novelty detection in a changing environment: regression and interpolation approaches,“ in: Journal of Sound and Vibration, pp. 741-761, Dezember 2002
- [6] C. ZANG, M. I. FRISWELL und M. IMREGUN, „Structural Damage Detection using Independent Component Analysis,“ in:

- Structural Health Monitoring, pp. 69-83, März 2004
- [7] F. UBERTINI, C. GENTILE und A. L. MATERAZZI, „Automated modal identification in operational conditions and its application to bridges,“ in: *Engineering Structures*, pp. 264-278, Juli 2012
- [8] E. J. CROSS, G. MANSON und K. P. S. WORDEN, „Features for damage detection with insensitivity to environmental and operational variations,“ in: *Proceedings of the royal society*, pp. 4098-4122, 10 Oktober 2012
- [9] W. FAN und P. QIAO, „Vibration-based Damage Identification Methods: A Review and Comparative Study,“ in: *Structural Health Monitoring*, pp. 83-111, 20 April 2010
- [10] G. COMANDUCCI, F. MAGALHÃES, F. UBERTINI und Á. CUNHA, „On vibration-based damage detection by multivariate statistical techniques: Application to a long-span arch bridge,“ in: *Structural health monitoring*, pp. 505-524, 2016
- [11] S. TAMURA, B. ZHANG, Y. WANG, F. CHEN und K. NGUYEN, „Supervised and Unsupervised Machine Learning Approaches for Bridge Damage Prediction,“ in: *Structural Health Monitoring*, 2013
- [12] A. MORDINI, K. SAVOV und H. WENZEL, „The Finite Element Model Updating: A Powerful Tool for Structural Health Monitoring,“ in: *Structural Engineering International*, pp. 352-358, November 2007
- [13] M. LYNDON, S. E. TAYLOR, D. ROBINSON, A. MUFTI und E. J. O'BRIEN, „Recent Developments in Bridge Weigh in Motion (B-WIM),“ in: *Journal of Civil Structural Health Monitoring*, Bd. 6, pp. 69-81, 2016
- [14] Y. YU, C. CAI und L. DENG, „State-of-the-art review on bridge weigh-in-motion technology,“ in: *Advances in Structural Engineering*, pp. 1-17, 2016
- [15] F. MOSES, „Weigh-in-motion system using instrumented bridges,“ in: *Journal of Transportation Engineering*, Bd. 105, Nr. 3, 1979
- [16] P. LUBASCH, „Identifikation von Verkehrslasten unter Einsatz von Methoden des Soft Computing,“ Universität Duisburg-Essen, Duisburg-Essen, 2009
- [17] N. EL-SHEIMY, H. HOU und X. NIU, „Analysis and Modeling of Inertial Sensors Using Allan Variance,“ in: *IEEE Transactions on Instrumentation and Measurement*, pp. 140-149, Januar 2008
- [18] A. PAPOULIS und U. PILLAI, *Probability, Random Variables and Stochastic Processes*, McGraw-Hill, 2002
- [19] IEEE, „IEEE Standard for Floating-Point Arithmetic IEEE Std 754-2008,“ IEEE, 2008
- [20] L. AUERSCH und S. SAID, „Dynamik von Stahlbetonbrücken – Messprojekte aus dem Eisenbahn- und Straßenverkehr,“ in 8. Symposium Experimentelle Untersuchungen von Baukonstruktionen, Dresden, 2015
- [21] „Wikipedia,“ Wikimedia Foundation Inc., 2019. [Online]. Available: <https://de.wikipedia.org/wiki/Spannbeton> [Zugriff am 26 Februar 2019]
- [22] H. BURCHARD, A. AYERS, W. FREY und S. N. S., „Approximation with Aesthetic Constraints,“ *Designing Fair Curves and Surfaces*, pp. 3-28, 1994
- [23] T. HASTIE, R. TIBSHIRANI und J. FRIEDMAN, in: *The Elements of Statistical Learning*, Springer Verlag, 2009
- [24] Y. BAR-SHALOM, X. R. LI und K. THIAGALINGAM, *Estimation with Application to Tracking and Navigation*, John Wiley & Sons, 2001
- [25] J. PEARL, *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*, Morgan Kaufmann Publishers, 1988
- [26] G. AGAMENNONI, J. NIETO und E. NEBOT, „An Outlier-Robust Kalman Filter,“ in: *IEEE International Conference on Robotics and Automation*, Shanghai, 2011
- [27] A. DEMPSTER, N. LAIRD und D. RUBIN, „Maximum Likelihood from Incomplete Data via the EM Algorithm,“ in: *Journal of the Royal Statistical Society*, pp. 1-38, 1977

- [28] C.-F. J. WU, „On the convergence properties of the EM algorithm,“ in: *Annals of Statistics*, pp. 95-103, 1983
- [29] Z. GHAMRANI und G. E. HINTON, „Parameter Estimation for Linear Dynamical Systems,“ 1996
- [30] W. E. WECKER und C. F. ANSLEY, „The Signal Extraction Approach to Nonlinear Regression and Spline Smoothing,“ in: *Journal of the American Statistical Association*, pp. 81-89, 2012
- [31] F. GUSTAFSSON, *Adaptive Filtering and Change Detection*, John Wiley & Sons, LTD, 2000
- [32] H. FUJIOKA und H. KANO, „Recursive construction of optimal smoothing splines with constraints,“ in: *Proceedings of the 2010 American Control Conference*, Baltimore, 2010
- [33] H. MADSEN und J. HOLST, „Estimation of continuous-time models for the heat dynamics of a building,“ in: *Energy and Buildings*, 1995
- [34] M. VERLEYSEN und D. FRANÇOIS, „The Curse of Dimensionality in Data Mining and Time Series Prediction,“ in: *Lecture Notes in Computer Science*, 2005
- [35] A. MAHFOUZ, M. VAN DE GIESSEN, L. VAN DER MAATEN, S. HUISMAN, M. REINDERS, M. J. HAWRYLYCZ und B. P. LELIEVELDT, „Visualizing the spatial gene expression organization in the brain through non-linear similarity embeddings,“ in: *Methods*, pp. 79-89, 2015
- [36] M. CHRIST, A. W. KEMA-LIEHR und M. FEINDT, „Distributed and parallel time series feature extraction for industrial big data applications,“ *ArXiv e-print 1610.07717*, 2017
- [37] J. SZALAI und F. E. MÓZES, „Intelligent Digital Signal Processing and Feature Extraction Methods,“ in: *New Approaches in Intelligent Image Analysis Techniques, Methodologies and Applications*, Springer International Publishing Switzerland, 2016, pp. 59-91
- [38] M. SPENGLER, „Dynamik von Eisenbahnbrücken unter Hochgeschwindigkeitsverkehr,“ Technische Universität Darmstadt, Darmstadt, 2010
- [39] T. H. CORMEN, C. E. LEISERSON, R. L. RIVEST und C. STEIN, *Introduction to Algorithms*, in: MIT Press, 2009
- [40] A. ZIMEK, E. SCHUBERT und H.-P. KRIEGEL, „A survey on unsupervised outlier detection in high-dimensional numerical data,“ in: *Statistical Analysis and Data Mining*, pp. 363-387, 2012
- [41] C. DING und X. HE, „K-means Clustering via Principal Component Analysis,“ in: *Proceedings of the 21st International Conference on Machine Learning*, Banff, 2004
- [42] L. J. P. VAN DER MAATEN und G. E. HINTON, „Visualizing High-Dimensional Data Using t-SNE,“ in: *Journal of Machine Learning Research* 9, pp. 2579-2605, November 2008
- [43] M. A. KRAMER, „Nonlinear principal component analysis using autoassociative neural networks,“ in: *AIChE Journal* Vol. 37, No. 2, pp. 233-242, 1991
- [44] B. KULIS und M. I. JORDAN, „Revisiting k-means: New Algorithms via Bayesian Nonparametrics,“ in: *Proceedings of the 29th International Conference on Machine Learning*, Edinburgh, 2012
- [45] J. SANDER und X. XU, „A density-based algorithm for discovering clusters in large spatial databases with noise,“ in: *Proceedings of 2nd International Conference on Knowledge Discovery and Data Mining*, 1996
- [46] S. MARTELLO und P. TOTH, „Linear Assignment Problems,“ *North-Holland Mathematics Studies*, pp. 259 – 282, 1987
- [47] T. LINDEBERG, „Principles for Automatic Scale Selection,“ KTH (Royal Institute of Technology), Stockholm, 1998
- [48] J. J. KOENDERINK und A. J. van DOORN, „Representation of local geometry in the visual system,“ in: *Biological Cybernetics*, pp. 367-375, 1987

- [49] M. ASMI und A. BAINCZYK, „Technical Report PG 594 – Big Data,“ TU Dortmund, Dortmund, 2016
- [50] L. BERLE, „Lambda-Architektur in der Praxis,“ Opitz Consulting, Gummersbach, 2017
- [51] F. TROSSBACH, „heise online,“ 3 11 2017. [Online]. Available: <https://www.heise.de/developer/artikel/Effiziente-Datenverarbeitung-mit-Kafka-3877195.html> [Zugriff am 20. Februar 2019]
- [52] S. SIAMI-NAMINI, N. TAVAKOLI und A. S. NAMIN, „A Comparison of ARIMA and LSTM in Forecasting Time Series,“ 2018

- Bild 7: Von dem Sensor MS6T1u erfasster Temperaturverlauf (blau) und angepasster Smoothing Spline (rot)
- Bild 8: Beispiel zur Anomaliedetektion bei dynamischen Daten (Smoothing Spline)
- Bild 9: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (Smoothing Spline)
- Bild 10: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (Smoothing Spline)
- Bild 11: Beispiel zur Anomaliedetektion bei Vorliegen von Ausreißern (Smoothing Spline)

Bilder 8 – 11: Anomalieerkennung mit Smoothing Splines für verschiedene Szenarien. Blaue Linie: Smoothing Spline, Grüne Linie: Original Sensordaten, Rote Kreuze: Ausreißer nach GMA, Rote Kreise: Ausreißer nach CUSUM. Die Schwellwerte für die Anomalieerkennung wurden anhand von Trainingsdaten aus der Winterzeit bestimmt.

Bilder

- Bild 1: Messreihenausschnitt und halblogarithmische Darstellung des zugehörigen Leistungsspektrums für den Dehnmessstreifen ‚MS17‘ des RTM-Systems
- Bild 2: Messreihenausschnitt und halblogarithmische Darstellung des zugehörigen Leistungsspektrums für den Beschleunigungssensor ‚B4‘, der zu dem instrumentierten Fahrbahnübergang gehört
- Bild 3: Messreihenausschnitt für den Temperatursensor ‚1CBF4‘ des iBASt-Systems
- Bild 4: Synchronisation zweier Signale. Die schwarzen und blauen Pfeilspitzen markieren die Abtastzeitpunkte zweier Signale. Die korrespondierenden Messungen dürfen nicht weiter als ein halbes Abtastintervall voneinander abweichen, damit eine eindeutige Zuordnung erfolgen kann.
- Bild 5: Bayes-Netz zu dem generativen Modell, das die dem Kalman-Filter zugrundeliegenden Annahmen über den beobachteten Prozess beschreibt.
- Bild 6: Bayes-Netz zu dem generativen Modell, das die dem Outlier Robust Kalman-Filter zugrundeliegenden Annahmen über den beobachteten Prozess beschreibt.

- Bild 12: Beispiel zur Anomaliedetektion bei dynamischen Daten (Smoothing Spline)
- Bild 13: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (Smoothing Spline)
- Bild 14: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (Smoothing Spline)
- Bild 15: Beispiel zur Anomaliedetektion bei Vorliegen von Ausreißern (Smoothing Spline)
- Bilder 12 – 15: Anomalieerkennung mit Smoothing Splines für verschiedene Szenarien. Blaue Linie: Smoothing Spline, Grüne Linie: Original Sensordaten, Rote Kreuze: Ausreißer nach GMA, Rote Kreise: Ausreißer nach CUSUM. Die Schwellwerte für die Anomalieerkennung wurden anhand von Trainingsdaten aus der Sommerzeit bestimmt.
- Bild 16: Beispiel zur Anomaliedetektion bei dynamischen Daten (ORKF mit gelerntem Modell)
- Bild 17: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (ORKF mit gelerntem Modell)

- Bild 18: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (ORKF mit gelerntem Modell)
- Bild 19: Beispiel zur Anomaliedetektion bei Vorliegen von Ausreißern (ORKF mit gelerntem Modell)
- Bilder 16 – 19: Anomalieerkennung mit ORKF und gelerntem Modell für verschiedene Szenarien. Blaue Linie: Ergebnis der Filterung durch das ORKF, Grüne Linie: Original Sensordaten, Rote Kreuze: Ausreißer nach GMA, Rote Kreise: Ausreißer nach CUSUM. Die Schwellwerte für die Anomalieerkennung wurden anhand von Trainingsdaten aus der Sommerzeit bestimmt.
- Bild 20: Beispiel zur Anomaliedetektion bei dynamischen Daten (ORKF mit vorgegebenem Modell)
- Bild 21: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (ORKF mit vorgegebenem Modell)
- Bild 22: Beispiel zur Anomaliedetektion bei fehlenden Messdaten (ORKF mit vorgegebenem Modell)
- Bild 23: Beispiel zur Anomaliedetektion bei Vorliegen von Ausreißern (ORKF mit vorgegebenem Modell)
- Bilder 20 – 23: Anomalieerkennung mit ORKF und vorgegebenem Modell für verschiedene Szenarien. Blaue Linie: Ergebnis der Filterung durch das ORKF, Grüne Linie: Original Sensordaten, Rote Kreuze: Ausreißer nach GMA, Rote Kreise: Ausreißer nach CUSUM.
- Bild 24: Scatterplot von Temperatur und Feuchte für den Monat Februar. Rote Linie: Mit Regression bestimmte Ausgleichsgerade
- Bild 25: Schätzung der relativen Luftfeuchte anhand der Temperatur für den Monat Februar. Rot: Geschätzte Feuchte, Blau: Messwerte
- Bild 26: Scatterplot von Temperatur und Feuchte für den Monat Juli. Rote Linie: Mit Regression bestimmte Ausgleichsgerade
- Bild 27: Schätzung der relativen Luftfeuchte anhand der Temperatur für den Monat Juli. Rot: Geschätzte Feuchte, Blau: Messwerte
- Bilder 24 – 27: Ergebnisse der Vorhersage der relativen Feuchte anhand der Temperatur
- Bild 28: Position der Temperatursensoren im Brückenquerschnitt
- Bild 29: Ersatzschaltbild für die Modellierung des Temperat austauschs zwischen verschiedenen Komponenten einer Hohlkastenbrücke
- Bild 30: Plausibilisierung dreier Temperaturmessungen im Zeitraum Januar bis Juli 2018. Schwarze Kreuze kennzeichnen als Ausreißer markierte Messwerte.
- Bild 31: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit drei Zuständen für einen Zeitraum mit fehlenden Daten
- Bild 32: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit drei Zuständen für einen Zeitraum mit einem groben Messfehler
- Bilder 31 und 32: Ausschnitte der Kalman-Filter basierten Anomalieerkennung für drei Temperatursensoren von Januar bis Juli 2018
- Bild 33: Plausibilisierung zweier Temperaturmessungen im Zeitraum Januar bis Juli 2018. Schwarze Kreuze kennzeichnen als Ausreißer markierte Messwerte.
- Bild 34: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit zwei Zuständen für einen Zeitraum mit fehlenden Daten
- Bild 35: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit zwei Zuständen für einen Zeitraum mit einem groben Messfehler
- Bild 36: Plausibilisierung zweier Temperaturmessungen im Zeitraum Januar bis Juli 2018, wobei die Messungen des iBAST Sensors 1CBF4 als Steuergröße aufgefasst wurden. Schwarze Kreuze kennzeichnen als Ausreißer markierte Messwerte.

- Bilder 34 – 36: Ausschnitte der Kalman-Filter basierten Anomalieerkennung für zwei Temperatursensoren von Januar bis Juli 2018
- Bild 37: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit zwei Zuständen für einen Zeitraum mit fehlenden Daten
- Bild 38: Ausschnitt der Kalman-Filter basierten Anomalieerkennung mit zwei Zuständen für einen Zeitraum mit einem groben Messfehler
- Bilder 37 und 38: Ausschnitte der Kalman-Filter basierten Anomalieerkennung für zwei Temperatursensoren von Januar bis Juli 2018, wobei die Außentemperaturmessungen des iBASt-Sensors 1CBF4 als Steuergröße aufgefasst wurden.
- Bild 39: Schematische Darstellung des Ablaufs der algorithmisch Unterstützten Sensordatenanalyse
- Bild 40: k-means
- Bild 41: DP-means
- Bild 42: DBSCAN
- Bilder 40 – 42: Ergebnisse der Gruppierung eingebetteter Merkmalsvektoren mit verschiedenen Verfahren. Die Farben kodieren die Gruppenzuordnung.
- Bild 43: Merkmale nach Einbettung
- Bild 44: Einfärbung nach Temperatur
- Bild 45: Einfärbung nach Wochentag
- Bild 46: Einfärbung nach Verkehrsdichte
- Bild 47: Erweiterung des Gesamtkonzepts zur Sensordatenauswertung für mehrere Kanäle
- Bild 48: Schematische Darstellung des Pooling-Schrittes: Zuerst werden die Gruppenindizes der in einem Zeitabschnitt detektierten Fenster in Vektoren zusammengefasst. Diese werden dann aneinandergehängt, um längere Sequenzen zu kodieren.
- Bild 49: Ereignisse, die von Sensoren längs der Fahrbahn detektiert wurden, müssen einander zeitlich zugeordnet werden.
- Bild 50: Ergebnis der Zuordnung von Fahrspurzuordnungen zu dominanten Beschleunigungsmaxima mit dem Jonker-Volgenant Algorithmus.
- Bild 51: Laplacian-of-Gaussian-(LoG-)Filterkernel ($s^2 = 16$)
- Bild 52: Ergebnis der Faltung verschiedener Filterkernel mit einer Gaussglocke ($\sigma^2 = 4$). Die Farbe kodiert den Wert des Parameters s^2 des LoG-Kernels von $s^2 = 2$ (rot) bis $s^2 = 16$ (gelb). Die Filterantwort ist für den Wert $s^2 = 5.66$ maximal.
- Bild 53: Skalenraumdarstellung für einen Ausschnitt aufgezeichneter Daten von Sensor MS27v des RTM Systems (Wegsensor). Rote Kreuze markieren die Maxima im zweidimensionalen Skalenraum.
- Bild 54: LoG-Filterantwort für den auch im linken Bild dargestellten Datenausschnitt des Wegsensors MS27v. Das Signal ist blau eingezeichnet, die Filterantworten sind entsprechend der Skala von rot (niedrigste Skala) bis gelb (höchste Skala) eingefärbt. Die Kreuze markieren die detektierten Skalenraummaxima.
- Bild 55: Auswahl der charakteristischen Skala für den Sensor MS7L des RTM Systems (Blau: Anzahl der signifikanten Skalenraummaxima für jede Skala, geteilt durch den Maximalwert. Rot: Zugewiesene charakteristische Skala)
- Bild 56: Auswahl der charakteristischen Skala für den Sensor MS27v des RTM Systems (Blau: Anzahl der signifikanten Skalenraummaxima für jede Skala, geteilt durch den Maximalwert. Rot: Zugewiesene charakteristische Skala)
- Bild 57: Ergebnis der Fenstergrößenanpassung anhand der charakteristischen Skala. Blaue Linie und durchgezogene Rechtecke: Signal des Dehnungssensors MS17: am Brückenüberbau mit detektierten Fenstern. Grüne Linie mit gestrichelten Rechtecken: Signal des Wegsensors MS27v an einem Lager des Bauwerks und Fenster
- Bild 58: Einseitige Leistungsspektren für Sensor MS27v ohne Anpassung der Fenstergrößen

- ße (Blau: Auf einzelnen Fenstern berechnete Spektren. Rot: Gemitteltes Spektrum)
- Bild 59: Einseitige Leistungsspektren für Sensor MS27v nach Anpassung der Fenstergröße (Blau: Auf einzelnen Fenstern berechnete Spektren. Rot: Gemitteltes Spektrum)
- Bild 60: Detektion von Überfahrten und Fahrspurzuordnung mit den Dehnungssensoren MS32 und MS4L des RTM Systems
- Bild 61: Anhand der Fahrspurdetektionen abgeleitete Verkehrsdichte im Wochenverlauf
- Bild 62: Logarithmischer Plot der Varianzen für die durch Singulärwertzerlegung (SVD) bestimmten Hauptkomponenten. In diesem Beispiel erklären die ersten 24 Komponenten 99 % der Varianz.
- Bild 63: Schematische Darstellung eines Autoencoder-Netzwerkes mit zwei verborgenen Schichten (E: Eingabeschicht, A: Abbildungsschicht, C: Code-Schicht, R: Rückabbildungsschicht, O: Ausgabeschicht)
- Bild 64: $k = 4$
- Bild 65: $k = 8$
- Bild 66: $k = 24$
- Bilder 64 – 66: Ergebnisse einer Gruppierung durch den k-means Algorithmus für verschiedene Gruppenzahlen k
- Bild 67: $\lambda = 125$, 3 Gruppen
- Bild 68: $\lambda = 375$, 9 Gruppen
- Bild 69: $\lambda = 1.500$, 4 Gruppen
- Bilder 67 – 69: Ergebnisse einer Gruppierung durch den DP-means Algorithmus für verschiedene Strafparameter (λ)
- Bild 70: $k = 1$, 18 Gruppen
- Bild 71: $k = 4$, 10 Gruppen
- Bild 72: $k = 17$, 7 Gruppen
- Bilder 70 – 72: Ergebnisse einer Gruppierung durch den DBSCAN Algorithmus für verschiedene Nachbarschaftsgrößen (k)
- Bild 73: Eingebettete Merkmale des Dehnungssensors MS18: eingefärbt nach Temperaturmessungen. Die Temperaturskala variiert hier von dunkelblau (ca. 1,1 °C) bis dunkelrot (ca. 26 °C).
- Bild 74: Eingebettete Merkmale des Dehnungssensors MS18: eingefärbt nach Gruppierung durch den DBSCAN Algorithmus (Nachbarschaftsgröße: 9). Hier wurden keine Ausreißer erkannt.
- Bild 75: Ohne PCA
- Bild 76: Ohne PCA
- Bild 77: PCA mit 10 Komponenten
- Bild 78: PCA mit 10 Komponenten
- Bild 79: PCA mit 3 Komponenten
- Bild 80: PCA mit 3 Komponenten
- Bilder 75 – 80: Eingebettete Merkmale des Beschleunigungssensors B3
Zeilen: Ergebnis für verschiedene Möglichkeiten der Dimensionsreduktion durch PCA. Linke Spalte: Merkmale eingefärbt nach Fahrzeugüberfahrten. Grün: Überfahrt links, Blau: Überfahrt rechts, Rot: Nicht zugeordnet. Rechte Spalte: Merkmale eingefärbt nach Gruppierung durch den DBSCAN Algorithmus (Nachbarschaftsgröße: 9). Rote Punkte wurden als Ausreißer eingestuft.
- Bild 81: Pooling mit Fenstergröße 5
- Bild 82: Pooling mit Fenstergröße 9
- Bild 83: Pooling mit Fenstergröße 17
- Bilder 81 – 83: Einfluss des Maximum Poolings auf das Einbettungsergebnis. Hier wurde nach dem Pooling im Frequenzbereich eine Projektion auf die 10 wichtigsten Hauptkomponenten durchgeführt bevor die Einbettung berechnet wurde.
- Bild 84: Klassenindizes der gruppierten Fenster für jeden Kanal (Ausschnitt 1)
- Bild 85: Kodierte Sequenzen (Ausschnitt 1)
- Bild 86: Ergebnisse der Einbettung der kodierten Sequenzen durch t-SNE (Ausschnitt 1)

- Bild 87: Klassenindizes der gruppierten Fenster für jeden Kanal (Ausschnitt 2)
- Bild 88: Kodierte Sequenzen (Ausschnitt 2)
- Bild 89: Ergebnisse der Einbettung der kodierten Sequenzen durch t-SNE (Ausschnitt 2)
- Bild 90: Komponenten eines Systems für die Brückenüberwachung
- Bild 91: Lambda-Architektur für Stapel- und Echtzeitdatenverarbeitung
- Bild 92: Kappa-Architektur für Echtzeitdatenverarbeitung
- Bild 93: Datenfluss im Netzwerk mit dezentralen Vermittlungsstellen
- Bild 94: Mögliche Technologieauswahl für die Brückenüberwachung

Tabellen

- Tab. 1: Auswahl populärer Big Data Technologien

Schriftenreihe

Berichte der Bundesanstalt für Straßenwesen

Unterreihe „Brücken- und Ingenieurbau“

2016

B 123: Nachrechnung bestehender Stahl- und Verbundbrücken – Restnutzung
Geißler, Krohn € 15,50

B 124: Nachrechnung von Betonbrücken – Systematische Datenauswertung nachgerechneter Bauwerke
Fischer, Lechner, Wild, Müller, Kessner
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 125: Entwicklung einheitlicher Bewertungskriterien für Infrastrukturbauwerke im Hinblick auf Nachhaltigkeit
Mielecke, Kistner, Graubner, Knaf, Fischer, Schmidt-Thrö
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 126: Konzeptionelle Ansätze zur Nachhaltigkeitsbewertung im Lebenszyklus von Elementen der Straßeninfrastruktur
Mielecke, Graubner, Roth
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 127: Verstärkung von Stahlbrücken mit Kategorie-2-Schäden
Kuhlmann, Hubmann € 21,50

B 128: Verstärkung von Stahlbrücken mit Kategorie-3-Schäden
Ungermann, Brune, Giese € 21,00

B 129: Weiterentwicklung von Verfahren zur Bewertung der Nachhaltigkeit von Verkehrsinfrastrukturen
Schmellekamp
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 130: Intelligente Straßenverkehrsinfrastruktur durch 3D-Modelle und RFID-Tags
Tulke, Schäfer, Brakowski, Braun
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 131: Pilotstudie zum Bewertungsverfahren Nachhaltigkeit von Straßenbrücken im Lebenszyklus
Schmidt-Thrö, Mielecke, Jungwirth, Graubner, Fischer, Kuhlmann, Hauf
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 132: Pre-Check der Nachhaltigkeitsbewertung für Brückenbauwerke
Graubner, Ramge, Hess, Ditter, Lohmeier
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 133: Anforderungen an Baustoffe, Bauwerke und Realisierungsprozesse der Straßeninfrastrukturen im Hinblick auf Nachhaltigkeit
Mielecke, Graubner, Ramge, Hess, Pola, Caspari
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 134: Nachhaltigkeitsbewertung für Erhaltungs- und Erhaltungskonzepte von Straßenbrücken
Gehrlein, Lingemann, Jungwirth
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

2017

B 135: Wirksamkeit automatischer Brandbekämpfungsanlagen in Straßentunneln
Kohl, Kammerer, Leucker, Leismann, Mühlberger, Gast
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 136: HANV als Verstärkung von Stahlbrücken mit Kategorie-1-Schäden
Stranghöner, Lorenz, Raake, Straube †, Knauff
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 137: Verstärkung von Stahlbrücken mit hochfestem Beton
Mansperger, Lehmann, Hofmann, Krüger, Lehmann € 14,50

B 138: Rückhaltesysteme auf Brücken – Einwirkungen aus Fahrzeuganprall und Einsatz von Schutzeinrichtungen auf Bauwerken
Mayer
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 139: Unterstützung der Bauwerksprüfung durch innovative digitale Bildauswertung – Pilotstudie
Sperber, Gößmann, Reget, Müller, Nolden, Köhler, Kremkau € 16,50

B 140: Untersuchungen zum Beulnachweis nach DIN EN 1993-1-5
U. Kuhlmann, Chr. Schmidt-Rasche, J. Frickel, V. Pourostad
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 141: Entwurf von hydrogeothermischen Anlagen an deutschen Straßentunneln
Moormann, Buhmann
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 142: Einsatz von offenporigen Belägen in Einhausungs- und Tunnelbauwerken
Baltzer, Riepe, Zimmermann, Meyer, Brungsberg, Mayer, Brenberger, Jung, Oeser, Meyer, Koch, Wienecke
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

2018

B 143: Analyse des menschlichen Verhaltens bei Aktivierung von stationären Brandbekämpfungsanlagen in Straßentunneln
Mühlberger, Gast, Plab, Probst € 15,50

B 144: Nachrechnung von Stahl- und Verbundbrücken – Systematische Datenauswertung nachgerechneter Bauwerke
Neumann, Brauer € 16,50

B 145: 8. BAST-Tunnelsymposium vom 6. Juni 2018 in der Bundesanstalt für Straßenwesen Bergisch Gladbach – Tagungsband
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

2019

B 147: Vorbereitung von Großversuchen an Stützkonstruktionen aus Gabionen
Blosfeld, Schreck, Decker, Wawrzyniak
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

2020

B 146: Beurteilung der Ermüdungssicherheit von vollverschlossenen Seilen mit Korrosionsschäden

Paschen, Dürrer, Gronau, Rentmeister
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 148: Übergreifungslängen von Betonstahlbewehrung Maßgebende Einflussparameter in den Grenzzuständen der Tragfähigkeit und Gebrauchstauglichkeit

Maurer, Bettin
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 149: Untersuchungen zum Einfluss von Modellparametern auf die Lebensdauerprognose für Brückenbauwerke

Keßler, Gehlen € 16,00

B 150: Beurteilung der Querkraft- und Torsionstragfähigkeit von Brücken im Bestand – erweiterte Bemessungsansätze

Hegger, Herbrand, Adam, Maurer, Gleich, Stuppak, Fischer, Schramm, Scheufler, Zilch, Tecusan
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 151: Verfahren und Modelle zur Quantifizierung der Zuverlässigkeit von dauerüberwachten Bestandsbrücken

Ralbovsky, Prammer, Lachinger, Vorwagner
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 152: Bemessung von Kopfbolzendübeln in Randlage unter Vermeidung eines Versagens infolge Herausziehens

Kuhlmann, Stempniewski
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 153: Kanalbrücke Berkenthin mit temperierter Fahrbahn – Pilotprojekt

Eilers, Friedrich, Quaas, Rogalski € 15,00

B 154: Korrosionsschutz von Brückenseilen – Wickelverfahren mit Korrosionsschutzbändern

Friedrich € 9,00

B 155: Innovativer und nachhaltiger Ersatzneubau von Betonbrücken

Wirker, Donner
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 156: Wirtschaftlichkeitsuntersuchungen von Monitoringmaßnahmen – Entwicklung eines Konzepts für die Analyse von Nutzen und Kosten

Schubert, Faber, Betz, Straub, Niemeier, Ziegler, Walther, Majka
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 157: 9. BAST-Tunnelsymposium – Tagungsband

€ 16,00

B 158: Beanspruchung orthotroper Fahrbahnplatten infolge der Erneuerung des Brückenbelags

Friedrich, Eilers, Quaas, Robrecht, Schamne, Staeck
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 159: Lebenszyklusmanagement für Bauwerke der Verkehrsinfrastruktur – Entwicklung eines verkehrsträgerübergreifenden, indikatorgestützten Systems

Lehardt, Seiler, Gerdes € 15,50

2021

B 160: Digitales Testfeld Autobahn – Intelligente Brücke – Datenerfassungsstrategien und Datenanalyse für intelligente Kalottenlager

Butz
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 161: Lagerwege von Brücken

Butz, Mack, Krawtschuk, Maldonado
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 162: Druckgurtanschluss in Hohlkastenbrücken – Ingenieurmodelle zur wirklichkeitsnahen Ermittlung der Tragfähigkeit

Müller
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 163: Dauerüberwachung von Bestandsbrücken – Quantifizierung von Zuverlässigkeit und Nutzen

Hindersmann
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 164: Intelligente Bauwerke – Verfahren zur Auswertung, Verifizierung und Aufbereitung von Messdaten

Kleinert, Sawo
Dieser Bericht liegt nur in digitaler Form vor und kann unter <https://bast.opus.hbz-nrw.de/> heruntergeladen werden.

Fachverlag NW in der Carl Ed. Schünemann KG
Zweite Schlachtpforte 7 · 28195 Bremen
Tel. +(0)421/3 69 03-53 · Fax +(0)421/3 69 03-48

Alternativ können Sie alle lieferbaren Titel auch auf unserer Website finden und bestellen.

www.schuenemann-verlag.de

Alle Berichte, die nur in digitaler Form erscheinen, können wir auf Wunsch als »Book on Demand« für Sie herstellen.