

# **Intelligente Bauwerke – Anforderungen an die Aufbereitung von Messgrößen und ihrer Darstellungsform**

**Berichte der  
Bundesanstalt für Straßenwesen**

**Brückenbau Heft B 114**

**bast**

# **Intelligente Bauwerke – Anforderungen an die Aufbereitung von Messgrößen und ihrer Darstellungsform**

von

Felix Sawo  
Vesa Klumpp  
Frederik Beutler

Knowtion UG  
Karlsruhe

**Berichte der  
Bundesanstalt für Straßenwesen**

**Brückenbau Heft B 114**

**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 Öffentlichkeitsarbeit.

Die Hefte der Schriftenreihe **Berichte der Bundesanstalt für Straßenwesen** können direkt bei der Carl Schünemann Verlag GmbH, 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 Öffentlichkeitsarbeit.

Ab dem Jahrgang 2003 stehen die **Berichte der Bundesanstalt für Straßenwesen (BASt)** zum Teil als kostenfreier Download im elektronischen BASt-Archiv ELBA zur Verfügung.  
<http://bast.opus.hbz-nrw.de>

## Impressum

**Bericht zum Forschungsprojekt FE 15.0548/2011/GRB:**  
Intelligente Bauwerke – Anforderungen an die Aufbereitung von Messgrößen und ihrer Darstellungsform

**Fachbetreuung**  
Eckhard Kempkens

**Herausgeber**  
Bundesanstalt für Straßenwesen  
Brüderstraße 53, D-51427 Bergisch Gladbach  
Telefon: (0 22 04) 43 - 0  
Telefax: (0 22 04) 43 - 674

**Redaktion**  
Stabsstelle Presse und Öffentlichkeitsarbeit

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

ISSN 0943-9293  
ISBN 978-3-95606-166-0

Bergisch Gladbach, Juni 2015

## Kurzfassung – Abstract

### **Intelligente Bauwerke – Anforderungen an die Aufbereitung von Messgrößen und ihrer Darstellungsform**

Ziel des Forschungsvorhabens FE 15.0548/2011/GRB war die Ausarbeitung einer Konzeption zu Anforderungen an die Aufbereitung und Verarbeitung von Messgrößen und ihrer Darstellung. Dies beinhaltete die Evaluierung und Entwicklung verschiedener modellbasierter und statistischer Analyseverfahren, die über den bisherigen Stand der Technik der Bauwerksüberwachung hinausgehen. Der Nutzen liegt in der Herausfilterung relevanter Informationen aus umfangreichem Datenmaterial (Vor-Aggregation) sowie der Erzeugung von belastbaren Zustandsinformationen bzw. Vorergebnissen hierzu durch eine frühzeitige, leistungsfähige Plausibilisierung. Es wurde gezeigt, dass durch den Einsatz von leistungsfähigen, gedächtnisbehafteten, selbstlernenden Algorithmen für die Sensorfusion, Interpolation, Plausibilitätserhöhung und Treffen fachtechnischer Monitoringaussagen Ergebnisse erzielt werden können, die bezüglich der Verarbeitung von Mess- und Erfassungsdaten weit über den aktuellen Stand beim Brückenmonitoring hinausgehen. Anhand mehrerer Szenarien, für die reale Erfassungsdaten zur Verfügung standen, wurde gezeigt, dass diese Verfahren sehr zuverlässig verschiedenste Signalstörungen, wie Messausreißer, erhöhtes Rauschen und Brummeinstreuung erkennen können. Nur durch die frühzeitige und zuverlässige Plausibilisierung von Sensordaten von Brückenbauwerken kann verhindert werden, dass offensichtlich fehlerhafte Messwerte (wie z. B. Messausreißer, störungsbehaftete Messungen) zu falschen Vorhersagen der Systemzuverlässigkeit von Brückenbauwerken durch rechnergestützte Systemmodelle führen.

### **Smart bridge – requirements for the preparation of measured variables and their representation**

The aim of the research project FE 15.0548/2011/GRB was the development of a conception of requirements for the preparation and processing of measured variables and their representation for the application of structural health monitoring of bridge structures. The investigation includes the evaluation and development of several model-based and statistical analysis methods that go beyond state of the art of structural health monitoring. The benefits of the proposed methods lie in the filtering of relevant information from large data material (pre-aggregation) as well as the generation of robust state information by monitoring and determining the plausibility. It has been shown that by means of powerful, self-learning algorithms for sensor fusion, interpolation, and plausibility checking, highly technical monitoring statements can be concluded that go far beyond the current state of the art of structural health monitoring. The performance of the proposed methods has been demonstrated by means of several scenarios based on real data. It turned out that these methods can reliably detect a wide range of signal interferences, such as outliers and increased sensor noises. The early and robust plausibility checking of sensor data prevents obviously erroneous readings (such as outliers), which lead to incorrect predictions of future reliability of bridges or other structures.



## Inhalt

<b>1</b>	<b>Einleitung</b> .....	7	3.3.2 Multiple-Modelle-Ansatz (MessMo2) .....	24
1.1	Sensor-Überwachungssystem zum robusten Brückenmonitoring. ....	7	3.3.3 Direkte Modellierung der bedingten Wahrscheinlichkeitsdichte (MessMo3) .....	25
1.2	Einordnung des Sensor-Überwachungssystems .....	9	3.4 Zusammenfassung .....	28
1.3	Ziel des Forschungsprojektes. ....	10		
1.4	Untersuchungsmethodik. ....	11	<b>4 Plausibilisierung, Datenfusion und Extraktion höherwertiger Information</b> .....	31
1.5	Gliederung .....	11		
<b>2</b>	<b>Erfassung von Einwirkung und Bauteilreaktionen</b> .....	12	4.1 Wertebereichs- und Trendüberwachung. ....	31
2.1	Temperatur .....	12	4.2 Modellbasierte Zustandsschätzer. ....	33
2.2	Material- und Luftfeuchtigkeit .....	12	4.2.1 Überblick und Ziele. ....	33
2.3	Chlorid .....	12	4.2.2 Klassifizierung nach Konfiguration der Mess- und Prüfdaten .....	34
2.4	Dehnung/Spannung .....	13	4.2.3 Sensordatenfusion .....	36
2.5	Beschleunigung/Vibration. ....	13	4.2.4 Datenplausibilisierung. ....	39
2.6	Rissentwicklung/Rissöffnung .....	13	4.2.5 Das Kalman-Filter für einfache lineare Probleme .....	40
2.7	Verkehrslasten .....	13	4.2.6 Zustandsschätzer für komplexe nichtlineare Probleme. ....	41
<b>3</b>	<b>Mathematische Modellierung des System- und Messverhaltens</b> .....	13	4.2.7 Zusammenfassung .....	43
3.1	Systemzustand zur Beschreibung physikalischer Systeme .....	14	4.3 Maschinelle Lernalgorithmen .....	44
3.2	Mathematische Modelle zur Beschreibung des dynamischen Systemverhaltens .....	16	4.3.1 Überblick und Ziele. ....	44
3.2.1	Überblick und Klassifizierung physikalischer Prozesse. ....	16	4.3.2 Univariate, multivariate und verteilte Mess- und Prüfgrößen .....	45
3.2.2	Präzise Modellierung des unter- lagerten physikalischen Prozesses (SysMo1) .....	17	4.3.3 Unüberwachte Lernalgorithmen zur Plausibilisierung .....	46
3.2.3	Allgemein physikalische Model- lierung (SysMo2) .....	18	4.3.4 Überwachte Lernalgorithmen zur Extraktion von höherwertigen Information .....	47
3.2.4	Multiple-Modelle-Ansätze (SysMo3). . .	20	4.3.5 Übersicht über maschinelle Lernverfahren .....	48
3.2.5	Separierung von Signalen (SysMo4). . .	22	4.3.6 Zusammenfassung .....	49
3.3	Mathematische Modelle zur Be- schreibung des Messverhaltens. ....	23	<b>5 Untersuchungen der Machbarkeit mittels realer Erfassungsdaten</b> .....	50
3.3.1	Exakte physikalische Modellierung der Mess- und Prüfdaten (MessMo1). ....	23	5.1 Multiring-Elektrode mit Temperatur- sensor PT 1000 .....	51

5.1.1	Plausibilisierung mittels maschineller Lernalgorithmen . . . . .	51
5.1.2	Filterung mittels modellbasierter Zustandsschätzer . . . . .	51
5.2	Temperatursensoren (Kanalbrücke Berkenthin) . . . . .	55
5.3	Wegaufnehmer . . . . .	58
5.4	Dehnmessstreifen (dynamischer Schwingversuch) – Erkennung von Sensordrifts . . . . .	63
5.5	Verkehrslastdaten . . . . .	65
<b>6</b>	<b>Aspekte der praktischen Umsetzung und Implementierung . . .</b>	<b>70</b>
6.1	Redundanz zur Erhöhung der Zuverlässigkeit der Datenplausibilisierung . . . . .	70
6.1.1	Hardwareredundanz . . . . .	70
6.1.2	Softwareredundanz . . . . .	70
6.1.3	Informationsredundanz . . . . .	70
6.1.4	Zeitredundanz . . . . .	71
6.2	Energieverbrauchsschätzung modellbasierter und statistischer Analyseverfahren . . . . .	71
6.3	Sensorbusse aus der industriellen Messtechnik . . . . .	72
<b>7</b>	<b>Zusammenfassung und Ausblick . . .</b>	<b>73</b>
7.1	Modellbasierte Analyseverfahren . . . . .	73
7.2	Statistische Analyseverfahren . . . . .	74
7.3	Folgerung für die Praxis . . . . .	75
<b>8</b>	<b>Literatur . . . . .</b>	<b>76</b>
<b>9</b>	<b>Anhang: Anwendungsszenario Kanalbrücke Berkenthin . . . . .</b>	<b>80</b>
9.1	Darstellung des Trainingsdatensatzes . . . . .	80

# 1 Einleitung

## 1.1 Sensor-Überwachungssystem zum robusten Brückenmonitoring

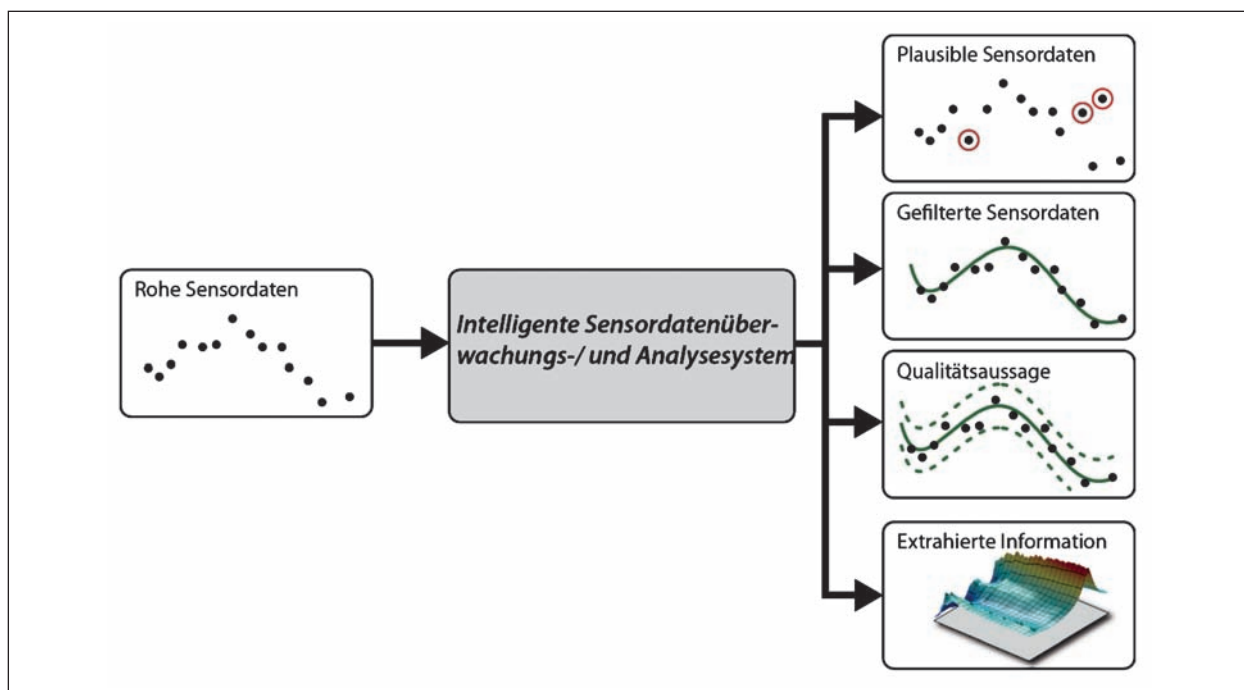
Durch Wartung und Inspektion von Brücken und anderen Ingenieurbauwerken entstehen in den nächsten Jahren steigende Kosten, da die Häufigkeit der Inspektion und die Wartungsmaßnahmen an den alternden Brückenbestand angepasst werden müssen. Eine umfassende echtzeitbasierte Zustandsbewertung von Brückenbauwerken kann diese Kosten nicht nur für Bestandsbauwerke, sondern auch für neue Bauwerke reduzieren.

Ein umfassendes echtzeitbasiertes und vor allem robustes Brückenmonitoring erfordert neben der Erhebung verschiedener Erfassungsdaten unmittelbar am Bauwerk eine Analyse, Reduktion und Weiterleitung der daraus abgeleiteten Informationen, siehe Bild 1. Im Vergleich zu anderen Messeinrichtungen in kontrollierter Umgebung unterliegen die mit Sensoren erfassten Messwerte am Bauwerk starken mechanischen und umweltbedingten Beanspruchungen. Die rauen Bedingungen im Freien führen dazu, dass die relevante Information in den Messsignalen durch Störsignale verschiedenster Art überlagert wird. Störungen wie beispielsweise Brummen, Rauschen, Messaussetzer, Sensordefekte oder

mangelnde EMV schränken die Funktionsweise und Lebensdauer der Sensoren stark ein.

Für die zuverlässige Überwachung von Bauwerken ist es somit notwendig, neben dem eigentlichen Bauwerk auch das gesamte Sensorsystem mittels eines „Intelligenten Sensordatenüberwachungs- und Analysesystems“ (kurz: Sensor-Überwachungssystem) durchgängig zu überprüfen. Dabei handelt es sich um ein leistungsfähiges Analysesystem, welches sich hauptsächlich durch die im Folgenden beschriebenen Leistungsmerkmale (siehe Bild 1) auszeichnet:

- Plausibilisierung von Sensordaten durch Detektion von Sensorsignalfehler verursacht durch Ausfall, Alterung, verschiedene im Bauwerk vorherrschende Störeinflüsse (z. B. Leitungsübersprechen, Einstreuungen durch elektromagnetische Felder, Drift),
- Fusion von Sensordaten gleicher und unterschiedlicher Messparameter zur Ermittlung von bauwerksbezogenen Zustandsparametern,
- Interpolation von Sensordaten als Eingangsgrößen rechnergestützter Systemmodelle zu Schadensprognosen (Erzeugung zeitlich und örtlich kontinuierlicher plausibler Eingangsdatenströme),



**Bild 1:** Die in diesem Projekt entwickelten Konzepte sollen störungsbehaftete Mess- und Prüfdaten auf Plausibilität überprüfen, relevante Information herausfiltern und weitergehende qualifizierte Monitoringinformation extrahieren. Für die Ausgangswerte kann stets eine Qualitätsaussage getroffen werden, d. h., wie genau die Schätzung bzw. Aussage ist



- Ableitung höherwertiger Information zu Zustandsparametern mit jeweils abgegrenztem messtechnischem bzw. bauwerksbezogene Aussagegehalt.

### **Plausibilisierung von Sensordaten**

Die Sensoren zur Erfassung von Messwerten beim robusten Brückenmonitoring unterliegen im Vergleich zu anderen Messeinrichtungen starken mechanischen und umweltbedingten Beanspruchungen. Für die Verwendung der Mess- und Prüfwerte in einem Brückenmodell zur Bestimmung der Systemzuverlässigkeit ist es somit zwingend erforderlich, diese auf Plausibilität zu beurteilen und somit ein Mindestmaß an Vertrauen in die Qualität der Daten zu haben. Es ist vorteilhaft, bereits am Anfang der Messkette eine Plausibilitätskontrolle durchzuführen. Nur durch die frühzeitige Plausibilisierung von Sensordaten von Brückenbauwerken kann verhindert werden, dass offensichtlich fehlerhafte Messwerte (wie z. B. Messausreißer, störungsbehaftete Messungen) zu falschen Vorhersagen der Systemzuverlässigkeit von Brückenbauwerken führen.

### **Fusion von Sensordaten**

Sensordatenfusion bedeutet das informative Zusammenführen von Daten bzw. Information von verschiedenen Sensoren. Für eine umfassende echtzeitbasierte Zustandsbewertung von Brückenbauwerken ist es zudem erforderlich, die relevanten Informationen aus den einzelnen ggf. störungsbehafteten Mess- bzw. Erfassungsdaten herauszufiltern. Da zwischen vielen erfassten Messwerten am Bauwerk eine große Abhängigkeit besteht, z. B. zwischen Dehnung und Temperatur, ist eine Kombination mehrerer Messgrößen zur Extraktion der relevanten störungsfreien Information notwendig. Weiterhin ist die Unterdrückung von Störeinflüssen aus dem regulären Betrieb des Bauwerksmonitoring z. B. Rauschen/Brummen im Messsignal, Überlagerung von Signalanteilen durch nicht ausreichend kompensierte Sensorik, die Erkennung von Effekten der Alterung einzelner Komponenten der Mess- bzw. Prüfkette (Sensoren, Messverstärker, AD-Wandler), je nach Anwendungsfall und Schwere der Störung notwendig. Insbesondere die Kompensation von Temperaturabhängigkeiten verschiedener physikalischer Erfassungsdaten, die Bereinigung von ungewollten Tagesschwankungen und allgemein die Glättung der sonst rauschbehafteten

Messdaten sind notwendige Schritte zur Erzeugung bzw. Vorbereitung der Eingangsdaten in ein nachgeschaltetes Brückenmodell. Die qualitative Verbesserung der Mess- und Erfassungsdaten die als Eingangsdaten für das Brückenmodell dienen, erhöht die qualitative Aussagekraft der gewonnenen Systemzuverlässigkeit. Nur durch die Fusion von Sensordaten kann verhindert werden, dass verrauschte, ungenaue Erfassungsdaten zu ungenauen Vorhersagen der Systemzuverlässigkeit führen.

### **Interpolation von Sensordaten**

Für die meisten Anwendungen beim robusten Brückenmonitoring stehen keine Sensorsysteme zur Verfügung, welche einen räumlich verteilten Prozess wie beispielsweise eine Temperaturverteilung über das Bauwerk als Ganzes erfassen. Aus diesem Grund muss man sich mit Sensoren begnügen, welche den Prozess lediglich zu diskreten Zeitpunkten an diskreten Ortspunkten erfassen. Für die Nutzung als Eingangsgrößen numerischer Schadensprognosen müssen diese diskreten Messungen mittels einer örtlichen und zeitlichen Interpolation in Beziehung gesetzt werden. Bei dieser Interpolation wird somit aus diesen diskretisierten Sensordaten auf das Verhalten des Prozesses an beliebigen zeitlichen und örtlichen Punkten geschlossen. Nur durch die zeitliche und örtliche Interpolation von Sensordaten kann verhindert werden, dass Effekte durch die zeitdiskreten Messintervalle und Ungenauigkeiten in der Platzierung der Sensoren (z. B. Messausreißer, Messlücken) zu falschen Vorhersagen der Systemzuverlässigkeit führen.

### **Ableitung höherwertiger Information**

Neben plausibilisierten Mess- und Prüfdaten können auch weitere höherwertige parameterbezogene und ggf. bauphysikalisch formulierte Monitoringinformation schon auf der Sensordatenauswertungsebene bereitgestellt werden. Für die genaue Vorhersage der Systemzuverlässigkeit aus dem Brückenmodell ist dies kein notwendiger Schritt; allerdings können diese höherwertigen Information (wie z. B. Änderungsraten, Signalverläufe) in irgendeiner Form genutzt werden, um noch mehr fachtechnische Erkenntnisse auch aus dem Brückenmodell zu gewinnen. Diese Information können als ergänzende qualifizierte Eingangsinformation für andere numerisch-aussagenlogisch basier-

te Bauwerksmodelle zur Erhöhung von deren Ausagesicherheit und möglichen Differenzierung von Schadensbildern genutzt werden. Nur durch die Ableitung höherwertiger Information sind monitoring-bezogene relevante Erkenntnisse zu Änderung, Verhalten sowie Verläufen einzelner Parameter und somit ein Treffen fachtechnischer Aussagen möglich.

## 1.2 Einordnung des Sensor-Überwachungssystems

Die zentrale Aufgabe des Sensor-Überwachungssystems stellt die Gewinnung und Plausibilisierung von Informationen aus den zuvor akquirierten Messdaten dar. Dieser Prozess basiert auf der Analyse der Messdaten mithilfe von Modellen. Dabei werden mehrere Sensoren zur Erfassung von Einwirkungs-, Tragfähigkeits- und Dauerhaftigkeitsparametern eingesetzt.

Für die Verarbeitung der Daten können verschiedene Verfahren angewendet werden, diese reichen von modelbasierten Ansätzen bis zu Algorithmen aus dem Bereich des maschinellen Lernens. Um zuverlässige und belastbare Aussagen zu erhalten, ist insbesondere die Plausibilisierung der Rohdaten und des Ergebnisses sehr wichtig.

In Bild 2 und Bild 3 sind das allgemeine Konzept des Sensor-Überwachungssystems und die Einordnung in das robuste Brückenmonitoring dargestellt. In diesem Projekt wird hauptsächlich auf die Verar-

beitungskette ohne Rückkopplung (d. h. Steuerung, Maßnahmen und Zusatzwissen) eingegangen, die Rückkopplungszweige werden nur vollständigkeitshalber aufgeführt.

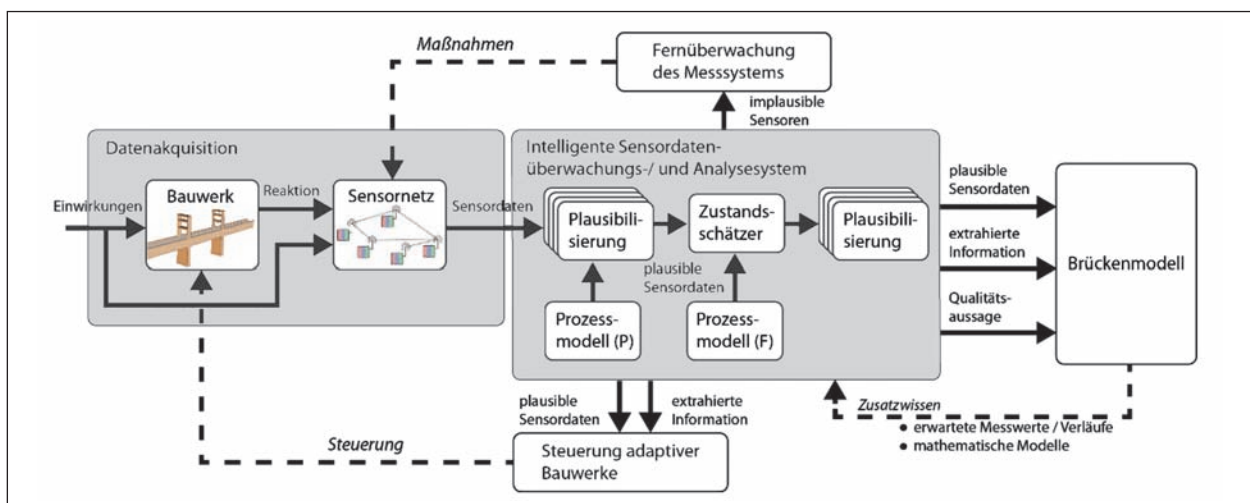
Die plausibilisierten Erfassungsdaten und die abgeleiteten höherwertigen Information können von verschiedenen Bausteinen bzw. Modulen, die beim robusten Brückenmonitoring eine Rolle spielen, genutzt werden.

- Brückenmodell

Die überprüften Erfassungsdaten und die abgeleitete höherwertige Information dienen dem Brückenmodell als Eingangssignal. Im Falle von nicht plausiblen Erfassungsdaten werden dem Brückenmodell korrigierte Daten basierend auf einem Prozessmodell zur Verfügung gestellt. Nur durch diese Aufbereitung der Erfassungsdaten kann auch das Brückenmodell zuverlässige und belastbare Aussagen über den Brückenzustand treffen. Durch eine Rückkopplung vom Brückenmodell kann Zusatzwissen in Form von mathematischen Modellen bei der Informationsgewinnung genutzt werden, um die genutzten Prozessmodelle zu verbessern.

- Fernüberwachung des Sensorsystems

Die Ausgangsdaten können von einem überlagerten Fernüberwachungssystem zur Überwachung der einzelnen Sensoren genutzt werden. Dadurch können für Sensoren, die keine plausiblen Erfassungsdaten liefern, entsprechende



**Bild 2:** Darstellung des in diesem Projekt entwickelten Konzeptes zur Sensorfusion, Plausibilisierung und Reduktion von Mess- und Prüfdaten bei der Überwachung von Bauwerken bzw. Brücken. Ziel ist es, aus den störungsbehafteten Erfassungsdaten robuste, belastbare Eingangsdaten für ein überlagertes Brückenmodell und eine Fernüberwachung des Messsystems und/oder Bauwerkes bereitzustellen

Maßnahmen für das Sensorsystem getroffen werden. Dies beinhaltet die Funktionsüberprüfung, aber auch die Erkennung von Alterungsercheinungen der Sensoren.

- Steuerung von adaptiven Bauwerken

Die abgeleiteten höherwertigen Information können zur Steuerung von adaptiven Bauwerken eingesetzt werden (Bauwerkssteuerung), um somit den Einwirkungen auf das Bauwerk entgegenzuwirken. Dabei kommt es insbesondere auf die Extraktion robuster, zuverlässiger und belastbarer Information aus den Erfassungsdaten an.

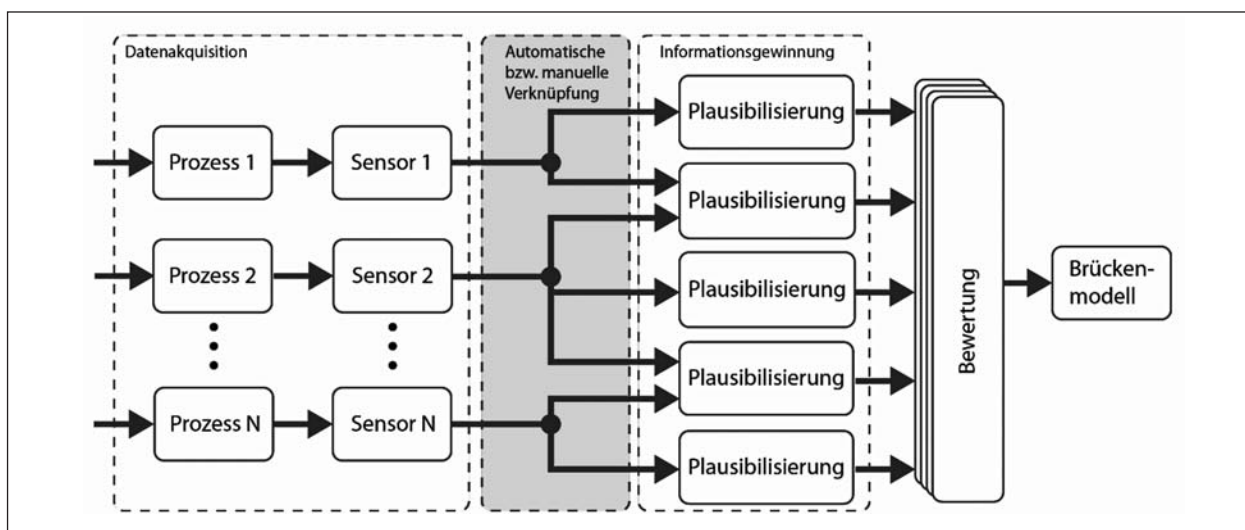
### 1.3 Ziel des Forschungsprojektes

Das Ziel dieses Forschungsprojektes ist die Ausarbeitung einer Konzeption zu Anforderungen an die Aufbereitung und Verarbeitung von Messgrößen und ihrer Darstellung. Dies beinhaltet die Evaluierung und Entwicklung verschiedener Algorithmen, die über den bisherigen Stand der Technik der Bauwerksüberwachung hinausgehen. Der Nutzen liegt in der Herausfilterung relevanter Informationen aus umfangreichem Datenmaterial (Vor-Aggregation) sowie der Erzeugung von belastbaren Zustandsinformationen bzw. Vorergebnissen hierzu durch frühzeitige Plausibilisierung. Es werden Konzepte entwickelt und die Machbarkeit robuster Algorithmen erprobt, die zuverlässige Aussagen über die gemessenen Größen bestimmen. Das Ergebnis soll fehlertolerant bezüglich

Ausreißern und Störungen der Mess- und Prüfdaten sein. Hierdurch sollen die Zuverlässigkeit und Aussagekraft eines hieraus abgeleiteten Brückenzustands erhöht werden.

Da die Komponenten des Überwachungssystems u. U. rauen Bedingungen im Freien ausgesetzt sind, wodurch die Funktionsweise und Lebensdauer der Sensoren eingeschränkt sein können, muss neben dem Bauwerk auch das Überwachungssystem durchgängig überprüft werden. Im Rahmen dieses Forschungsprojektes sollen Konzepte und Algorithmen untersucht werden, die die Überwachung aller Messgrößen erlauben. Die zu untersuchenden Algorithmen sollen zur Erhöhung der Plausibilität und der Genauigkeit der bestimmten Größen beitragen. Weiterhin soll, um die Anwendbarkeit auch in größeren Szenarien sicherzustellen, eine Reduktion des zu übertragenden Datenvolumens stattfinden. Dies kann zum Beispiel mit einer ausschließlichen Übertragung der entsprechenden Zustandsparameter anstatt der Messrohdaten erfolgen.

Zudem werden die Machbarkeit der entwickelten und untersuchten Verfahren und Ansätze anhand von realen Erfassungsdaten erprobt und evaluiert. Dabei werden in verschiedenen Szenarien verschiedene Aspekte des robusten Brückenmonitorings einzeln untersucht. Hierfür werden basierend auf verschiedenen Sensordaten unterschiedliche Algorithmen untersucht, welche die Sensordaten nach den oben genannten Voraussetzungen verarbeiten.



**Bild 3:** Darstellung des Konzepts für eine sehr große Anzahl an Sensoren ( $N > 50$ ). Dabei werden unterschiedliche Sensoren miteinander auf Plausibilität hin überprüft. Die Verknüpfung kann dabei automatisch (beispielsweise durch Korrelationsanalysen) oder manuell (beispielsweise bei nahe liegenden Sensoren) durchgeführt werden

## 1.4 Untersuchungsmethodik

Für die methodische Vorgehensweise zur Erfüllung der geforderten Aufgabenstellung und zur Erreichung der oben genannten Projektziele ergaben sich die folgenden Arbeitsschritte:

1. Entwicklung Gesamtkonzept  
Für die Komponente Sensor-Überwachung wird ein Gesamtkonzept entwickelt und deren Schnittstellen zu den relevanten Bereichen Brückenmodell, Fernüberwachung des Sensorsystems und Steuerung adaptiver Bauwerke konzeptioniert und dargestellt.
2. Recherche Analyseverfahren  
Für die oben genannten Einsatzbereiche werden Analyseverfahren recherchiert und deren Einsatzbarkeit aus theoretischen Gesichtspunkten untersucht. Das Augenmerk liegt dabei auf modellbasierten und statistischen Analyseverfahren, die eine gedächtnisbehafte selbstlernende Signalverarbeitungsstruktur aufweisen.
3. Prototypische Implementierung  
Für die spätere Studie der Einsatzbarkeit in den oben genannten Bereichen des robusten Brückenmonitorings werden ausgewählte Algorithmen prototypisch implementiert. Es wurden die Bayes'schen Ansätze (z. B. Kalman-Filter) stellvertretend für modellbasierte und die künstlichen neuronalen Netze stellvertretend für statische Analyseverfahren als aussichtsreichste Ansätze ausgewählt und für die spätere Machbarkeitsstudie prototypisch implementiert.
4. Machbarkeitsstudie  
Anhand von realen Mess- und Erfassungsdaten wird die Machbarkeit einer praktischen Umsetzung der modellbasierten und statistischen Analyseverfahren in den oben genannten Einsatzbereichen evaluiert. Dabei werden in verschiedenen Szenarien verschiedene Aspekte des robusten Brückenmonitorings einzeln untersucht. Für die folgenden Sensoren standen reale Messdaten zur Verfügung und wurden entsprechend untersucht:
  - (a) Multiring-Elektrode mit Temperatursensor PT 1000,
  - (b) Temperatur-Array von Kanalbrücke Berkenthin,
  - (c) Wegaufnehmer erhoben am realen Bauwerk und
  - (d) Verkehrslastdaten.

5. Untersuchung zur praktischen Umsetzung  
Es werden verschiedene Aspekte detaillierter untersucht, wie zum Beispiel eine Darstellung verfügbarer Sensorbusse aus der industriellen Messtechnik, redundante Auslegung der Analyseverfahren zur Erhöhung der Zuverlässigkeit und eine Energieverbrauchsschätzung für einen möglichen energieautarken Einsatz.
6. Ableitung von Empfehlungen  
Basierend auf den gewonnenen Erkenntnissen der vorangegangenen Arbeitsschritte und der langjährigen Erfahrung der Autoren werden für verschiedene Einsatzbereiche Empfehlungen abgegeben; diese berücksichtigen theoretische und praktische Gesichtspunkte.

## 1.5 Gliederung

Kapitel 2 gibt einen kurzen Überblick über die im robusten Brückenmonitoring wichtigen Messgrößen und die typischerweise verwendeten Sensoren.

In Kapitel 3 werden verschiedene Modelle für die Beschreibung der unterlagerten dynamischen Prozesse und der Mess- und Prüfdaten, die beim robusten Brückenmonitoring eine Rolle spielen, vorgestellt. Diese Modellbeschreibung ist für die modellbasierte Sensorfusion und Plausibilisierung ein wichtiger Bestandteil.

Verfahren und Ansätze zur Plausibilisierung, Datenfusion und Ableitung höherwertiger Information werden in Kapitel 4 erörtert. Dabei werden ein Überblick über existierende Verfahren sowie eine kurze Einführung in die Thematik und Funktionsweise stochastischer Zustandsschätzer gegeben. Weiterhin liegt der Fokus auf statistischen und maschinelle Lernverfahren für die Plausibilisierung gemessener Größen. Diese Verfahren zeichnen sich durch ein Minimum an notwendigem Prozesswissen aus, allerdings ist eine gewisse Menge an Testdaten notwendig.

Die Anwendung der in den vorherigen Kapiteln diskutierten Verfahren findet in Kapitel 5 auf eine Auswahl im robusten Brückenmonitoring relevanter Szenarien statt. Hier werden reale Erfassungsdaten verarbeitet und die Ergebnisse diskutiert.

Aspekte der praktischen Umsetzung und Implementierung bezüglich der benötigten Energiemenge der modellbasierten Algorithmen sowie Überlegungen zur Erhöhung der Zuverlässigkeit der Plausibilisierung durch Redundanz sind in Kapitel 6 dargelegt.

## 2 Erfassung von Einwirkung und Bauteilreaktionen

Ein umfassendes echtzeitbasiertes Monitoring von Bauwerken bzw. Brücken beinhaltet eine kontinuierliche Erfassung und Auswertung relevanter Bauwerksparameter mit geeigneter Sensorik über einen längeren Zeitraum (1). In verschiedenen Bereichen des Bauwesens werden sowohl drahtlose als auch drahtgebundene Sensortechnologien eingesetzt.

Für die Entwicklung eines möglichst allgemeingültigen Konzeptes für die intelligente automatische Verarbeitung von Mess- und Prüfdaten im Bauwerksmonitoring ist es notwendig, ein möglichst breites Spektrum von Sensorprinzipien und -technologien mit unterschiedlichsten Sensorcharakteristiken und Störeigenschaften zu berücksichtigen. In Gesprächen mit der BAST wurden die folgenden Einwirkungs- und Reaktionsparameter als besonders wichtig für die Entwicklung eines Konzeptes für die Sensorfusion, Plausibilisierung und Reduktion von Erfassungsdaten im robusten Brückenmonitoring eingestuft:

### 2.1 Temperatur

Zu den grundlegenden Untersuchungen im Rahmen eines umfassenden Bauwerksmonitorings gehören die kontinuierliche Erfassung und Auswertung der Luft- und Bauwerkstemperatur (2). Die Temperatur hat direkte Auswirkung auf die eingesetzten Baustoffe und somit auf das Gesamtbauwerk. Zudem sind viele Bauwerksparameter, die mit geeigneter Sensorik erfasst werden, stark temperaturabhängig und müssen entsprechend kompensiert bzw. mit besonderen Algorithmen herausgerechnet werden. Für die Erfassung der Temperatur steht eine Vielzahl von Sensoren zur Verfügung, beispielsweise Thermoelemente und Widerstandsthermometer.

Thermoelemente bestehen im Prinzip aus zwei unterschiedlichen Metallen, die an einem Ende miteinander verbunden sind. Eine Temperaturdifferenz erzeugt durch den Wärmefluss eine elektrische Spannung, die gemessen werden kann und somit direkte Rückschlüsse auf die Temperatur erlaubt. Die Thermoelemente sind robust, kostengünstig, benötigen keine externe Stromquelle und weisen eine kurze Ansprechzeit auf, allerdings ist ihre Sensitivität begrenzt (3).

Widerstandsthermometer bestehen ähnlich wie Thermistoren aus temperaturabhängigen elektrischen Widerständen (NTC-Widerstände oder PTC-Widerstände) und bieten somit eine Möglichkeit, über die Messung der Widerstände auf die Temperatur zu schließen. Widerstandsthermometer sind robust und genauer als Thermoelemente, allerdings relativ teuer und besitzen eine längere Ansprechzeit (3).

### 2.2 Material- und Luftfeuchtigkeit

Ein weiterer häufig gemessener Bauwerksparameter ist die Bauwerksfeuchte. Die Feuchteverteilung im Bauwerk kann mithilfe von Multiring-Elektroden bestehend aus mehreren, meistens jedoch acht, übereinander angeordneten Edelstahlringen bestimmt werden. Zwischen zwei benachbarten Ringen kann ein Wechselstromwiderstand gemessen werden und daraus ein Widerstandsprofil über die gesamte Einbautiefe des Sensors bestimmt werden. Durch eine materialabhängige Kalibrierkurve kann diese in ein Feuchteprofil umgerechnet werden (4).

Faseroptische Sensoren nutzen spezifische optische Eigenschaften von Materialien, oft auch der Faser selbst, zum Messen physikalischer Größen wie Temperatur, Feuchtigkeit oder Dehnung (5). Die faseroptischen Sensoren sind unempfindlich gegenüber Strahlung und extremer Witterung, allerdings ist das Messsystem teuer (3).

### 2.3 Chlorid

Bei Stahlbeton- und Spannbetonbrücken stellt die Korrosion der Bewehrung den bedeutendsten Schadenstyp dar. Für ein sogenanntes Korrosionsmonitoring ist es erforderlich, die Schädigung des Bauwerkes durch Chloridangriffe zu erfassen. Obwohl die Sensoren verschiedene Größen erfassen, ist das Messprinzip bei allen dasselbe; es erfolgt eine tiefengestaffelte Anordnung mehrerer Einzelanoden und in Abhängigkeit der freien Chloride im Beton stellt sich am Sensor das Potenzial bezüglich einer Referenzelektrode ein. Durch mehreren Schichten, ähnlich wie bei der Multiring-Elektrode für Feuchte, in unterschiedlichen Tiefen kann ein entsprechendes Chloridprofil bestimmt werden (6, 7).

## 2.4 Dehnung/Spannung

Für die Dehnungs- und Spannungsmessung überwiegen Technologien basierend auf Widerstandsmessungen, wie beispielsweise Dehnmessstreifen (DMS), bei denen sich der Widerstand eines Messgitters in Abhängigkeit von Verformung ändert (8, 9, 10). Die Dehnmessstreifen sind kostengünstig und können nachträglich am Bauwerk angebracht werden, allerdings können diese nur über kurze Messdistanzen eingesetzt werden, sind anfällig gegenüber elektromagnetischen Einflüssen und empfindlich gegenüber Temperatur und Feuchtigkeit. Somit müssen zur Kompensation Temperatur und Feuchtigkeit in der Nähe des Dehnmessstreifens gemessen werden.

## 2.5 Beschleunigung/Vibration

Mechanische Schwingungen (Erschütterungen und Vibration) können mittels spezieller Beschleunigungssensoren gemessen werden (11, 12). Für ein umfassendes, echtzeitbasiertes Monitoring sind insbesondere Piezosensoren und MEMS-Sensoren geeignet. Die Piezosensoren sind robust, temperaturunempfindlich, besitzen eine hohe Genauigkeit und großen Frequenzbereich. MEMS-Sensoren sind kostengünstig, sehr stromsparend und besitzen eine geringe Abmessung (3).

## 2.6 Rissentwicklung/Rissöffnung

Für die Überwachung und Verfolgung von Rissbreiten schon vorhandener Risse stehen verschiedene Sensortechnologien zur Verfügung. Die weiteste Anwendung in der Praxis finden spezielle Dehnmessstreifen (Riss-DMS) zur Erfassung der Rissentwicklung bzw. der Rissöffnung. Dabei werden die Messstreifen direkt über den bereits vorhandenen Riss geklebt. Nimmt die Rissaufweitung zu, werden allerdings die Messstreifen zerstört. Für die Verformungsmessung über längere Messstrecken kann eine große Anzahl potenziometrische, induktiver oder auch kapazitiver Wegaufnehmer eingesetzt werden (13).

## 2.7 Verkehrslasten

Die zuverlässige Zustandsbewertung von Bauwerken bzw. Brücken erfordert stets die Kenntnis der vorhandenen Beanspruchung durch Verkehrs-

lasten. Diese Größe kann mit Methoden der Lastidentifikation ermittelt werden. Im Allgemeinen können die Methoden zur Identifikation von Verkehrslasten in direkte und indirekte Methoden unterteilt werden. Bei den direkten Methoden wird das Fahrzeuggewicht direkt mithilfe von Weight-in-Motion, (WIM-)Systemen gemessen. Dabei werden Plattensensoren und Streifensensoren für die Bestimmung der Verkehrslast eingesetzt. Es ist auch vorstellbar, Kamerasysteme für eine genauere Last einzusetzen. Bei den indirekten Methoden wird das gesamte Bauwerk bzw. Brücke als Sensorelement genutzt. An verschiedenen Stellen werden Dehnmessstreifen oder Wegaufnehmer angebracht und über bestimmte Algorithmen auf die Verkehrslast geschlossen (14).

## 3 Mathematische Modellierung des System- und Messverhaltens

Im Allgemeinen dient das mathematische Modell der Beschreibung eines Systems oder Prozesses wie beispielsweise der Feuchteverteilung im Bauwerk. Das Modell setzt sich aus einer Modellstruktur sowie Modellparametern zusammen. Es werden Beziehungen zwischen den Eingangsgrößen und den Ausgangsgrößen abgebildet (15).

### Systemgrenzen

Die genaue mathematische Beschreibung des Modells hängt stark von den definierten Systemgrenzen ab. Wird das gesamte Bauwerk bzw. Brücke als System betrachtet, können beispielsweise die Belastung als Eingangsgröße und die Durchbiegung als Ausgangsgrößen angenommen werden. Auch die Sensoren können als einzelne Systeme, in dem Fall sogenannte Messsysteme, mit ihren entsprechenden Systemgrenzen betrachtet werden. In diesem Projekt wird die Messeinrichtung als einzelnes System mit den entsprechenden Grenzen modelliert. Die mathematische Beschreibung des unterlagerten zu beobachtenden Prozess kann hierbei zur Plausibilisierung der Mess- und Prüfdaten herangezogen werden.

### 3.1 Systemzustand zur Beschreibung physikalischer Systeme

#### Definition Systemzustand

Als Systemzustand  $\underline{x}(t)$  werden die physikalischen Größen bezeichnet, die den Zustand des unterlagerten Prozesses eindeutig beschreiben. Sind zu einer beliebigen Zeit  $t = t_0$  die Elemente von  $\underline{x}(t_0)$  zusammen mit dem zukünftigen Verlauf des Systemeingangs  $\underline{u}(t)$  für  $t_0 \leq t \leq t_e$  bekannt, so sind die einzelnen Elemente der Zustandsgröße  $\underline{x}(t_e)$  und der Ausgangsgröße  $\underline{y}(t_e)$  eindeutig bestimmt. Wird eine Zeitdiskretisierung durchgeführt, so bezeichnet  $\underline{x}_k$  den Systemzustand zum diskreten Zeitpunkt  $t = t_k$ . Je nach unterlagertem System, das beschrieben werden soll, können verschiedene physikalische Größen als Zustandsvariable verwendet werden. Bei elektrischen Systemen sind es normalerweise Ströme und Spannungen, wohingegen bei mechanischen Systemen in der Regel Wege, Winkel, Geschwindigkeiten und Beschleunigungen als Systemzustand verwendet werden.

Die Systemzustände sind also physikalische Größen, die das Verhalten von Speicherelementen wie z. B. Kapazitäten, Induktivitäten, Massen oder Federn beschreiben. Bei bekannten Eingangsrößen und bekanntem Systemzustand zum aktuellen Zeitpunkt kann das zukünftige Systemverhalten also vorhergesagt werden. Somit repräsentiert der Systemzustand  $\underline{x}(t)$  das Gedächtnis des unterlagerten dynamischen Prozesses bzw. Systems (16).

#### Beispiel Multiring-Elektrode – Systemzustand

Als Beispiel soll hier kurz die Multiring-Elektrode mit integriertem PT-1000-Element zur Bestimmung der Feuchtigkeit in einer bestimmten Tiefe betrachtet werden. Das Systemverhalten der zu messenden

Feuchtigkeit in einem infinitesimalen Bereich des Bauwerks ist eindeutig durch die Zustandsvariablen Betonfeuchte  $f^B$  und Temperatur  $T$  beschrieben. Somit ist der Zustandsvektor gegeben durch

$$\underline{x}_k = \begin{bmatrix} T_k \\ f_k^B \end{bmatrix}$$

Die Multiring-Elektrode liefert die beiden Widerstände  $R_f$  (für den Feuchtesensor) und  $R_T$  (für das PT-1000-Element) als Messsignal. Somit ist der Messvektor gegeben durch

$$\underline{y}_k = \begin{bmatrix} R_T \\ R_f \end{bmatrix}$$

Das mathematische Modell, die sogenannte Messgleichung, versucht, die Beziehung zwischen der Betonfeuchte  $f_k^B$  und der Temperatur  $T_k$  und den gemessenen Widerständen  $R_f$  und  $R_T$  zu beschreiben. In Bild 4 ist der Zusammenhang zwischen dem Systemzustand  $\underline{x}_k$  am Eingang und den Sensordaten  $\underline{y}_k$  am Ausgang der Messeinrichtung am Beispiel der Multiring-Elektrode dargestellt.

#### Probabilistischer Ansatz

Bei einem probabilistischen Ansatz wird der Systemzustand  $\underline{x}_k$  als Zufallsvariable, beschrieben durch eine Wahrscheinlichkeitsverteilung  $f_{\underline{x}_k}$ , modelliert. Für die Wahrscheinlichkeitsverteilung gibt es verschiedene Darstellungsformen, siehe Bild 5. Je nach Anwendung muss die Wahrscheinlichkeitsverteilung zur probabilistischen Beschreibung des Systemzustands unterschiedlich modelliert werden. Die Bandbreite der Modellierung reicht dabei von einer einfachen Normalverteilung (charakterisiert durch Mittelwert und Standardabweichung) bis hin zu komplexen Modellierungen durch Gaußmischverteilungen.

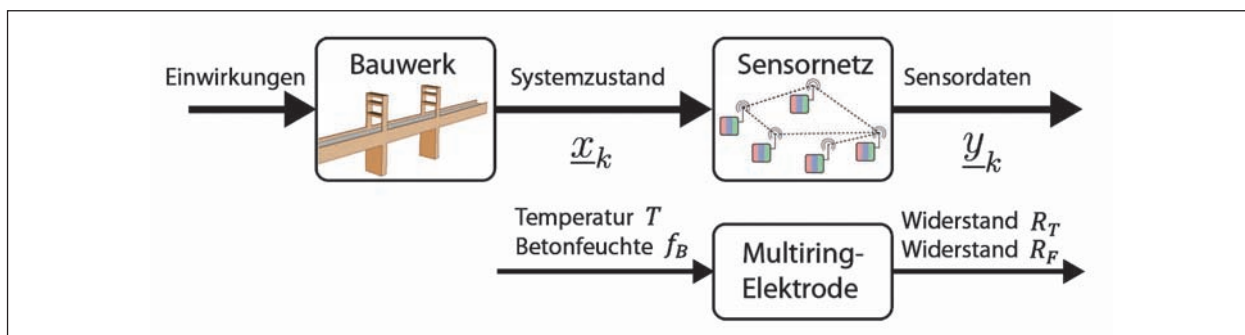


Bild 4: Definition des Systemzustands  $\underline{x}_k$  und der Sensordaten  $\underline{y}_k$  am Beispiel der Multiring-Elektrode

## Normalverteilung

Eine wichtige Wahrscheinlichkeitsverteilung ist beispielsweise durch die eben genannte Normalverteilung gegeben. Ihre Verteilungsdichte  $f(x_k)$  kann wie folgt beschrieben werden

$$f(x_k) = N(x_k - \mu_k, \sigma_k) \\ = \frac{1}{\sqrt{2\pi}} \cdot \exp\left(-\frac{1}{2} \cdot \left(\frac{x - \mu_k}{\sigma_k}\right)^2\right)$$


wobei  $\mu_k$  den Mittelwert und  $\sigma_k$  die Standardabweichung der Zufallsgröße  $x_k$  darstellen. In Bild 5 (b) ist ein Beispiel für eine Normalverteilung mit Mittelwert  $\mu_k = 1.75$  und Standardabweichung  $\sigma_k = 0.5$  dargestellt. Mithilfe der Normalverteilung ist es möglich, beliebige Verteilungsfunktionen zu approximieren. Diese sogenannten Gaußmischverteilungsdichten können wie folgt beschrieben werden

$$f(x_k) = \sum_i \alpha_k^{(i)} \cdot N(x_k - \mu_k^{(i)}, \sigma_k^{(i)})$$

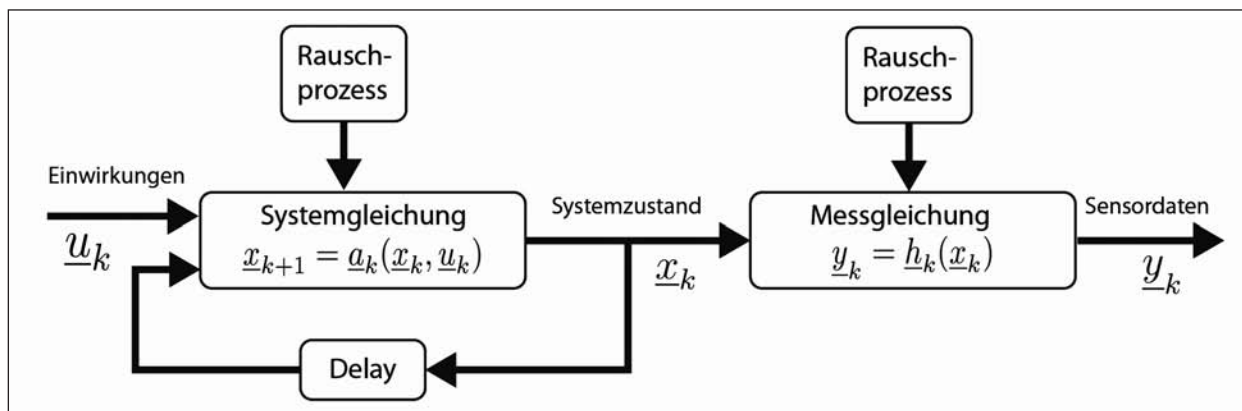
wobei  $\alpha_k^{(i)}$  die Gewichte der einzelnen Normalverteilungen darstellen und es gilt  $\sum_i \alpha_k^{(i)} = 1$ . In Bild 5 (c) ist ein Beispiel für eine Gaußmischverteilungsdichte mit drei Komponenten dargestellt. Diese allgemeine Approximationseigenschaft der Normalverteilung wird in vielen Anwendungen der Daten- und Informationsverarbeitung ausgenutzt, um effiziente und präzise Verfahren und Algorithmen zu entwickeln (17, 18, 19, 20, 21).

## Arten mathematischer Modelle

Für die Bestimmung des physikalischen Systemzustands  $\underline{x}_k$  basierend auf den Sensordaten  $\underline{y}_k$  sind verschiedene Typen mathematischer Modelle notwendig. Die probabilistische Systemgleichung beschreibt das dynamische Verhalten des Systemzustands und die probabilistische Messgleichung die Wirkung des unterlagerten physikalischen Prozesses auf konkrete Messungen, siehe Bild 6. In den folgenden Kapiteln werden diese beiden Gleichungen genauer beschrieben.



**Bild 5:** Verschiedene Wahrscheinlichkeitsverteilungen für die probabilistische Beschreibung des Systemzustands. (a) deterministische Beschreibung, bei der der Wert des Zustands exakt bekannt ist, (b) Normalverteilung und (c) komplexe Verteilung durch Gaußmischverteilungen



**Bild 6:** Darstellung der Systemgleichung zur Beschreibung des dynamischen Verhaltens des physikalischen Systemzustands  $\underline{x}_k$  und der Messgleichung zur Beschreibung der Wirkung auf die konkreten Messungen



### 3.2 Mathematische Modelle zur Beschreibung des dynamischen Systemverhaltens

#### 3.2.1 Überblick und Klassifizierung physikalischer Prozesse

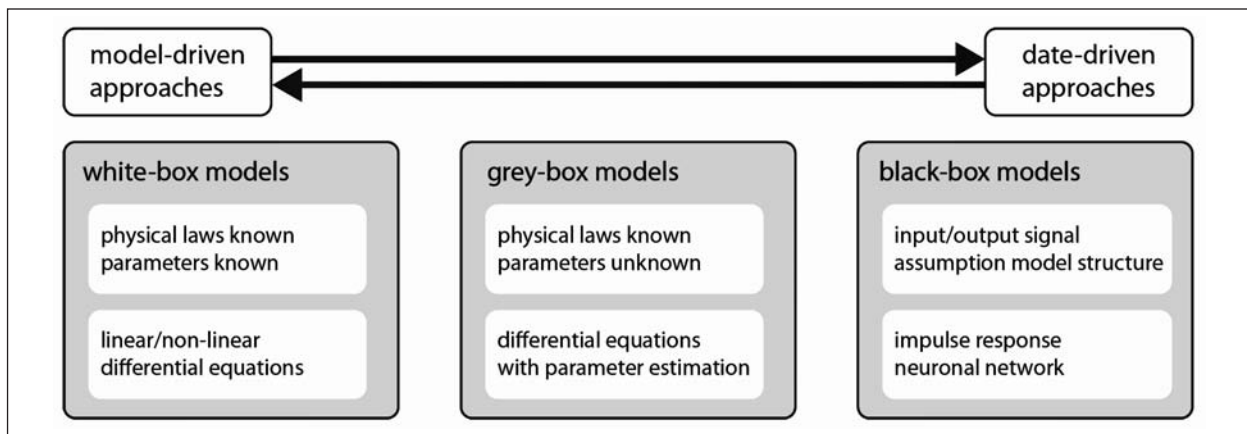
Je nach Anwendungsbereich im robusten Brückenmonitoring kann die Form des mathematischen Modells stark variieren, siehe Bild 7. Im Fall von bekannter Modellstruktur und bekannten Modellparametern spricht man von sogenannten White-Box-Modellen. Bei den Grey-Box-Modellen ist zwar die Modellstruktur bekannt, aber die Modellparameter sind unbekannt und müssen mittels entsprechender Identifikationsverfahren ermittelt werden. Eine Möglichkeit, die Modellparameter zur Laufzeit zu bestimmen, ist, den Systemzustand  $x_k$  durch diese Modellparameter zu erweitern und mittels eines modellbasierten Zustandsschätzers zu identifizieren. Bei den sogenannten Black-Box-Modellen sind weder Modellparameter noch Modellstruktur bekannt. Hierzu zählen datengetriebene Modellierungsansätze, die beispielsweise mittels Impulsant-

worten oder künstlichen neuronalen Netzen die Beziehung zwischen Ein- und Ausgangssignalen beschreiben, siehe Kapitel 4.3.

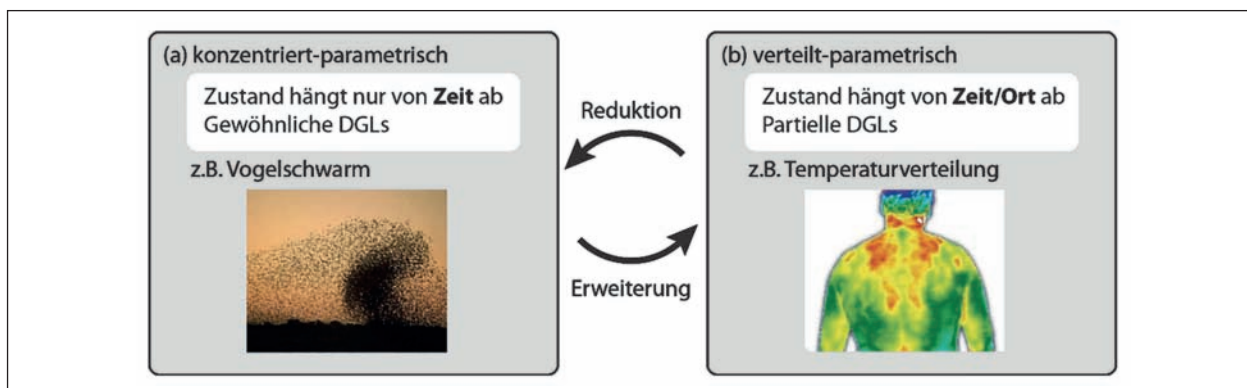
#### Klassifikation von Systemen

Es gibt eine Vielzahl von Möglichkeiten, um physikalische Prozesse, die im robusten Brückenmonitoring eine Rolle spielen, zu beschreiben. In diesem Projekt werden Prozesse als entweder statische<sup>1</sup> oder dynamische Systeme und als entweder konzentriert-parametrische oder verteilt-parametrische Systeme klassifiziert, siehe Bild 8. Ein statisches System verändert sich über die Zeit nicht, aber im Fall eines verteilt-parametrischen Systems sehr wohl über seine Ortsvariable, währenddessen sich der Kennwert eines dynamischen Systems zusätzlich mit der Zeit ändert.

<sup>1</sup> Mit dem Begriff „statisches System“ ist hier nicht der Begriff aus der Baustatik gemeint, sondern die Eigenschaft eines allgemeinen Systems, sich nicht zu verändern. Somit gehört hier zum Beispiel auch ein ruhendes Pendel zu den statischen Systemen.



**Bild 7:** Klassifikation von mathematischen Modellen nach dem Gesichtspunkt, welche Information über Modellstruktur und Modellparameter bekannt oder unbekannt ist und dadurch noch identifiziert bzw. geschätzt werden muss



**Bild 8:** Klassifikation von physikalischen Prozessen in konzentriert-parametrische und verteilt-parametrische Systeme

### Verteilt-parametrische Systeme

Verteilt-parametrische Systeme haben die Eigenschaft, dass ihre Kennwerte nicht nur alleine von der Zeit abhängen. Vielmehr sind diese zusätzlich räumlich verschmiert, d. h. vom Ort abhängig. Zur Beschreibung eines räumlich verteilten Prozesses werden Systeme von partiellen Differenzialgleichungen (PDE) verwendet. Diese beschreiben die Wechselwirkung zweier zeitlich und räumlich benachbarter Punkte in Abhängigkeit eines Eingangssignals. Ein typisches Beispiel für ein verteilt-parametrisches System ist eine Temperatur- oder Feuchteverteilung. Die Auswirkungen von Konzentrationsunterschieden werden durch die Diffusions-PDE beschrieben.

### Konzentriert-parametrische Systeme

Konzentriert-parametrische Systeme zeichnen sich dadurch aus, dass ihre physikalischen Zustandsvariablen in einzelnen Raumpunkten konzentriert sind, d. h., die Systemvariablen hängen nur von der Zeit, nicht aber vom Ort ab. In vielen praktischen Anwendungen ist es ausreichend, sich auf solche Systeme zu beschränken. Konzentriert-parametrische Systeme lassen sich durch ein System gewöhnlicher Differenzialgleichungen (DGL) beschreiben. Ein Beispiel für ein konzentriert-parametrisches System ist das Flugverhalten eines Vogelschwarms. Position und Geschwindigkeit der einzelnen Vögel beschreiben den Zustand dieses Prozesses in erster Näherung vollständig.

Die zeitdiskrete konzentriert-parametrische Systemgleichung beschreibt den Zusammenhang zwischen einem Systemzustand  $\underline{x}_k$  zur diskreten Zeit  $t_k$  und dem darauffolgenden Systemzustand  $\underline{x}_{k+1}$ . Ein allgemein angenommener Fall eines nichtlinearen Zusammenhangs hat oft folgende Form:

$$\underline{x}_{k+1} = \underline{a}_k(\underline{x}_k, \underline{u}_k) + \underline{w}_k$$

wobei  $\underline{a}_k(\cdot)$  die vektorielle Systemfunktion zur diskreten Zeit  $t_k$  beschreibt und  $\underline{w}_k$  unbekannte und nicht modellierte Einflüsse und Störgrößen, wie z. B. zeitliche Diskretisierungsfehler, subsumiert. Durch den zusätzlichen Rauschterm  $\underline{w}_k$  wird der Tatsache Rechnung getragen, dass die zeitliche Entwicklung des Systemzustandes selbst bei gegebenem Anfangszustand als nicht gesichert angenommen werden kann. Ist die Systemfunktion über die Zeit konstant, so spricht man von zeitinvarianten Systemen. Für den in der Praxis weitverbreite-

ten Fall des linearen Zusammenhangs ergibt sich die folgende Form der zeitdiskreten konzentriert-parametrischen Systemgleichung:

$$\underline{x}_{k+1} = A_k \cdot \underline{x}_k + B_k \cdot \underline{u}_k + \underline{w}_k$$

wobei  $A_k$  und  $B_k$  Matrizen sind. Sind zusätzlich die Matrizen  $A_k = A$  und  $B_k = B$  zeitunabhängig, erhält man ein lineares zeitinvariantes System.

### 3.2.2 Präzise Modellierung des unterlagerten physikalischen Prozesses (SysMo1)

Die meisten physikalischen Prozesse, die beim robusten Brückenmonitoring eine Rolle spielen, können als verteilt-parametrische Systeme betrachtet werden. Bei einer präzisen Modellierung ist deshalb die Beschreibung der physikalischen Größe mittels eines Systems von stochastischen partiellen Differenzialgleichungen (PDE) notwendig. Diese Gleichung beschreibt nicht nur die zeitliche Wechselwirkung, sondern auch die örtliche Wechselwirkung beispielsweise bei Temperaturunterschieden in der Brücke. Die am häufigsten in der Praxis verwendete PDE ist die Diffusionsgleichung mit evtl. konvektiven Termen. Damit kann beispielsweise die Temperatur-, Feuchte- oder Spannungsverteilung in Brückenabschnitten sehr präzise modelliert werden (22, 23).

Auch bei vielen Schädigungsvorgängen spielen insbesondere räumliche Abhängigkeiten der jeweiligen physikalischen Größe eine wichtige Rolle. Diese können entweder als stochastische PDE oder als räumliche Zufallsfelder beschrieben werden (24, 25, 26, 27). Durch solch eine Beschreibung kann der Informationsgewinn an einer beliebigen Stelle auf der Oberfläche genutzt werden, um auch an den umgebenden Orten die physikalische Größe zu aktualisieren und somit einen zusätzlichen Informationsgewinn zu erzielen.

Es gibt zwei große Aufgabenstellungen, die bei einer präzisen Modellierung des unterlagerten physikalischen Prozesses für die Sensorfusion und die Plausibilisierung gelöst werden müssen. Die eine zu lösende Teilaufgabe ist die hohe Komplexität und Rechenaufwand solcher Modelle, insbesondere wenn die Sensordaten lokal vor Ort, d. h. im Sensorknoten, fusioniert und auf Plausibilität überprüft werden sollen. Die andere zu lösende Teilaufgabe ist die Vielzahl an unbekanntem Parametern. Dazu kommt, dass insbesondere bei einem inhomogenen System wie einer Brücke diese Parameter vom Ort abhängig und somit als verteilt-parametrisch

angenommen werden müssen. Die präzise Modellierung ist deshalb sehr aufwändig und steht in keinem Verhältnis zu dem Genauigkeits- und Robustheitsgewinn für die Sensorfusion und die Plausibilisierung. Hierfür ist es lohnenswert, einfachere Modelle zu finden, die für eine Plausibilisierung der Mess- und Prüfdaten ausreichen.

### 3.2.3 Allgemein physikalische Modellierung (SysMo2)

Wie im vorherigen Kapitel erläutert, ist die detaillierte Modellierung aller physikalischen Effekte bei vielen physikalischen Größen und Sensoren, die beim robusten Brückenmonitoring vorkommen sehr aufwändig und steht für die Sensorfusion und die Plausibilisierung in keinem Verhältnis zu dem Genauigkeits- und Robustheitsgewinn. Deshalb ist es insbesondere für die Datenplausibilisierung oft zweckmäßiger, sich auf möglichst einfache, allgemeingültige Gesetzmäßigkeiten zu beschränken. Die dabei auftretenden Ungenauigkeiten können einfach in die Modellierung des Rauschprozesses beaufschlagt werden.

In vielen Fällen kann angenommen werden, dass sich beispielsweise die Temperatur in einem Bauteil

oder Sensor nicht sprungartig ändern kann, sondern eine gewisse Zeit benötigt wird, um die beteiligten, thermischen Massen auszugleichen. Diese Trägheit bei vielen physikalischen Prozessen kann durch ein sogenanntes PV-Modell (P steht für die physikalische Größe und V für deren zeitliche Ableitung) oder allgemeiner durch ein PVA-Modell (A steht für die zweite zeitliche Ableitung) beschrieben werden.

Je nach betrachteter physikalischer Größe können unterschiedliche allgemeine Gesetzmäßigkeiten als Grundlage für die Modellierung der Systemgleichung dienen. Beispielsweise bei der Temperatur kann das allgemeine Ausgleichsverhalten der beteiligten thermischen Massen herangezogen werden. Bei der Beschleunigung können einfache Bewegungsgesetze der beteiligten Bauteilmassen und bei der Lufttemperatur einfach meteorologische Zusammenhänge als Grundlage dienen.

Im Folgenden werden zwei Beispiele zur einfachen allgemeinen physikalischen Modellierung des unterlagerten Prozesses gegeben, einmal die Modellierung eines Temperatursensors und einer Multi-ring-Elektrode. In beiden Fällen dient ein allgemeines Modell zur Beschreibung von Trägheit und Glattheitseigenschaften als Grundlage für das Systemmodell.

Temperatur	<b>Modellierung:</b> Temperaturverteilung in Bauwerksabschnitten, in der Regel inhomogene PDE <b>Eigenschaften:</b> aufwändige Modellierung, viele unbekannte Parameter und Störeinflüsse bzw. Eingangsgrößen für PDE, aufwändige Anpassung für jedes Bauwerk
Feuchtigkeit (Luft-/Materialfeuchte)	<b>Modellierung:</b> Feuchtigkeitsverteilung in Bauwerksabschnitten, in der Regel inhomogene PDE, Abhängigkeit von Temperatur <b>Eigenschaften:</b> komplexe Gesetzmäßigkeiten, hohe Temperaturabhängigkeit, viele unbekannte Parameter und Störeinflüsse bzw. Eingangsgrößen für PDE, aufwändige Anpassung für jedes Bauwerk
Dehnung/Spannung	<b>Modellierung:</b> Dehnung/Spannungsverläufe in Bauwerksabschnitten, in der Regel inhomogene PDE, Abhängigkeit von Temperatur und Verkehrslasten <b>Eigenschaften:</b> komplexe Gesetzmäßigkeiten, hohe Temperaturabhängigkeit, viele unbekannte Materialparameter, viele unbekannte Parameter und Störeinflüsse bzw. Eingangsgrößen (z. B. Wind- und Verkehrslasten) für PDE, aufwändige Anpassung für jedes Bauwerk
Beschleunigung (Schwingung)	<b>Modellierung:</b> Schwingverhalten (z. B. Modalanalyse) von Bauwerksabschnitten bzw. der gesamten Brücke, in der Regel (großes) System von DGL (konzentriert-parametrisch) <b>Eigenschaften:</b> viele unbekannte Materialparameter, viele unbekannte Parameter und Störeinflüsse bzw. Eingangsgrößen (z. B. Wind- und Verkehrslasten) für DGL, aufwändige Anpassung für jedes Bauwerk
Rissentwicklung	<b>Modellierung:</b> Fortentwicklung eines Risses im Bauwerk, in der Regel inhomogene PDE, Abhängigkeit von Verkehrslasten und Temperatur <b>Eigenschaften:</b> komplexe und teils unbekannte Materialgesetze, Einsatz von FEM schwierig da sich Struktur sprungartig ändert, Abhängigkeiten von Verkehrslast und Temperatur schwer modellierbar, unbekannte Störeinflüsse bzw. Eingangsgröße (z. B. Wind- und Verkehrslasten)
Verkehrslasten	<b>Modellierung:</b> Schwingverhalten (z. B. Modalanalyse) von Bauwerksabschnitten bzw. der gesamten Brücke, in der Regel (großes) System von DGL (konzentriert-parametrisch) <b>Eigenschaften:</b> viele unbekannte Material- und Einwirkungsparameter, Störeinflüsse, aufwändige Anpassung an jedes Bauwerk erforderlich

**Tab. 1:** Mögliche Einsatzbereiche und Eigenschaften präziser physikalischer Systemmodelle für die Sensorfusion und Plausibilisierung

### Beispiel Temperatursensor – PV-Modell

In diesem Beispiel wird auf ein allgemeines physikalisches Modell für einen einfachen Temperatursensor (PT-1000-Element) eingegangen. Im Fall des Temperatursensors kann der Zustandsvektor  $\underline{x}_k$  wie folgt erweitert werden

$$\underline{x}_k = \begin{bmatrix} T_k \\ \dot{T}_k \end{bmatrix}$$

wobei  $T_k$  die Temperatur und  $\dot{T}_k$  deren zeitliche Ableitung, d. h. Temperaturänderungsgeschwindigkeit, darstellen. Für die Herleitung des PV-Modells wird angenommen, dass sich zwischen zwei diskreten Zeitpunkten  $t_k$  und  $t_{k+1}$  die Temperatur nur mit konstanter Geschwindigkeit ändert. Somit ergibt sich die folgende lineare konzentriert-parametrische Systemgleichung

$$\underline{x}_{k+1} = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix} \cdot \underline{x}_k + \underline{w}_k$$

wobei  $\Delta t$  die Zeitdiskretisierung beschreibt. Für den Rauschprozess  $\underline{w}_k$ , der auch die Korrelation bzw. Abhängigkeiten zwischen der Temperatur und deren Änderung beschreibt, gibt es nun verschiedene Möglichkeiten der Modellierung. In vielen praktischen Fällen kann dieser als normalverteilt angenommen werden mit folgender Kovarianzmatrix

$$C_k^w = q_k^T \cdot Q_k \quad \text{mit} \quad Q_k = \begin{bmatrix} \Delta t^4/4 & \Delta t^3/2 \\ \Delta t^3/2 & \Delta t^2 \end{bmatrix}$$

wobei  $q_k^T$  die Unsicherheit auf der Temperaturänderung darstellt. Dieser Parameter kann entweder aus der Sensorspezifikation entnommen oder durch Versuchsreihen ermittelt werden. Aus dieser Gleichung für die Kovarianzmatrix  $C_k^w$  wird die Abhängigkeit bzw. Korrelation zwischen der Temperatur  $T_k$  und deren Änderung  $\dot{T}_k$  ersichtlich. Auf eine Herleitung dieser Gleichung wird aus Platzgründen an dieser Stelle verzichtet, es wird vielmehr auf die Literatur verwiesen (17).

### Beispiel Multiring-Elektrode – PV-Modell

In diesem Beispiel wird auf ein allgemeines, physikalisches Modell für eine Multiring-Elektrode mit integriertem Temperatursensor eingegangen. In diesem Fall kann der Zustandsvektor  $\underline{x}_k$  wie folgt erweitert werden

$$\underline{x}_k = \begin{bmatrix} T_k \\ \dot{T}_k \\ f_k^B \\ \dot{f}_k^B \end{bmatrix}$$

wobei  $T_k$  die Temperatur und  $\dot{T}_k$  deren zeitliche Ableitung und  $f_k^B$  die Betonfeuchte und  $\dot{f}_k^B$  deren zeit-

Temperatur	<b>Modellierung:</b> physikalische Trägheit von Wärmeausbreitungen <b>Eigenschaften:</b> einfache Bestimmung der Parameter, einfache Modellierung z. B. durch PV-Modell, Berücksichtigung von Trägheit und Glattheitseigenschaften, ausreichend für Sensorfusion und Plausibilisierung, geringe Anpassung für jedes Bauwerk
Feuchtigkeit (Luft-/Materialfeuchte)	<b>Modellierung:</b> physikalische Trägheit von Feuchtigkeitsausbreitung, Abhängigkeiten von Temperatur <b>Eigenschaften:</b> einfache Modellierung z. B. durch PV-Modell, einfache Bestimmung der Parameter, Temperaturabhängigkeit kann einfacher berücksichtigt werden, Berücksichtigung von Trägheiten und Glattheitseigenschaften, ausreichend für Sensorfusion und Plausibilisierung, geringe Anpassung für jedes Bauwerk
Dehnung/Spannung	<b>Modellierung:</b> Glattheitseigenschaften von Dehnung- und Spannungsverteilungen in Bauwerksabschnitten (Annahme: im Bauwerk gibt es keine zeitliche Sprünge), Abhängigkeit von Temperatur und Verkehrslasten <b>Eigenschaften:</b> einfache Modellierung z. B. durch PV-Modell, einfache Bestimmung der Parameter, Temperaturabhängigkeit kann einfacher berücksichtigt werden, geringe Anpassung für jedes Bauwerk, ausreichend für Sensorfusion und Plausibilisierung
Beschleunigung (Schwingung)	<b>Modellierung:</b> physikalische Trägheit von sich bewegenden Massen, Abhängigkeit von Temperatur <b>Eigenschaften:</b> einfache Modellierung durch Bewegungsmodell, einfache Bestimmung der Parameter, geringe Anpassung für jedes Bauwerk, ausreichend für Sensorfusion und Plausibilisierung
Rissentwicklung	<b>Modellierung:</b> physikalische Trägheit zwischen einzelnen sprungartigen Rissweiterentwicklung, Abhängigkeit von Temperatur und Verkehrslasten <b>Eigenschaften:</b> einfache Modellierung durch Bewegungsmodell, Unterscheidung zwischen Phasensprung und Ausreißer schwierig, unbekannte Störeinflüsse bzw. Eingangsgröße (z. B. Wind- und Verkehrslasten)
Verkehrslasten	<b>Modellierung:</b> physikalischen Trägheit von sich bewegenden Massen <b>Eigenschaften:</b> einfache Modellierung durch Bewegungsmodell, einfache Bestimmung der Parameter, geringe Anpassung für jedes Bauwerk, ausreichend für Sensorfusion und Plausibilisierung

**Tab. 2:** Möglicher Einsatzbereich und Eigenschaften allgemeiner physikalischer Systemmodelle (z. B. PV-Modelle) für die Sensorfusion und Plausibilisierung

liche Ableitung darstellen. Ähnlich wie im vorherigen Beispiel wird für die Herleitung des PV-Modells angenommen, dass sich zwischen zwei diskreten Zeitpunkten  $t_k$  und  $t_k + 1$  die Temperatur und die Betonfeuchte nur mit konstanter Geschwindigkeit ändern. Somit ergibt sich die folgende lineare konzentriert-parametrische Systemgleichung:

$$\underline{x}_{k+1} = \begin{bmatrix} 1 & \Delta t & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \underline{x}_k + \underline{w}_k$$

wobei  $\Delta t$  die Zeitdiskretisierung beschreibt. Für den Rauschprozess  $\underline{w}_k$  gibt es nun verschiedene Möglichkeiten der Modellierung. In vielen praktischen Fällen kann dieser als normalverteilt angenommen werden mit der Kovarianzmatrix

$$C_k^w = \begin{bmatrix} q_k^t \cdot Q_k & \underline{0} \\ \underline{0} & q_k^f \cdot Q_k \end{bmatrix} \text{ mit}$$

$$Q_k = \begin{bmatrix} \Delta t^4/4 & \Delta t^3/2 \\ \Delta t^3/2 & \Delta t^2 \end{bmatrix}$$

wobei  $q_k^t$  die Unsicherheit der Temperaturänderung und  $q_k^f$  die Unsicherheit der Betonfeuchteänderung darstellen. Diese Parameter können entweder aus der Sensorspezifikation entnommen oder durch Versuchsreihen ermittelt werden. Auf eine Herleitung dieser Gleichung wird aus Platzgründen an dieser Stelle verzichtet, es wird vielmehr auf die Literatur verwiesen (17).

### 3.2.4 Multiple-Modelle-Ansätze (SysMo3)

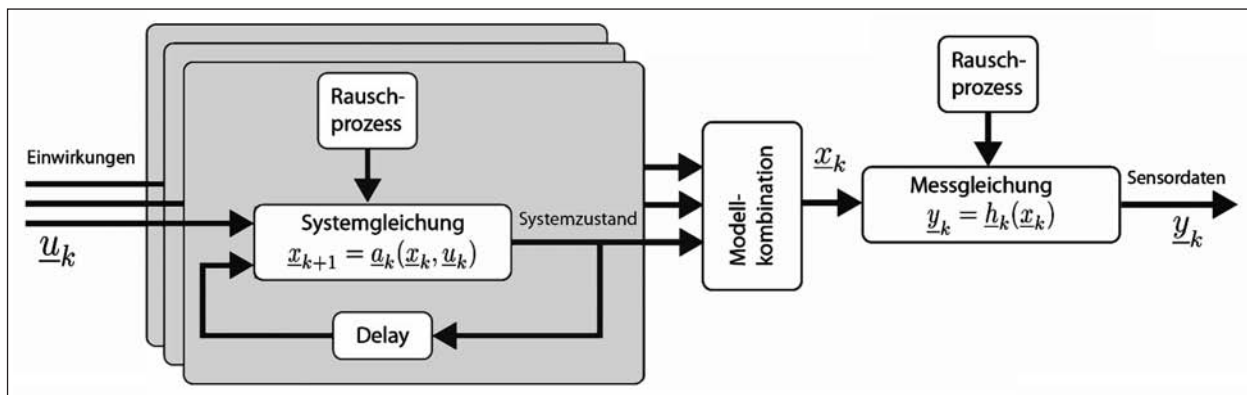
Das dynamische Verhalten vieler physikalischer Prozesse kann beim robusten Brückenmonitoring eine Rolle spielen, jedoch ist es in vielen Fällen

nicht möglich, dieses dynamische Verhalten durch ein einzelnes Systemmodell hinreichend zu beschreiben. Beispielsweise kann das dynamische Verhalten bei starken Temperaturanstiegen völlig anders sein als bei einem starken Temperaturabfall bei einem Wettersturz. Eine Möglichkeit, diese Unterschiede zu berücksichtigen, ist, eine endliche Anzahl von möglichen Modellen anzunehmen, die das unterschiedliche Systemverhalten beschreiben, siehe Bild 9. Diese Modelle können sich z. B. im Rauschpegel, in der Systemstruktur/Parameter oder in der Dimensionalität des Zustands unterscheiden. Ein Signal, welches zu unterschiedlichen Zeitpunkten beispielsweise zwischen langsamen und schnellen Veränderungen wechselt, kann mit zwei Systemmodellen beschrieben werden.

Je nach Situation ändert sich die Gewichtung der einzelnen Modelle und somit passt sich der Algorithmus adaptiv an. Weiterhin können höherwertige Information aus den Modellgewichten abgeleitet werden. Algorithmen, die einen Multiple-Modelle-(MM-)Ansatz verwenden, können in statische und dynamische MM-Verfahren unterschieden werden. Bei statischen MM-Verfahren können die Modelle über die Zeit nicht wechseln. Bei dynamischen MM-Verfahren wechseln die einzelnen Modelle basierend auf einer Markov-Kette mit bekannter Übergangsmatrix der Auftrittswahrscheinlichkeiten der einzelnen Modelle. Praktikable dynamische MM-Verfahren sind die „Generalized Pseudo-Bayesian“ (GPB) und „Interacting Multiple Model“ (IMM). Im Folgenden sollen die Multiple-Modelle-Ansätze beispielhaft erklärt werden (28).

### Beispiel Temperatursensor – Multiple Modelle

In diesem Beispiel wird auf einen Multiple-Modelle-Ansatz für einen einfachen Temperatursensor



**Bild 9:** Darstellung mehrerer Systemgleichungen zur Beschreibung des dynamischen Verhaltens des physikalischen Systemzustands  $\underline{x}_k$  bei einem Multiple-Modelle-Ansatz

(PT-1000-Element) eingegangen. Es werden drei verschiedene Modelle angewendet, jeweils ein Modell für (1) konstante Temperatur, (2) konstanten Anstieg bzw. Abfall und (3) überproportionalen Anstieg bzw. Abfall der Temperatur. Die drei verschiedenen Modelle werden durch ein P-Modell (für konstantes Verhalten), PV-Modell (für lineares Verhalten) und PVA-Modell (für überproportionales Verhalten) beschrieben. Dadurch ergeben sich die drei folgenden Zustandsvektoren:

$$\underline{x}_k^{(1)} = T_k \quad \underline{x}_k^{(2)} = \begin{bmatrix} T_k \\ \dot{T}_k \end{bmatrix} \quad \underline{x}_k^{(3)} = \begin{bmatrix} T_k \\ \dot{T}_k \\ \ddot{T}_k \end{bmatrix}$$

wobei  $T_k$  die Temperatur und  $\dot{T}_k$  deren zeitliche Ableitung und  $\ddot{T}_k$  deren zweite zeitliche Ableitung darstellen. Somit ergeben sich die folgenden linearen konzentriert-parametrischen Systemgleichungen:

$$\text{P-Modell} \quad \underline{x}_{k+1}^{(1)} = \underline{x}_k^{(1)} + \underline{w}_k^{(1)}$$

$$\text{PV-Modell} \quad \underline{x}_{k+1}^{(2)} = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix} \cdot \underline{x}_k^{(2)} + \underline{w}_k^{(2)}$$

$$\text{PVA-Modell} \quad \underline{x}_{k+1}^{(3)} = \begin{bmatrix} 1 & \Delta t & \Delta t^2/2 \\ 0 & 1 & \Delta t \\ 0 & 0 & 1 \end{bmatrix} \cdot \underline{x}_k^{(3)} + \underline{w}_k^{(3)}$$

wobei  $\Delta t$  die Zeitdiskretisierung beschreibt. Je nach Situation ändert sich die Gewichtung der einzelnen Modelle. Bei konstanter Temperatur hat das P-Modell eine höhere Gewichtung, bei konstantem Anstieg hat das PV-Modell eine höhere Gewichtung und bei einem überproportionalen Anstieg hat das PVA-Modell eine höhere Gewichtung. Die Gewichtung wird automatisch durch einen entsprechenden Zustandsschätzer angepasst. Weiterhin kann anhand der Modellgewichtung höherwertige Information extrahiert werden, beispielsweise ob es gerade einen Temperaturanstieg im System gibt.

Temperatur	<p><b>Modellierung:</b> Verschiedene Modelle für verschiedene Zustandsphasen z. B. Temperatur steigt/fällt, Erkennung der Zustandsphasen</p> <p><b>Eigenschaften:</b> einfache Modellierung z. B. durch Kombination von P-Modell, PV-Modell und PVA-Modell, einfache Bestimmung der Parameter, ausreichend für Sensorfusion und Plausibilisierung, geringer Anpassungsaufwand an jedes Bauwerk</p>
Feuchtigkeit (Luft-/Materialfeuchte)	<p><b>Modellierung:</b> Verschiedene Modelle für verschiedene Zustandsphasen z. B. Feuchtigkeit steigt/fällt, Erkennung der Zustandsphasen</p> <p><b>Eigenschaften:</b> einfache Modellierung z. B. durch Kombination von P-Modell, PV-Modell und PVA-Modell, einfache Bestimmung der Parameter, ausreichend für Sensorfusion und Plausibilisierung, geringer Anpassungsaufwand an jedes Bauwerk</p>
Dehnung/Spannung	<p><b>Modellierung:</b> Verschiedene Modelle für wenig Änderungen und sprungartige Veränderungen, Erkennung von Sprüngen und Lastwechseln</p> <p><b>Eigenschaften:</b> einfache Modellierung durch Kombination verschiedener Bewegungsmodelle, einfache Bestimmung der Parameter, Temperaturabhängigkeit kann einfacher berücksichtigt werden, geringer Anpassungsaufwand an jedes Bauwerk, ausreichend für Sensorfusion und Plausibilisierung</p>
Beschleunigung (Schwingung)	<p><b>Modellierung:</b> Verschiedene Modelle für kleine und sprungartige Bewegungen, Erkennung von Sprüngen und Lastwechseln</p> <p><b>Eigenschaften:</b> einfache Modellierung durch Kombination verschiedener Bewegungsmodelle, einfache Bestimmung der Parameter, geringer Anpassungsaufwand an jedes Bauwerk, ausreichend für Sensorfusion und Plausibilisierung</p>
Rissentwicklung	<p><b>Modellierung:</b> Verschiedene Modelle für kleine und sprungartige Bewegungen, Erkennung von sprungartigen Rissweiterentwicklungen</p> <p><b>Eigenschaften:</b> einfache Modellierung durch Kombination verschiedener Bewegungsmodelle, Unterscheidung zwischen Phasensprung und Ausreißer schwierig, unbekannte Störeinflüsse bzw. Eingangsgröße (z. B. Wind- und Verkehrslasten)</p>
Verkehrslasten	<p><b>Modellierung:</b> Verschiedene Modelle für kleine und sprungartige Bewegungen (z. B. durch Überfahrt eines Fahrzeuges), Erkennung von Lastwechseln</p> <p><b>Eigenschaften:</b> einfache Modellierung durch Kombination verschiedener Bewegungsmodelle, einfache Bestimmung der Parameter, geringer Anpassungsaufwand an jedes Bauwerk, ausreichend für Sensorfusion und Plausibilisierung</p>

**Tab. 3:** Mögliche Einsatzbereiche und Eigenschaften von Multiple-Systemmodellen für die Sensorfusion und Plausibilisierung

### 3.2.5 Separierung von Signalen (SysMo4)

Durch eine entsprechende Wahl des probabilistischen Systemmodells können weitergehende qualifizierte Monitoringinformation aus den Erfassungsdaten extrahiert werden. Es können nicht direkt messbare Kenngrößen ermittelt werden, wie beispielsweise Temperaturtrend-Geschwindigkeiten, siehe Bild 10. Die beim robusten Brückenmonitoring relevanten Mess- und Prüfsignale entstehen in den meisten Fällen durch verschiedenartige physikalische Effekte. Deshalb können diese Signale in verschiedene Bestandteile getrennt werden, wie z. B. Trennung in langsamere und schnelle Veränderungen.

Der Zustandsvektor  $\underline{x}_k$  einer physikalischen Größe kann somit in die Komponenten Trend, Geschwindigkeit des Trends und periodische Schwankungen aufgeteilt werden. In diesem Fall würde das probabilistische Systemmodell aus mehreren linearen Systemmodellen bestehen, die jeweils die unterschiedlichen zeitlichen Veränderungen berücksichtigen. Für den Trend und die Geschwindigkeit des Trends kann ein PV-Modell bzw. ein PVA-Modell verwendet werden (29). Diese Modelle werden in Kapitel 3.2.3 anhand verschiedener Beispiele näher beschrieben. Für die Tag-/Nacht-Schwankungen können dynamische sinusförmige Modelle verwendet werden (30, 31). Diese Modelle werden im folgenden Beispiel näher beschrieben.

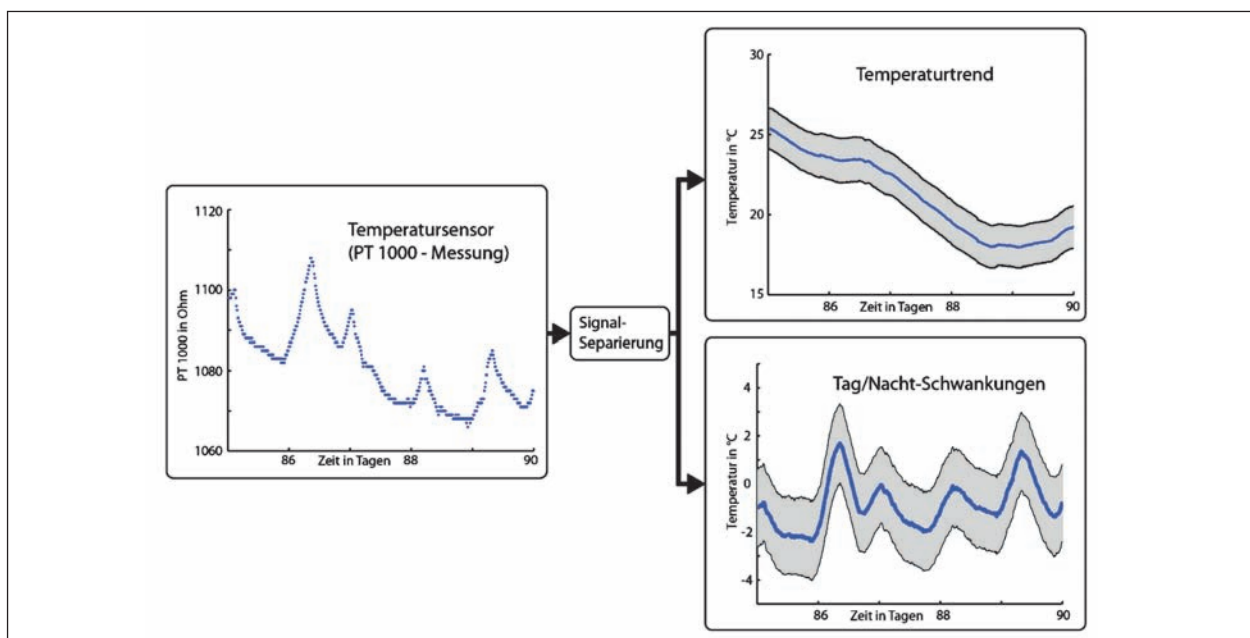
### Beispiel Temperatursensor – Tag-/Nacht-Schwankungen

In diesem Beispiel wird auf die Modellierung der Tag-/Nacht-Schwankungen eines Temperatursensors eingegangen, siehe Bild 10. In diesem Fall kann der Zustandsvektor  $\underline{x}_k$  wie folgt erweitert werden

$$\underline{x}_k = \begin{bmatrix} T_k \\ \dot{T}_k \\ S_k^x \\ S_k^y \end{bmatrix}$$

wobei  $T_k$  die Temperatur und  $\dot{T}_k$  deren zeitliche Ableitung darstellt. Die zeitliche Änderung der Tag-/Nacht-Schwankung wird durch die beiden Zustandsvariablen  $S_k^x$  und  $S_k^y$  beschrieben. Für die Herleitung des PV-Modells wird angenommen, dass sich zwischen zwei diskreten Zeitpunkten  $t_k$  und  $t_{k+1}$  die Temperatur nur mit konstanter Geschwindigkeit ändert. Die Tag-/Nacht-Schwankungen können als eine Art Kreisbewegung mit entsprechender Frequenz für die Tag-/Nacht-Wechsel modelliert werden (30, 31). Somit ergibt sich die folgende lineare, konzentriert-parametrische Systemgleichung

$$\underline{x}_{k+1} = \begin{bmatrix} 1 & \Delta t & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & \cos \omega_1 & -\sin \omega_1 \\ 0 & 0 & \sin \omega_1 & \cos \omega_1 \end{bmatrix} \cdot \underline{x}_k + \underline{w}_k$$



**Bild 10:** Separierung eines Temperatursignals in einen Temperaturtrend und Tag-/Nacht-Schwankungen. Die beiden Signale können getrennt für eine Datenplausibilisierung genutzt werden, beispielsweise durch eine Schwellenwertüberprüfung der Tag-/Nacht-Schwankungen [Quelle: reale Sensordaten einer Multiring-Elektrode bereitgestellt durch BAST]

Temperatur	<b>Modellierung:</b> Separierung des Temperatursignals in ein Trendsignal und Tag-/Nacht-Schwankungen <b>Eigenschaften:</b> beide Signale können getrennt voneinander auf Plausibilität überprüft werden
Feuchtigkeit (Luft-/Materialfeuchte)	<b>Modellierung:</b> Separierung des Feuchtesignals in ein Trendsignal und Tag-/Nacht-Schwankungen <b>Eigenschaften:</b> beide Signale können getrennt voneinander auf Plausibilität überprüft werden
Dehnung/Spannung	<b>Modellierung:</b> Separierung langfristige Trendsignal und Schwankungen hervorgerufen durch Temperaturänderungen <b>Eigenschaften:</b> beide Signale können getrennt voneinander auf Plausibilität überprüft werden, langfristige Trendsignal stellt höherwertige Information für Brückenmodell dar
Beschleunigung (Schwingung)	<b>Modellierung:</b> Separierung verschiedener Frequenzen (z. B. Eigenfrequenzen, Lastwechsel), Bestimmung eines Frequenzspektrums <b>Eigenschaften:</b> Amplituden verschiedener Frequenzen kann getrennt voneinander auf Plausibilität überprüft werden
Rissentwicklung	<b>Modellierung:</b> Separierung verschiedener Frequenzen (z. B. Eigenfrequenzen, Lastwechsel, Tag/Nacht-Schwankungen), Bestimmung eines Frequenzspektrums <b>Eigenschaften:</b> Amplituden verschiedener Frequenzen kann getrennt voneinander auf Plausibilität überprüft werden
Verkehrslasten	<b>Modellierung:</b> Separierung verschiedener Frequenzen (z. B. Anregung durch Lastwechsel), Bestimmung eines Frequenzspektrums, Bestimmung der Lastwechsel <b>Eigenschaften:</b> Lastwechsel können gezählt werden, Amplituden verschiedener Frequenzen kann getrennt voneinander auf Plausibilität überprüft werden

Tab. 4: Möglicher Einsatzbereich und Eigenschaften von einfachen Systemmodellen für periodische Schwankungen

wobei  $\Delta t$  die Zeitdiskretisierung beschreibt. Für den Rauschprozess  $w_k$  gibt es nun verschiedene Möglichkeiten der Modellierung. In vielen praktischen Fällen kann dieser als normalverteilt angenommen werden mit folgender Kovarianzmatrix

$$C_k^w = \begin{bmatrix} q_k^T \cdot Q_k & \underline{0} \\ \underline{0} & q_k^S \cdot I \end{bmatrix} \text{ mit}$$

$$Q_k = \begin{bmatrix} \Delta t^4/4 & \Delta t^3/2 \\ \Delta t^3/2 & \Delta t^2 \end{bmatrix}$$

wobei  $q_k^T$  die Unsicherheit der Temperaturänderung und  $q_k^S$  die Unsicherheit der Tag-/Nacht-Schwankung darstellt. Diese Parameter können entweder aus der Sensorspezifikation entnommen oder durch Versuchsreihen ermittelt werden. Auf eine Herleitung dieser Gleichung wird aus Platzgründen an dieser Stelle verzichtet, es wird vielmehr auf die Literatur verwiesen (17). Die so separierten Signale können getrennt voneinander auf ihre Plausibilität hin überprüft werden, beispielsweise durch eine Schwellenwertüberprüfung der Tag-/Nacht-Schwankungen.

### 3.3 Mathematische Modelle zur Beschreibung des Messverhaltens

#### 3.3.1 Exakte physikalische Modellierung der Mess- und Prüfdaten (MessMo1)

Für die Bestimmung des Systemzustands  $x_k$  aus den diskreten Messungen  $y_k$  benötigt man neben der Systemgleichung noch eine Messgleichung,

welche die Wirkung des unterlagerten physikalischen Prozesses auf konkrete Messungen beschreibt, siehe Bild 6. Die konkrete Struktur und Einflussgrößen der Messgleichung hängen sehr stark von dem jeweiligen Sensorprinzip ab. In den meisten Fällen kann die Messgleichung direkt aus den Kennlinienfeldern des jeweiligen Sensors abgeleitet werden.

Auch können Abhängigkeiten verschiedener physikalischer Mess- und Prüfgrößen untereinander in der Messgleichung beschrieben werden, z. B. die Temperaturabhängigkeit eines Feuchtesensors. Die zeitdiskrete nichtlineare Messgleichung

$$y_k = h_k(x_k) + v_k$$

bildet mit der Funktion  $h_k(\cdot)$  die Zustandsvariable  $x_k$  auf die Messungen  $y_k$  ab.  $v_k$  ist das Messrauschen, welches die Ungenauigkeiten, die bei einer realen Messung entstehen, subsummiert.

Selbst für recht einfache, beim robusten Brückenmonitoring vorkommende Messprinzipien, wie z. B. bei der Multiring-Elektrode, ist die Abbildungsfunktion  $h_k(\cdot)$  nichtlinear, siehe Beispiel Multiring-Elektrode – Messgleichung. Im linearen Fall ergibt sich die folgende zeitdiskrete, lineare Messgleichung

$$y_k = H_k \cdot x_k + v_k$$

wobei  $H_k$  eine Matrix ist. Ist zusätzlich die Matrize  $H_k = H$  zeitunabhängig, erhält man eine lineare zeitinvariante Messgleichung.



**Beispiel Multiring-Elektrode – Messgleichung**

In diesem Beispiel wird kurz auf die Messgleichung für die Multiring-Elektrode mit integriertem PT-1000-Element eingegangen. Die Messgleichung stellt die Beziehung zwischen dem Messsignal  $y_k$  bestehend aus den beiden gemessenen Widerständen  $R_T$  (am PT-1000-Element) und  $R_f$  (am Feuchtesensor) und dem Zustandsvektor  $x_k$  bestehend aus der Temperatur  $T_k$  und der Betonfeuchtigkeit  $f_k^B$  dar, siehe Beispiel Multiring-Elektrode – Systemzustand. An dieser Stelle wird betont, dass je nach Anwendungsszenario und Berücksichtigung von besonderen Messeffekten unterschiedliche Messgleichungen aufgestellt werden können. In dieser Forschungsarbeit soll die folgende Gleichung betrachtet werden

$$h_k(x_k) = \left[ \left( \text{Exp} \left\{ \frac{b_1}{f_k^B + b_2} + b_3 \right\} + b_4 \right) \cdot \text{Exp} \left\{ b_5 \cdot \left( \frac{1}{T_{ref}} - \frac{1}{T_k} \right) \right\} \right]$$

wobei  $a_1$  und  $a_2$  Kalibrierungsparameter für das PT-1000-Element und  $b_1, \dots, b_5$  Kalibrierungsparameter für den Feuchtesensor darstellen. Diese Parameter können entweder aus der jeweiligen Sensorspezifikation entnommen oder mittels Versuchsreihen ermittelt werden. In dieser Gleichung wird deutlich, dass der gemessene Widerstand  $R_f$  am Feuchtesensor stark von der aktuellen Temperatur  $T_k$  abhängt. Dadurch kann die Temperaturabhängigkeit bei der Sensorfusion und Plausibilisierung berücksichtigt bzw. kompensiert werden. Das Messrauschen  $v_k$  wird als normalverteilt, mittelwertfreies Rauschen modelliert. Weiterhin kann angenommen werden, dass die gemessenen Wider-

stände  $R_T$  und  $R_f$  unabhängige Größen sind, d. h. nicht korreliert sind. Somit ergibt sich die folgende Gleichung für das Messrauschen  $v_k$

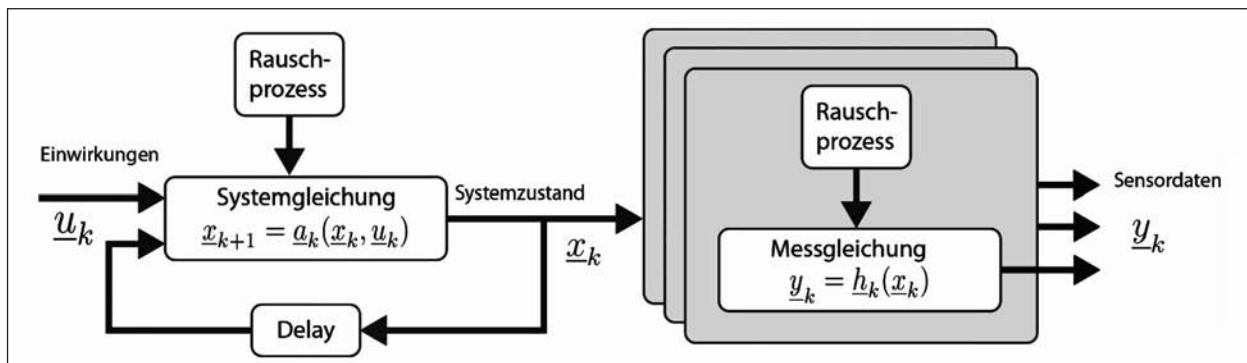
$$v_k \sim N \left( y_k - \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} C_k^T & 0 \\ 0 & C_k^f \end{bmatrix} \right)$$

wobei die Funktion  $N(\cdot)$  die zwei-dimensionale Normalverteilung darstellt.  $C_k^T$  ist die Varianz des PT-1000-Elements und  $C_k^f$  ist die Varianz des Feuchtesensors. Diese Werte können aus der Sensorspezifikation entnommen oder durch Versuchsreihen bestimmt werden.

**3.3.2 Multiple-Modelle-Ansatz (MessMo2)**

Es gibt einige Situationen beim robusten Brückenmonitoring, bei denen es nicht ausreichend ist, die Mess- und Prüfdaten durch ein einzelnes probabilistisches Messmodell zu beschreiben. Beispielsweise können die Störeinflüsse, wie Temperaturabhängigkeiten oder Sensorrauschen, in verschiedenen Situationen unterschiedlich sein. Auch können bestimmte Sensorparameter und Sensorkennlinien situationsbedingt variieren. Eine Möglichkeit, diese Unterschiede zu berücksichtigen, ist, eine endliche Anzahl von Modellen anzunehmen, die das unterschiedliche Verhalten der Mess- und Prüfdaten beschreiben, siehe Bild 11. Diese Modelle können sich z. B. im Rauschpegel, in der Modellstruktur/Parameter oder in der Dimensionalität des Messvektors unterscheiden.

Ähnlich wie beim Multiple-Modelle-Ansatz beim Systemmodell ändert sich die Gewichtung der einzelnen Modelle je nach Situation. Fängt der Sensor beispielsweise an stark zu rauschen, dann vergrößert sich die Gewichtung eines „Messmodells mit großem Messrauschen“ im Verhältnis zu einem



**Bild 11:** Darstellung verschiedener Messgleichungen zur Beschreibung der Mess- und Prüfdaten bei einem Multiple-Modelle-Ansatz

„Messmodell mit kleinem Messrauschen“. Dadurch wird bei der Sensorfusion der Einfluss der Messungen auf die aktuelle Schätzung verringert und es wird mehr Vertrauen dem probabilistischen Systemmodell gegeben. Verringern sich das Messrauschen des Sensors wieder und somit die Gewichtung des Messmodells, so erhöht sich auch automatisch der Einfluss der Messung auf die aktuelle Schätzung. Weiterhin kann die Gewichtung der Modelle als höherwertige Information, beispielsweise für eine Plausibilisierung der Mess- und Prüfdaten, genutzt werden.

### Beispiel Multiring-Elektrode – Multiple-Modelle-Ansatz

In diesem Beispiel wird auf ein Multiple-Modelle-Ansatz für eine Multiring-Elektrode mit integriertem PT-1000-Element eingegangen. Es werden zwei verschiedene Modelle angewendet, jeweils ein Modell für (1) großes Messrauschen und (2) kleines Messrauschen. Die beiden Messmodelle besitzen dieselbe Struktur wie in „Beispiel Multiring-Elektrode – Messmodell“ angegeben, allerdings unterscheidet sich das Messrauschen  $\underline{v}_k$  wie folgt

$$\underline{v}_k^{(1)} \sim N\left(\underline{y}_k - \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}\right)$$

$$\underline{v}_k^{(2)} \sim N\left(\underline{y}_k - \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 10 & 0 \\ 0 & 10 \end{bmatrix}\right)$$

wobei die Funktion  $N(\cdot)$  die zweidimensionale Normalverteilung darstellt. Je nachdem, wie stark das Messrauschen ist, ändert sich die Gewichtung der beiden Modelle, d. h., bei geringem Messrauschen wird Modell (1) und bei hohem Messrauschen Modell (2) höher gewichtet. Diese Gewichtung kann als höherwertige Information für eine Plausibilisierung der Mess- und Prüfdaten genutzt werden. Zum Beispiel erreicht die Gewichtung des Modells (2) (hohes Messrauschen) einen bestimmten, vorher festgelegten Schwellenwert, deutet dies auf einen Sensordefekt hin und die Mess- und Prüfdaten können nicht mehr als plausibel angesehen werden.

### 3.3.3 Direkte Modellierung der bedingten Wahrscheinlichkeitsdichte (MessMo3)

Bei vielen Sensoren und Anwendungsszenarien bei der robusten Überwachung von Brücken und Gebäuden ist eine Modellierung der physikalischen Effekte und des Verhaltens der Mess- und Prüfdaten sehr schwierig. Insbesondere wenn die Wechsel-

wirkungen verschiedener physikalischer Größen und/oder verschiedener Messstellen mit berücksichtigt werden sollen, wird die Modellierung sehr aufwändig und steht in keinem Verhältnis zu dem Genauigkeits- und Robustheitsgewinn für die Sensorfusion und die Plausibilisierung (32).

Viel entscheidender als die hohe Genauigkeit der Modellierung für die Datenplausibilisierung sind die Zuverlässigkeit und Robustheit, d. h., viele physikalische Wechselwirkungen müssen gar nicht so genau modelliert werden, oftmals reicht eine grobe, dafür zuverlässige, Beschreibung. Die Wechselwirkung zwischen verschiedenen physikalischen Größen kann mit einer bedingten Wahrscheinlichkeitsdichte beschrieben werden. Mit dieser können probabilistische Aussagen über die Plausibilität bestimmter Zustände getroffen werden.

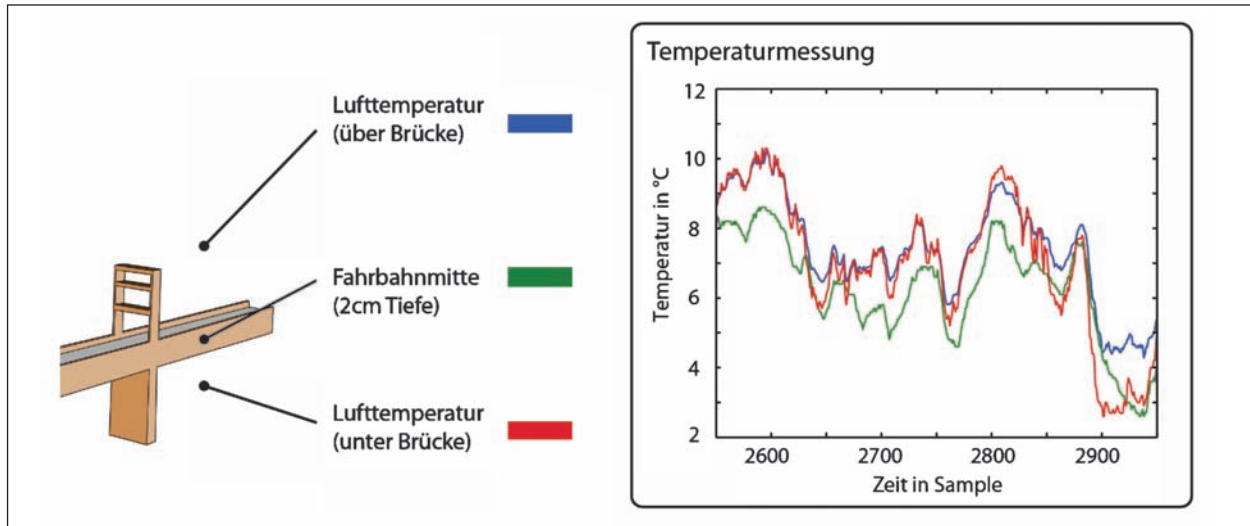
In diesem Kapitel wird ein Ansatz zur direkten Modellierung der bedingten Wahrscheinlichkeitsdichte anhand eines einfachen Beispiels erläutert und aufgezeigt, wie mit dessen Hilfe die Mess- und Prüfdaten auf ihre Plausibilität hin überprüft werden können. Dieser Ansatz ist besonders gut geeignet für Fälle wo eine gewisse Menge an Daten und/oder Expertenwissen in folgender Form vorhanden ist:

- <WENN> Temperatur Sensor 1 hoch/niedrig  
<DANN> Temperatur Sensor 2 hoch/niedrig,
- <WENN> Temperatur Sensor 1 steigt/fällt  
<DANN> Temperatur Sensor 2 steigt/fällt,
- <WENN> Temperatur steigt/fällt  
<DANN> Feuchte steigt/fällt.


Solche Bedingungen für plausible Mess- und Prüfdaten können direkt als bedingte Wahrscheinlichkeitsdichten modelliert werden. Im folgenden Beispiel wird diese Herangehensweise anhand eines Arrays von drei Sensoren, die an verschiedenen Stellen einer Brücke verteilt angebracht sind, näher erläutert, siehe Bild 12.

### Beispiel Array von Temperatursensoren

In Bild 12 ist die Lage der Temperatursensoren schematisch dargestellt, (1) Lufttemperatur über der Brücke, (2) Temperatur in der Fahrbahnmitte (2 cm Tiefe) und (3) Lufttemperatur unter der Brücke. Daneben ist der Verlauf der Messung der verschiedenen Sensoren beispielhaft dargestellt. Es ist deutlich, dass es zwischen allen drei Sensoren



**Bild 12:** Schematische Darstellung der Lage der drei Temperatursensoren über/unter der Brücke und in 2 cm Tiefe in der Fahrbahnmitte und beispielhafter Verlauf der Temperaturmessungen. Es ist deutlich, dass eine starke stochastische Abhängigkeit (Korrelation) zwischen den Sensoren besteht [Quelle: Temperatur- und Feuchtigkeitssensoren der Brücke Berkenthin, bereitgestellt durch BAST]



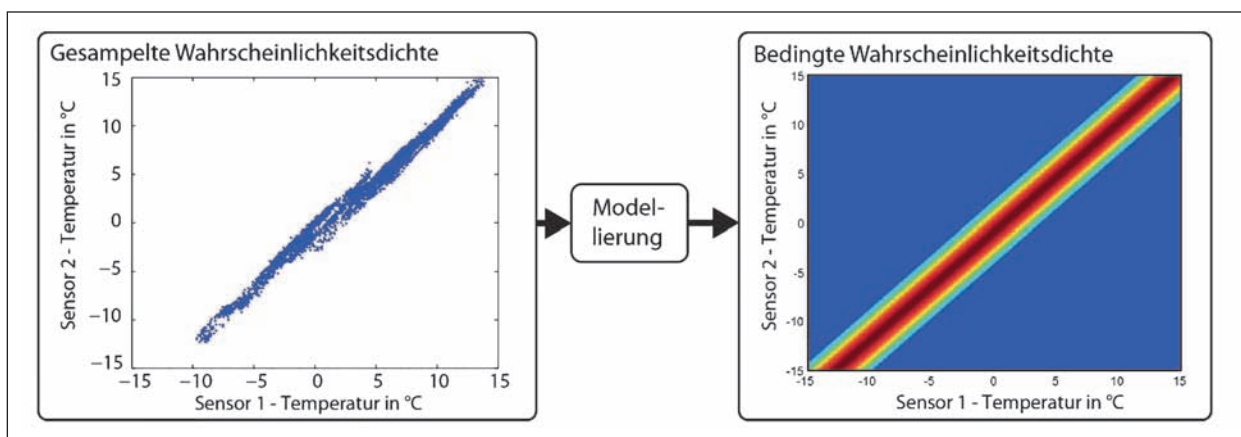
**Bild 13:** Marginalien der gesampelten Wahrscheinlichkeitsdichte für die gesamte zur Verfügung stehende Datenreihe. Die starke lineare Abhängigkeit zwischen den einzelnen Sensoren ist besonders deutlich erkennbar [Quelle: Temperatur- und Feuchtigkeitssensoren der Brücke Berkenthin, bereitgestellt durch BAST]

eine starke stochastische Abhängigkeit (Korrelation) existiert. Weiterhin ist zu erkennen, dass sich die Temperaturen in den meisten Fällen kohärent zueinander ändern, d. h., sie steigen/fallen mit einer sehr geringen Verzögerung alle zur gleichen Zeit.

In Bild 13 sind die Marginalien der gesampelten Wahrscheinlichkeitsdichte für die gesamte zur Verfügung stehende Datenreihe dargestellt. Hier ist die starke Abhängigkeit zwischen den einzelnen Sensoren besonders deutlich. Trotz der großen örtlichen Entfernung sind die beiden Sensoren für die Lufttemperatur stärker miteinander korreliert als zu dem (örtlich näheren) Sensor in der Fahrbahnmitte in 2 cm Tiefe. Hier scheinen andere physikalische Effekte bei der Erwärmung/Abkühlung des Fahrbahnbelages eine Rolle zu spielen. Es ist deutlich, dass sich dadurch die Breite der gesampelten Wahrscheinlichkeitsdichte insbesondere im unteren Temperaturbereich vergrößert.

### Bedingte Wahrscheinlichkeitsdichte

Die gesampelte Wahrscheinlichkeitsdichte kann nun genutzt werden um Bedingungen bzw. stochastische Abhängigkeiten, die zwischen den einzelnen Sensoren für plausible Daten gelten müssen zu modellieren. Diese sogenannte bedingte Wahrscheinlichkeitsdichte beschreibt, mit welcher Wahrscheinlichkeit ein Ereignis auftritt, wenn das Auftreten eines bestimmten (in der Regel anderen) Ereignisses bereits gesichert ist. Beispielsweise beschreibt sie die Wahrscheinlichkeitsverteilung für Sensor 2, wenn das Ereignis „Sensor 1 liefert die Messung  $\hat{y}_k = 10\text{ °C}$ “ eintritt. In Bild 14 ist dies beispielhaft für die Abhängigkeit zwischen Temperatursensor 1 (über Brücke) und Temperatursensor 2 (unter Brücke) dargestellt. Es ist deutlich zu erkennen, dass die Sensordaten auf einer Geraden mit Ausdehnung liegen, d. h., es besteht ein linearer Zusammenhang. Die bedingte Wahrscheinlich-



**Bild 14:** Darstellung der gesampelten Wahrscheinlichkeitsdichte zwischen dem Temperatursensor (über Brücke) und Temperatursensor (unter Brücke) aus dem Beispiel „Array von Temperatursensoren“ und eine mögliche bedingte Wahrscheinlichkeitsdichte [Quelle: Temperatur- und Feuchtigkeitssensoren der Brücke Berkenthin, bereitgestellt durch BAST]

keitsdichte  $f(x^{(2)}|x^{(1)})$  zwischen zwei Zufallsvariablen kann für den additiven, normalverteilten Fall allgemein wie folgt modelliert werden:

Bedingte Wahrscheinlichkeitsdichte

$$f(x^{(2)}|x^{(1)}) = N(x^{(2)} - a(x^{(1)}), \sigma^v)$$

wobei die Funktion  $N(\cdot)$  die Gaussfunktion mit Erwartungswert  $a(x^{(1)})$  und Standardabweichung  $\sigma^v$  ist. Die Abhängigkeit zwischen den beiden Zufallsvariablen steckt in der Funktion  $a(\cdot)$  und kann für den linearen Fall wie folgt beschrieben werden:

Deterministischer Zusammenhang

$$x^{(2)} = a(x^{(1)}) = m \cdot x^{(1)} + n$$

wobei  $x^{(1)}$  und  $x^{(2)}$  Zufallsvariablen für die Temperaturen jeweils für Sensor 1 (hier über der Brücke) und Sensor 2 (hier unter der Brücke) sind. Die Parameter  $m$  und  $n$  beschreiben den Anstieg und Offset der Geraden. Diese Parameter bzw. allgemein die Funktion  $a(\cdot)$  kann mittels eines Optimierungsverfahrens aus der Datenreihe bestimmt oder basierend auf Expertenwissen einfach festgelegt werden. Die bedingte Wahrscheinlichkeitsdichte  $f(x^{(2)}|x^{(1)})$  beschreibt also Bedingungen für das Auftreten bestimmter Konstellationen.

### Verbund-Wahrscheinlichkeitsdichte

Für mehrere Zufallsvariablen kann eine gemeinsame Wahrscheinlichkeitsdichte  $f(\underline{x})$  definiert werden. Diese Dichtefunktion beschreibt die Wahrscheinlichkeit, dass die Parameter  $\underline{x}$  in einem bestimmten Intervall liegen. Für den Fall, dass die Zu-

fallsvariablen  $\underline{x} = [x^{(1)}, x^{(2)}]$  stochastisch unabhängig sind, kann die gemeinsame Wahrscheinlichkeitsdichte  $f(x^{(1)}, x^{(2)})$  aus dem Produkt der jeweiligen Wahrscheinlichkeitsdichten  $f(x^{(i)})$  der einzelnen Zufallsvariablen  $x^{(i)}$  gewonnen werden und man schreibt

Verbund-Wahrscheinlichkeitsdichte

$$f(x^{(1)}, x^{(2)}) = f(x^{(1)}) \cdot f(x^{(2)})$$

Sind die einzelnen Zufallsvariablen  $x^{(i)}$  hingegen untereinander stochastisch abhängig, muss die Verbund-Wahrscheinlichkeitsdichte  $f(x^{(1)}, x^{(2)})$  durch Umwandlung des Satzes der bedingten Wahrscheinlichkeit bestimmt werden. Für zwei Zufallsvariablen kann diese wie folgt bestimmt werden

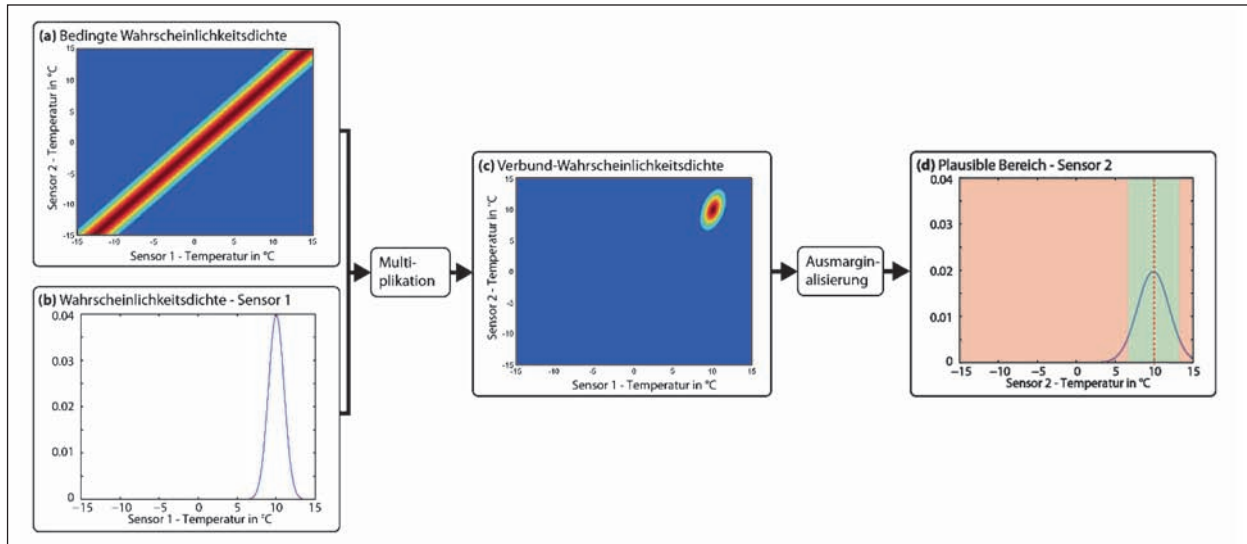
Verbund-Wahrscheinlichkeitsdichte

$$f(x^{(1)}, x^{(2)}) = f(x^{(2)}|x^{(1)}) \cdot f(x^{(1)})$$

Die sukzessive Anwendung dieser Gleichung erlaubt die Erweiterung von zwei Zufallsvariablen auf  $n$ -Zufallsvariablen. In Bild 15 ist die Berechnung der Verbund-Wahrscheinlichkeitsdichte mithilfe der  $f(x^{(2)}, x^{(1)})$ -bedingten Wahrscheinlichkeitsdichte für das Beispiel „Array von Temperatursensoren“ schematisch dargestellt.

### Marginale Wahrscheinlichkeitsdichte

Durch Ausmarginalisieren kann aus der Verbund-Wahrscheinlichkeitsdichte  $f(x^{(2)}, x^{(1)})$  die Wahrscheinlichkeitsdichte  $f(x^{(2)})$  für die Zufallsvariable  $x^{(2)}$  wie folgt berechnet werden:



**Bild 15:** Schematische Darstellung der Berechnung der Verbund-Wahrscheinlichkeitsdichte mithilfe der bedingten Wahrscheinlichkeitsdichte für das Beispiel „Array von Temperatursensoren“ und die daraus abgeleiteten plausiblen Bereiche für die zweite Zufallsvariable

Temperatur	<b>Modellierung:</b> Abhängigkeit mehrerer Temperatursensoren (verschiedene Messstellen), Abhängigkeit zwischen Temperatur und Feuchtigkeit, Abhängigkeit Temperatur und Dehnung
Feuchtigkeit (Luft-/Materialfeuchte)	<b>Modellierung:</b> Abhängigkeit mehrerer Feuchtigkeitssensoren (verschiedene Messstellen), Abhängigkeit zwischen Feuchtigkeit und Temperatur
Dehnung/Spannung	<b>Modellierung:</b> Abhängigkeit mehrerer Dehnungs-/Spannungssensoren, Abhängigkeit zwischen Temperatur und Dehnung/Spannung
Beschleunigung (Schwingung)	<b>Modellierung:</b> Abhängigkeit mehrerer Beschleunigungssensoren
Rissentwicklung	<b>Modellierung:</b> Abhängigkeit mehrerer Sensoren (z. B. Dehnmessstreifen), auch zwischen verschiedenen Sensorprinzipien
Verkehrslasten	<b>Modellierung:</b> Abhängigkeit mehrerer Sensoren (z. B. kapazitive Wegaufnehmer), auch zwischen verschiedenen Sensorprinzipien

**Tab. 5:** Möglicher Einsatzbereich und Eigenschaften direkte Modellierung der bedingten Wahrscheinlichkeitsdichte für Sensorfusion und Plausibilisierung

Marginalisierung

$$f(x^{(2)}) = \int f(x^{(1)}, x^{(2)}) \cdot dx^{(1)}$$

In Bild 15 ist die Ausmarginalisierung der Verbund-Wahrscheinlichkeitsdichte für das Beispiel „Array von Temperatursensoren“ schematisch dargestellt. Die berechnete Wahrscheinlichkeitsdichte  $f(x^{(2)})$  definiert den plausiblen Bereich für den Sensor 2 für gegebene Werte des Sensors 1 (in Form der Wahrscheinlichkeitsdichte  $f(x^{(1)})$ ). Nach der Definition eines bestimmten Schwellenwertes, z. B. die 3-Sigma-Grenze, kann überprüft werden, ob die Messwerte des Sensors 1 und des Sensors 2 in einem plausiblen Bereich liegen.

3.4 Zusammenfassung

Im Folgenden werden die einzelnen Ansätze zur Modellierung der Sensoren und der unterlagerten Prozesse auf ihre Eignung und Einsetzbarkeit untersucht. Eine erste Einschätzung der Modellierungsansätze ist in Tabelle 6 gegeben; dabei bedeuten Rot ungeeignet, Gelb bedingt geeignet und Grün geeignet und die mit „X“ markierten Felder sind aus theoretischen Gesichtspunkten abgeleitete Empfehlung aufgrund unserer langjähriger Erfahrung, die in sehr vielseitigen Problemstellung einsetzbar sind.

SysMo1 – Präzise Modellierung

Der Ansatz SysMo1 ist bedingt durch die Voraussetzung der sehr genauen präzisen Modellierung des unterlagerten Prozesses und aller äußeren

	Systemmodell				Messmodell		
	SysMo1 – Präzise Modellierung	SysMo2 – Allgemeine Modellierung	SysMo3 – Multiple Modelle	SysMo4 – Separierung von Signalen	MessMo1 – Präzise Modellierung	MessMo2 – Multiple Modelle	MessMo3 – Direkte Modellierung
DMS/Temperatur		X			X		
Feuchtigkeit (Luft-/Materialfeuchte)		X			X		
Dehnung/Spannung		X			X		
Beschleunigung (Schwingung)		X			X		
Rissentwicklung			X				X
Verkehrslasten		X					X

**Tab. 6:** Eignung und Einsetzbarkeit der verschiedenen Modellierungsarten für die Sensorfusion und Plausibilisierung beim robusten Brückenmonitoring. (SysMo1) Präzise Modellierung, (SysMo2) Allgemeine Modellierung (z. B. PV-Modell), (SysMo3) Multiple-Modelle, (SysMo4) Separierung von Signalen, (MessMo1) Präzise Modellierung (z. B. aus Sensorkennlinien), (MessMo2) Multiple-Modelle, (MessMo3) Direkte Modellierung der bedingten Wahrscheinlichkeitsdichte

Störeinflüsse nur für die wenigsten Anwendungsfälle einsetzbar. Für die Beobachtung der Temperatur in einem sehr kleinen Bereich einer Brücke ist dieser Ansatz bedingt einsetzbar. Allerdings für alle anderen Parameter steht der benötigte Rechen- und Modellierungsaufwand (meistens sind die Temperaturen abhängig) in keinem Verhältnis zu dem Genauigkeits- und Robustheitsgewinn für die Sensorfusion und die Plausibilisierung.

### SysMo2 – Allgemeine Modellierung

Der Ansatz SysMo2 ist bedingt durch die Modellierung sehr einfacher allgemeingültiger physikalischer Gesetze für alle physikalischen, chemischen Prozesse gut geeignet. Für die Erkennung von Ausreißern bzw. Plausibilisierung von Sensordaten hat sich die Modellierung des allgemeinen Trägheitsverhaltens als besonders effizient herausgestellt. Beispielsweise bei der Temperatur kann das allgemeine Ausgleichsverhalten der beteiligten thermischen Massen herangezogen werden. Bei der Beschleunigung können einfache Bewegungsgesetze der beteiligten Bauteilmassen und bei der Lufttemperatur einfache meteorologische Zusammenhänge als Grundlage dienen. Das Trägheitsverhalten spielt bei fast allen chemischen, physikalischen Prozessen eine Rolle und kann somit für die Plausibilisierung herangezogen werden.

### SysMo3 – Multiple Modelle

Der Ansatz SysMo3 ist einfach die Kombination verschiedener einfacher allgemeingültiger Modelle und somit für die meisten physikalischen Größen geeignet und einsetzbar. Insbesondere bei verschiedenen dynamischen Verhalten (also verschiedenen Prozessphasen), z. B. ständige Wechsel von Ruhe- und Schwingphasen, ist dieser Modellierungsansatz zur Plausibilisierung von Sensordaten besonders geeignet. Bei der Modellierung der Verkehrslasten und Dehnung/Spannung ist dieser Ansatz allerdings nur bedingt geeignet, durch die etwas höhere Komplexität der einzelnen Modelle; verschiedene Modelle für kleine und sprungartige Bewegungen (z. B. durch Überfahrt eines Fahrzeuges).

### SysMo4 – Separierung von Signalen

Der Ansatz SysMo4 ist besonders gut geeignet bei Anwendungen, wo sich Signale mit unterschiedlichen bekannten Frequenzen überlagern, z. B. Tag-/Nacht-Schwankungen und hochfrequentes Störsignal (beispielsweise 50-Hz-Brummen). Bei Temperatur und Feuchtigkeit kann dieser Ansatz zur Separierung der Tag-/Nacht-Schwankungen und des eigentlichen Nutzsignals genutzt werden. Bei Dehnung/Spannung und Beschleunigung kön-

nen hochfrequente Störsignale mit bekannter Frequenz verwendet werden. Bei Rissentwicklung und Verkehrslasten ist in den meisten Fällen keine Separierung verschiedener Signale notwendig; obwohl eine prinzipielle Anwendung möglich ist.

### MessMo1 – Präzise Modellierung

Der Ansatz MessMo1 nutzt eine präzise Modellierung des Zusammenhangs zwischen Systemzustand und Mess- und Prüfdaten. In den meisten Fällen kann die Messgleichung direkt aus den Kennlinienfeldern des jeweiligen Sensors abgeleitet werden. Die konkrete Struktur und Einflussgrößen der Messgleichung hängen sehr stark von dem jeweiligen Sensorprinzip ab. Bei Temperatur, Feuchtigkeit, Dehnung/Spannung und Beschleunigung ist dieser Zusammenhang sehr gut erforscht und die konkrete Struktur und Einflussgrößen der Messgleichung können abhängig vom jeweiligen Sensorprinzip aus der jeweiligen Sensorspezifikation entnommen werden. Bei der Rissentwicklung und Verkehrslasten ist dieser Zusammenhang je nach Anwendung etwas komplizierter und somit eventuell nur bedingt einsetzbar.

### MessMo2 – Multiple Modelle

Der Ansatz MessMo2 ist einfach die Kombination verschiedener einfacher Messgleichungen und somit für die meisten physikalischen Größen geeignet und einsetzbar. Das Hauptanwendungsgebiet dieses Ansatzes ist die Modellierung unterschiedlicher Rauschprozesse bei verschiedenen Umweltsituationen. Beispielsweise können die Störeinflüsse, wie Temperaturabhängigkeiten oder Sensorrauschen, in verschiedenen Situationen un-

terschiedlich sein. Auch können bestimmte Sensorparameter und Sensorkennlinien situationsbedingt variieren. Dies ist insbesondere bei Sensoren für Temperatur, Feuchtigkeit und Dehnung/Spannung der Fall.

### MessMo3 – Direkte Modellierung der bedingten Wahrscheinlichkeitsdichte

Der Ansatz MessMo3 modelliert den Zusammenhang zwischen verschiedenen Sensoren. Eine genaue mathematisch exakte Modellierung aller physikalischen Effekte ist bei vielen Sensoren und Anwendungsszenarien nicht möglich. Insbesondere wenn die Wechselwirkungen verschiedener physikalischer Größen und/oder verschiedener Messstellen mit berücksichtigt werden sollen, wird die Modellierung sehr aufwändig und steht in keinem Verhältnis zu dem Genauigkeits- und Robustheitsgewinn für die Sensorfusion und die Plausibilisierung. Viel entscheidender als die hohe Genauigkeit der Modellierung für die Datenplausibilisierung sind die Zuverlässigkeit und Robustheit, d. h., viele physikalische Wechselwirkungen müssen gar nicht so genau modelliert werden, oftmals reicht eine grobe, dafür zuverlässige Beschreibung.

In Tabelle 7 werden für verschiedene Messgrößen Lösungsansätze empfohlen. Die empfohlenen Ansätze basieren auf der von der BASt zur Verfügung gestellten Modellinstrumentierung, siehe Bild 16. Dabei ist die Energiesparlösung weniger genau, allerdings sind die verwendeten Algorithmen einfacher und benötigen weniger Rechenleistung (und somit weniger Energie). Für ausgewählte Messgrößen werden Ansätze empfohlen.

	Empfohlene Lösung			Energiesparlösung		
	Systemmodell	Messmodell	Zustandsschätzer	Systemmodell	Messmodell	Zustandsschätzer
DMS/ Temperatur	PV-Modell	Präzise Modellierung	LRKF	PV-Modell	Direkte Messung	Kalman-Filter
Feuchtigkeit	PV-Modell	Präzise Modellierung	LRKF	PV-Modell	Direkte Messung	Kalman-Filter
Korrosion	PV-Modell	Direkte Messung	Kalman-Filter	P-Modell	Direkte Messung	Kalman-Filter
Neigung	PV-Modell	Präzise Modellierung	LRKF	PV-Modell	Direkte Messung	Kalman-Filter
Verschiebung (Setzung)	PV-Modell	Präzise Modellierung	LRKF	PV-Modell	Direkte Messung	Kalman-Filter

Tab. 7: Für verschiedene Messgrößen empfohlene Lösungsansätze

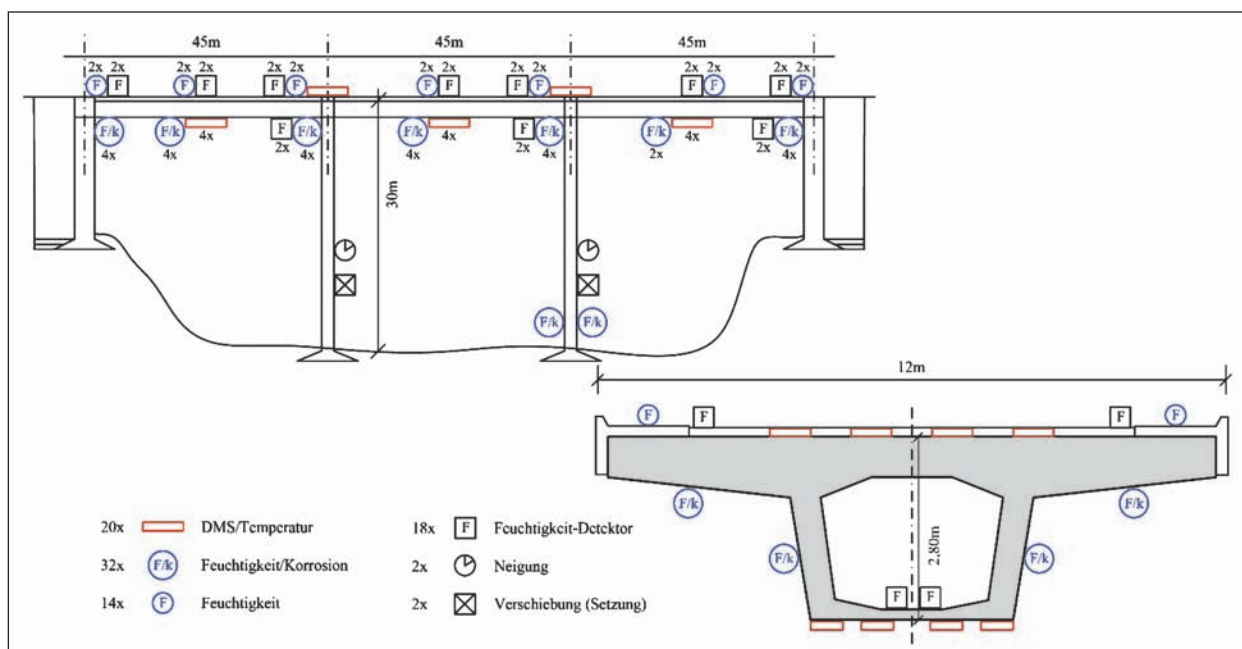


Bild 16: Modellinstrumentierung einer Brücke

## 4 Plausibilisierung, Datenfusion und Extraktion höherwertiger Information

### 4.1 Wertebereichs- und Trendüberwachung

Eine Möglichkeit, Erfassungsdaten auf Plausibilität hin zu überprüfen, ist die Überwachung des Wertebereichs und/oder des Trends. Dabei wird geprüft, ob die Sensoren Daten innerhalb eines bestimmten Wertebereichs liefern. Entspricht der Messwert nicht dem vorgegebenen Wertebereich, wird dieser von der weiteren Verarbeitung ausgeschlossen, um fehlerhafte Ergebnisse basierend auf falschen Eingangswerten zu vermeiden. Weiterhin kann eine entsprechende Meldung an die überlagerte Schicht der Fernüberwachung des Messsystems und des Bauwerks gegeben werden. In Bild 17 ist ein Beispiel für die Wertebereichs- und Trendüberwachung von gefilterten Daten, d. h. Ausgangssignal des modellbasierten Zustandsschätzers (siehe Kapitel 4.2), dargestellt. Hier wird beispielhaft der Wertebereich der Temperatur und Änderungsgeschwindigkeit überwacht.

Die Kriterien und Schwellenwerte für die jeweiligen Wertebereiche können auf unterschiedlichste Weise bestimmt werden. Eine Möglichkeit ist die Vorgabe durch einen Nutzer. Hierdurch können insbesondere physikalisch absolut implausible Mess-

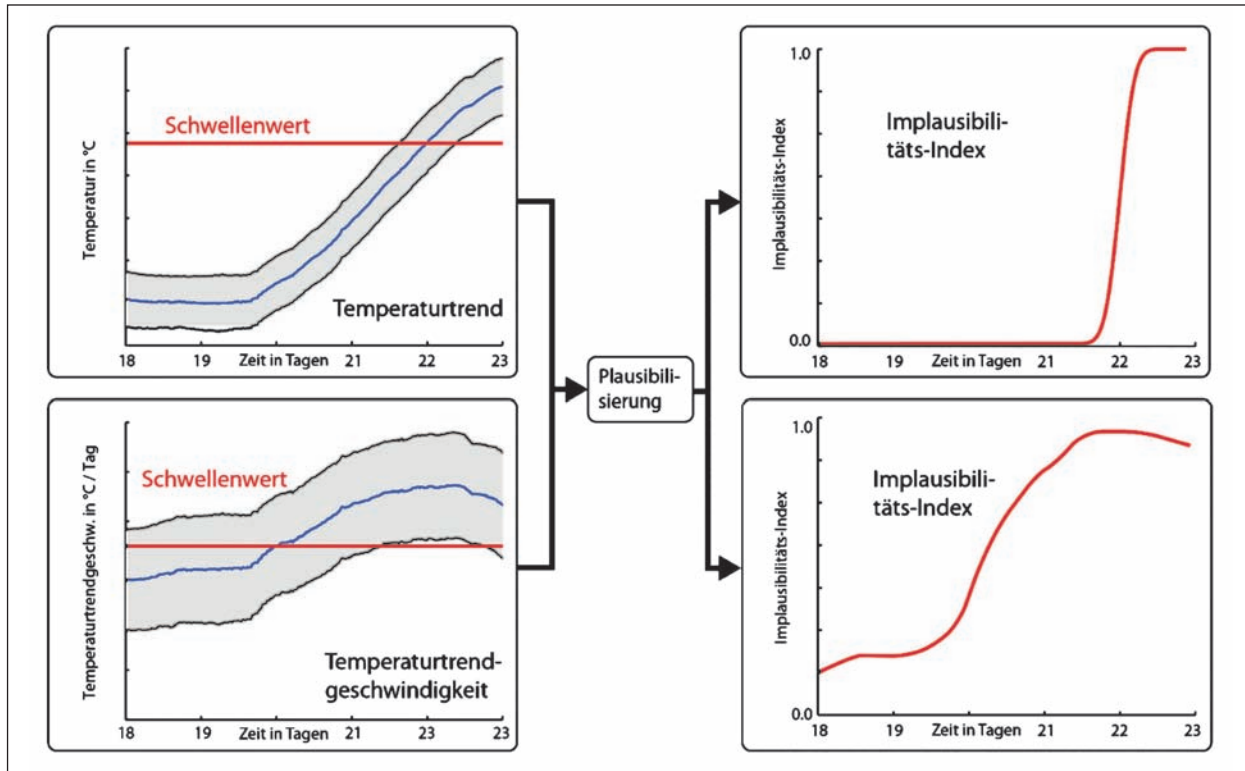
und Prüfdaten ausgeschlossen werden. Allerdings sind in der Regel solche Schwellenwerte sehr konservativ und würden viele Erfassungsdaten, die nicht plausibel sind, nicht als solche erkennen, vor allem bei hoher Dynamik der gemessenen Größen. Durch den Einsatz von Lernalgorithmen (siehe Kapitel 4.3) können die Schwellenwerte auch basierend auf einem Trainingsdatensatz bestimmt werden. Hierdurch werden die speziellen Gegebenheiten und Umweltbedingungen vor Ort mit berücksichtigt. Dies führt zu Kriterien und Schwellenwerten, die nicht so konservativ sind, und dadurch auch robustere, belastbarere Aussagen über die Plausibilität treffen können. Denkbar ist auch eine Kombination dieser beiden genannten Ansätze.

### Plausibilisierung


Die Wertebereichs- und Trendüberwachung eignet sich nur für eine sehr grobe Plausibilisierung. Es können physikalisch absolut implausible Erfassungsdaten von einer weiteren detaillierteren Untersuchung ausgeschlossen werden, z. B. wenn ein Temperatursensor im Sommer  $-30\text{ }^{\circ}\text{C}$  liefert.

Insbesondere Verfahren aus dem Bereich der Fuzzylogik und unscharfe Mengen spielen hier eine wichtige Rolle (33). Mittels dieser Verfahren kann die sogenannte Fuzziness von Angaben wie <ein bisschen> und <stark> in mathematischen Modellen erfasst werden. Weiterhin können auch Trendinformationen für die Plausibilisierung genutzt werden, z. B.





**Bild 17:** Plausibilisierung von Mess- und Prüfdaten mittels Wertebereichs- und Trendüberwachung. Sowohl die reinen Sensordaten als auch die gefilterten Daten (Ausgangssignal des modellbasierten Zustandsschätzers), wie in der Abbildung dargestellt, können diesbezüglich auf Plausibilität überprüft werden



**Bild 18:** Ableitung höherwertiger Information mittels Fuzzylogik. Die Mess- und Erfassungsdaten bilden auf die Zugehörigkeit verschiedener Gruppen ab, in diesem Beispiel 75 % <niedrig> und 25 % <mittel>

die Temperatur ändert sich <schnell> oder <langsam>. Die Fuzzylogik basiert auf sogenannten Zugehörigkeitsfunktionen, die Mess- und Erfassungsdaten auf Fuzzy-Mengen abbilden, auf diesen können dann logische Operationen und Inferenz für die Plausibilisierung bzw. Ableitung höherwertiger Information (siehe unten) durchgeführt werden, siehe Bild 18. Die logischen Operationen für eine Plausibilisierung könnten wie folgt aussehen:

- <WENN> Temperatur-Sensor 1 hoch/niedrig  
<DANN> Temperatur-Sensor 2 hoch/niedrig,
- <WENN> Temperatur-Sensor 1 steigt/fällt  
<DANN> Temperatur-Sensor 2 steigt/fällt,

- <WENN> Temperatur steigt/fällt  
<DANN> Feuchte steigt/fällt.

Für die Bestimmung der einzelnen Schwellwerte und die genaue Form der Zugehörigkeitsfunktionen der einzelnen Bereiche bzw. Gruppierung ist allerdings sehr viel Expertenwissen notwendig, um die notwendige Information aus den Mess- und Erfassungsdaten herauszuziehen. Dies schränkt den praktischen Einsatz solcher Verfahren sehr stark ein.

**Fusion von Sensordaten**

Die Verfahren der Wertebereichs- und Trendüberwachung sind nicht für die Fusion von Sensordaten geeignet.

**Interpolation**

Die Verfahren der Wertebereichs- und Trendüberwachung sind nicht für die zeitliche und örtliche Interpolation geeignet.

**Ableitung höherwertiger Information**

Die Wertebereichs- und Trendüberwachung eignet sich nur sehr eingeschränkt zur Ableitung höherwertiger Information. Es kann eine grobe Einord-

nung der Mess- und Erfassungsdaten in verschiedene Bereiche/Gruppierung erfolgen, z. B., die Temperatur ist <hoch>, <mittel> und <niedrig>. Wie bei der Plausibilisierung spielen hier insbesondere Verfahren aus dem Bereich der Fuzzylogik eine wichtige Rolle. Hier werden Mess- und Erfassungsdaten mittels geeigneter Zugehörigkeitsfunktionen in verschiedene Gruppen eingeteilt, siehe Bild 18. Diese Information kann dann von einem höhergelagerten Informationssystem und/oder einem nachgeschalteten Schädigungsmodell genutzt werden.

### Datenreduktion

Die Verfahren der Wertebereichs- und Trendüberwachung sind nicht für die Datenreduktion geeignet.

### Zusammenfassung

In Tabelle 8 ist die Eignung von Verfahren der Wertebereichs- und Trendüberwachung für die Plausibilisierung, Fusion von Sensordaten, Interpolation, Ableitung höherwertiger Information und Datenreduktion zusammengefasst dargestellt; dabei bedeuten Rot ungeeignet, Gelb bedingt geeignet und Grün geeignet. Dies ist eine aus theoretischen Gesichtspunkten abgeleitete Einschätzung, welche auf der langjährigen Erfahrung der Autoren beruht. Es ist deutlich, dass die Wertebereichs- und Trendüberwachung lediglich für eine grobe Plausibilisierung und Ableitung höherwertiger Information geeignet ist.

## 4.2 Modellbasierte Zustandsschätzer

### 4.2.1 Überblick und Ziele

Ziel der modellbasierten Zustandsschätzung ist die Herausfilterung relevanter Information aus den einzelnen ggf. störungsbehafteten Mess- bzw. Erfassungsdaten. Die rauen Bedingungen, denen die Sensoren beim robusten Brückenmonitoring ausgesetzt sind, führen dazu, dass die relevanten Informationen in den Mess- und Prüfdaten durch Störsignale verschiedenster Art überlagert werden. Störungen, die die Funktionsweise und Lebensdauer der Sensoren stark einschränken, können beispielsweise systematische Fehler (Offset, Bias), Rauschen oder Brummen, Messaussetzer oder Sensordefekte sein. Die Grundlage der modellbasierten Verfahren stellt dabei das in Kapitel 3 vorgestellte probabilistische Systemmodell und Messmodell zur Beschreibung des unterlagerten Systems und der Mess- und Prüfdaten dar.

Mithilfe geeigneter und möglichst automatisierter Verfahren werden die Mess- und Prüfdaten fusioniert und kombiniert, um eine umfassende echtzeitbasierte Zustandsbewertung von Brückenbauwerken zu erhalten. In Bild 19 sind typische Eigenschaften der vorliegenden Mess- und Prüfdaten beim robusten Brückenmonitoring und der daraus extrahierten relevanten Information dargestellt. So können Sensordaten ungewünschte Eigenschaften wie systematische Fehler aufweisen, die eine durchgängige Abweichung des Messwerts zum tatsächlichen Wert verursachen, oder verrauscht sein, welches die Genauigkeit und den Informationsge-

	Plausibilisierung	Fusion von Sensordaten	Interpolation	Ableitung höherwertiger Information	Datenreduktion
Wertebereichs- und Trendüberwachung					

Tab. 8: Eignung der Verfahren der Wertebereichs- und Trendüberwachung

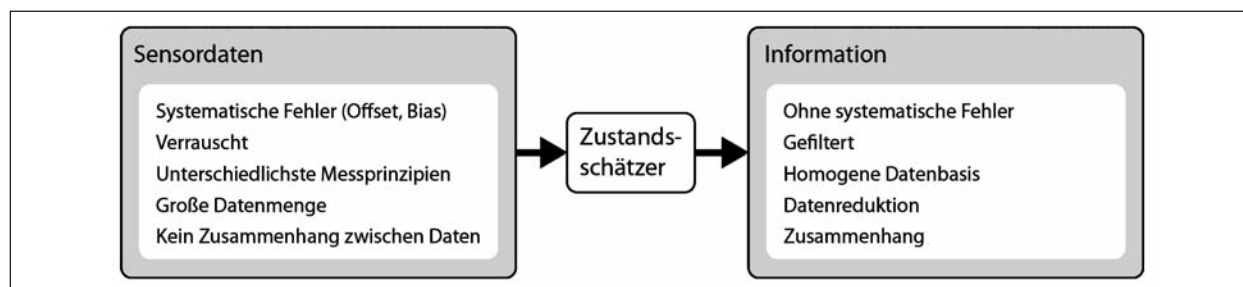


Bild 19: Typische Eigenschaften der vorliegenden Mess- und Prüfdaten beim robusten Brückenmonitoring und der daraus extrahierten relevanten Information

halt der Messung schmälert. In den folgenden Kapiteln wird eine kurze Einführung in die modellbasierte Zustandsschätzung gegeben. Eine detaillierte Einführung in dieses Themengebiet findet sich zum Beispiel in (17) oder (19).

#### 4.2.2 Klassifizierung nach Konfiguration der Mess- und Prüfdaten

##### Univariate Mess- und Prüfgrößen

Im Fall von univariaten Mess- und Prüfgrößen, d. h., es existiert nur ein Sensor für einen bestimmten zu erfassenden skalaren Kennwert, werden die Daten mit einem mathematischen Modell fusioniert. Durch diese Kombination der Daten mit Zusatzwissen können glattere Ergebnisse generiert werden, Störungen unterdrückt und beispielsweise Tagesschwankungen herausgerechnet werden. Weiterhin können die Daten mit dem mathematischen Modell abgeglichen und auf Implausibilitäten hin überprüft werden. In Bild 20 ist beispielhaft die Filterung relevanter Information für einen Temperatursensor (im speziellen PT-1000-Element) dargestellt. Es ist deutlich zu sehen, dass die Tagesschwankungen und das Rauschen herausgerechnet werden können. Weiterhin können für die extrahierten Information Qualitätsaussagen in Form von Unsicherheitsbeschreibungen berechnet werden. Diese Unsicherheitsbeschreibung ist in der Abbildung als grau hinterlegter Bereich innerhalb der 3-Sigma-Grenzen eingezeichnet.


##### Multivariate Mess- und Prüfgrößen

Zwischen vielen erfassten Messwerten am Bauwerk besteht eine große Abhängigkeit, z. B. zwischen Betonfeuchte und Temperatur. Dadurch ist die Kombination mehrerer Mess- und Prüfgrößen

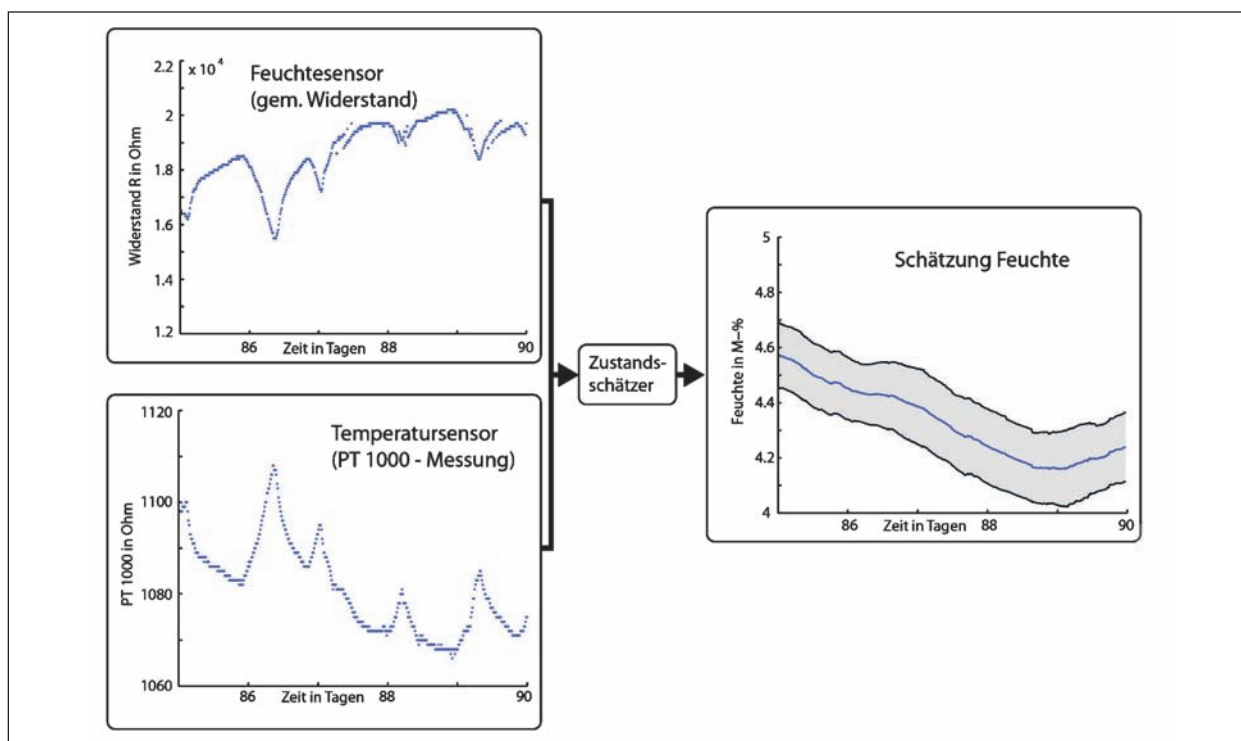
zur Extraktion der relevanten störungsfreien Information zwingend notwendig. Dabei werden die Abhängigkeiten zwischen den gemessenen Größen, z. B. Feuchte (gemessener Widerstand) und Temperatur (PT 1000) berechnet. Dadurch können glattere Ergebnisse generiert werden, Störungen unterdrückt und beispielsweise die Temperaturabhängigkeit des Feuchtesensors herausgerechnet werden. Weiterhin können die Daten mit dem mathematischen Modell abgeglichen und auf Implausibilitäten hin überprüft werden. In Bild 21 ist beispielhaft die Filterung relevanter Information für eine Multiring-Elektrode mit integriertem PT 1000 dargestellt. Es ist deutlich zu sehen, dass durch die Berücksichtigung der physikalischen Abhängigkeiten aus dem gemessenen Widerstand (Feuchte) und PT-1000-Werten (Temperatur) die Feuchte inklusive einer Qualitätsaussage berechnet werden kann; die Temperaturabhängigkeit des Feuchtesensors kann kompensiert werden. Weiterhin können Störungen und Tagesschwankungen herausgerechnet werden.

##### Verteilte Mess- und Prüfgrößen

Für die meisten Anwendungen beim robusten Brückenmonitoring stehen keine Sensorsysteme zur Verfügung, welche einen räumlich verteilten Prozess wie beispielsweise eine Temperaturverteilung über das Bauwerk als Ganzes erfassen. Aus diesem Grund muss man sich mit Sensoren begnügen, welche den Prozess lediglich zu diskreten Zeitpunkten an diskreten Ortspunkten erfassen. Für die Zustandsschätzung und auch für die automatische Überprüfung der Mess- und Prüfdaten auf Plausibilität müssen diese diskreten Messungen mittels einer Rekonstruktion in Beziehung gesetzt werden. Bei der Rekonstruktion wird somit aus diesen diskretisierten Sensordaten auf das Verhalten



**Bild 20:** Filterung relevanter Information aus Mess- und Prüfdaten am Beispiel eines PT-1000-Temperatursensors. Die Tagesschwankungen und Rauschen können gefiltert und somit ein störungsfreies Ausgangssignal inklusive Qualitätsaussage generiert werden [Quelle: reale Sensordaten einer Multiring-Elektrode bereitgestellt durch BAST]



**Bild 21:** Filterung relevanter Information aus Mess- und Prüfdaten am Beispiel einer Multiring-Elektrode mit integriertem PT-1000-Temperatursensor. Es ist deutlich, dass durch die Berücksichtigung der physikalischen Abhängigkeiten die Temperaturabhängigkeit des Feuchtesensors kompensiert werden kann und somit ein plausibleres Ergebnis generiert werden kann [Quelle: reale Sensordaten einer Multiring-Elektrode bereitgestellt durch BAST]

des Prozesses an beliebigen zeitlichen und örtlichen Punkten geschlossen (21). Die räumlich verteilten physikalischen Prozesse können mittels partieller Differenzialgleichungen mathematisch beschrieben werden. Diese berücksichtigen nicht nur die zeitliche Veränderung, sondern auch die räumliche Ausbreitung. Da diese Darstellungsform für die Entwicklung eines Algorithmus für die Zustandsschätzung und Plausibilisierung sehr komplex ist, ist eine Konversion in eine entsprechende konzentriert-parametrische Form notwendig. Durch eine probabilistische und modellbasierte Herangehensweise ist es möglich, die charakteristischen Größen, die den verteilten Prozess vollständig beschreiben, in einer physikalisch korrekten und systematischen Weise zu bestimmen.

Bei der Rekonstruktion beispielsweise einer Temperaturverteilung mittels eines verteilten Messsystems werden modellfreie und modellbasierte Verfahren eingesetzt. Bei den modellfreien Verfahren wird kein explizites physikalisches Modell, welches die physikalischen Eigenschaften und Zusammenhänge des beobachteten Prozesses beschreibt, angenommen. Der mathematische Zusammenhang wird aus den Daten gelernt. Zu diesen datengetriebenen Verfahren zählen Gauß-Pro-

zesse (34), statistische Lerntheorie, künstliche neuronale Netze (35), Data Mining (36) und andere maschinelle Lernalgorithmen (37, 38, 39), 40). Für die örtliche Interpolation von Kennwerten an verschiedenen Mess- und Prüfstellen können, wenn kein physikalisches Hintergrundwissen in Form eines Modells vorhanden ist, die sogenannten Kriging-Verfahren angewendet werden (41).

Bei den modellbasierten Verfahren wird das physikalische Hintergrundwissen implizit mit berücksichtigt, sodass eine verbesserte Zustandsschätzung möglich ist. Dafür wird ein Modell, welches die physikalischen Eigenschaften und Zusammenhänge des zu beobachteten Prozesses beschreibt, angenommen. Im Allgemeinen sind diese Modelle nichtlinear (nichtlineare gewöhnliche Differenzialgleichung) und/oder räumlich verteilt (partielle Differenzialgleichung), welches eine besonders hohe Herausforderung für die Verarbeitung der Mess- und Prüfdaten darstellt. Für räumlich verteilte Messsysteme, wie beispielsweise ein Array von Temperatursensoren, sind spezielle Algorithmen für die Verarbeitung notwendig. Zur Reduktion der Komplexität der Verarbeitung der verteilten Mess- und Prüfdaten wird die verteilt-parametrische Modellbeschreibung (partielle Differenzialgleichung) in eine kon-

zentriert-parametrische Modellbeschreibung (gewöhnliche Differenzialgleichung) überführt (21, 42). Diese Überführung kann mittels einer Modalzerlegung (43), Finite-Elemente-Verfahren oder Finite-Differenzen-Verfahren erreicht werden. Dies führt in der Regel zu hochdimensionalen Schätzproblemen.

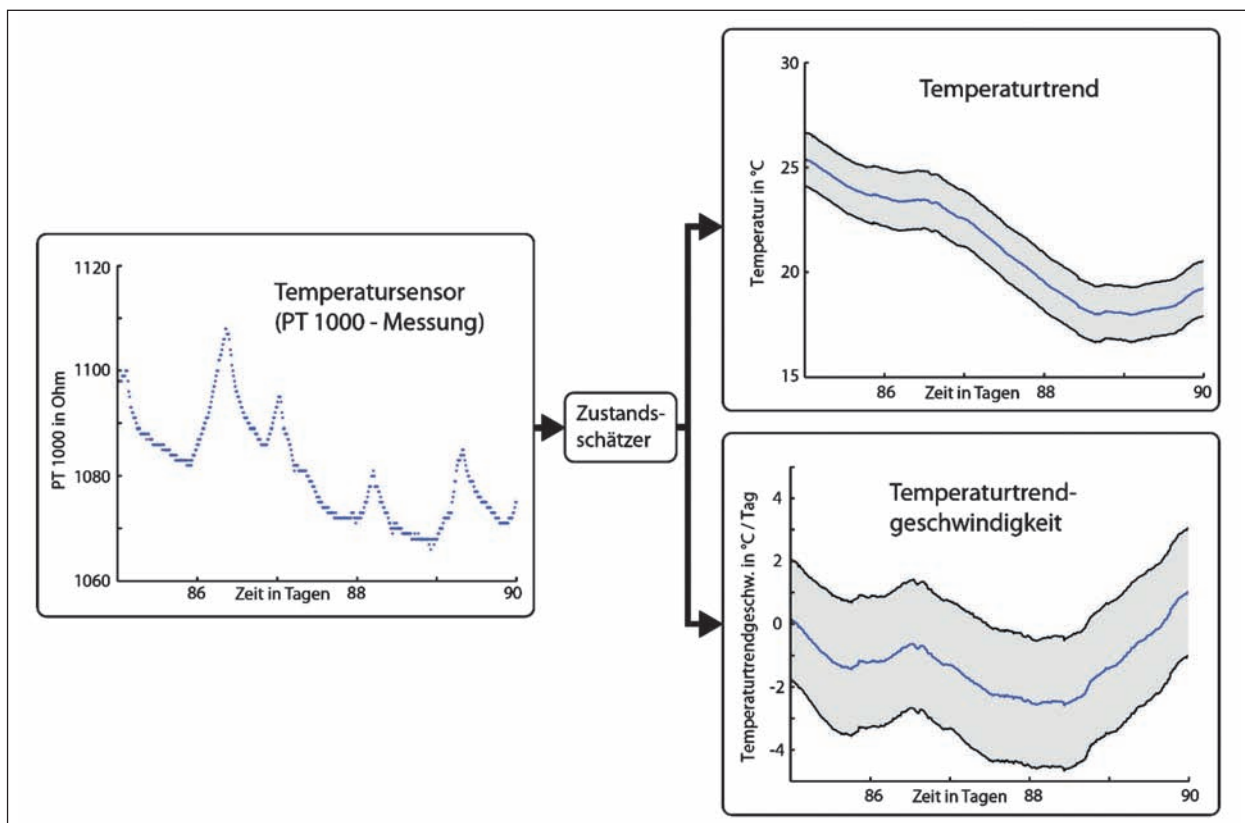
### Extraktion qualifizierter Monitoringinformation

Mittels der modellbasierten Zustandsschätzung können bei entsprechender Wahl des mathematischen Modells weitergehende qualifizierte Monitoringinformation aus den Erfassungsdaten extrahiert werden. Es können nicht direkt messbare Kenngrößen ermittelt werden, wie z. B. Temperaturtrend-Geschwindigkeiten, siehe Bild 22. Weiterhin kann das Eingangssignal in verschiedene Bestandteile getrennt werden, wie z. B. Trennung in langsamen und schnellen Veränderungen. Es ist wichtig zu erwähnen, dass bei der modellbasierten Zustandsschätzung auch über diese qualifizierten Monitoringinformation eine Qualitätsaussage in Form eines Unsicherheitsbands (z. B. 3-Sigma-Grenzen) angegeben werden kann.

### 4.2.3 Sensordatenfusion

Bei der modellbasierten Zustandsschätzung wird ein explizites physikalisches Modell, welches die physikalischen Eigenschaften und Zusammenhänge des zu untersuchenden Prozesses beschreibt, angenommen. Beispiele für physikalische Modelle sind zeitunabhängige Stoffgesetze, analytische Lebensdauermodelle sowie Modelle zur Beschreibung des Last- und Verformungsverhaltens, siehe Kapitel 3.2. Im Allgemeinen sind diese Modelle nichtlinear (nichtlineare gewöhnliche Differenzialgleichung) und/oder räumlich verteilt (partielle Differenzialgleichung), welches eine besonders hohe Herausforderung für die Sensorfusion darstellt.

Bei der modellbasierten Zustandsschätzung wird dieses physikalische Hintergrundwissen implizit mit berücksichtigt, sodass die Messgrößen bezüglich Genauigkeit und Glattheitseigenschaften verbessert werden können. In manchen Fällen, wenn kein physikalischer Zusammenhang benötigt wird, lässt sich so ein Modell ebenfalls nutzen, um den Signalverlauf zu charakterisieren. Solche Modelle sind dann vor allem für eine Plausibilisierung geeignet.



**Bild 22:** Extraktion weitergehender qualifizierter Monitoringinformation. Hier wird beispielhaft aus PT-1000-Messungen nicht nur die tagesschwankungsbereinigte Temperatur bestimmt, sondern auch noch die Änderungsrate bzw. Temperaturtrend-Geschwindigkeit [Quelle: reale Sensordaten einer Multiring-Elektrode bereitgestellt durch BAST]

Modellbasierte Zustandsschätzer verwenden eine Zustandsraumdarstellung zur Beschreibung eines Systems, siehe Kapitel 3.1. Weiterhin existieren ein Systemmodell sowie ein Messmodell, welche die Veränderung des Systemzustands über die Zeit sowie den Zusammenhang zwischen Zustand und Messung beschreiben. Der Systemzustand zum Zeitpunkt  $t_k$  wird mit  $\underline{x}_k$  und eine erhaltene Messung zum selben Zeitpunkt mit  $\hat{y}_k$  bezeichnet. Wichtig bei der stochastischen Zustandsschätzung ist, dass die Schätzung des Zustands als Wahrscheinlichkeitsverteilung über den Zustandsraum dargestellt wird – es erfolgt also keine direkte Verarbeitung des Zustandsvektors  $\underline{x}_k$ , sondern eine Wahrscheinlichkeitsdichte  $f(\underline{x}_k)$ . Diese Wahrscheinlichkeitsdichte beschreibt das aktuelle Wissen über den tatsächlichen Systemzustand  $\underline{x}_k$ .

In Bild 23 ist der prinzipielle Ablauf eines modellbasierten Zustandsschätzers dargestellt. Die Zustandsschätzung durchläuft bei ihrer Verarbeitung einen Zyklus aus (1) Prädiktion (im Block „Probabilistische Systemgleichung“), (2) Filterung (im Block Bayes) und (3) Delay. Die Prädiktion dient hierbei, eine geschätzte Wahrscheinlichkeitsdichte  $f^e(\underline{x}_k)$  auf die prädierte Wahrscheinlichkeitsdichte  $f^p(\underline{x}_{k+1})$ , die eine Vorhersage für den nächsten Zeitschritt  $t_k + 1$  darstellt, fortzuschreiben. Das Delay-Element im Schaubild dient der Verzögerung, sodass aus dem zukünftigen Zeitpunkt  $t_k + 1$  der aktuelle Zeitpunkt  $t_k$  wird. Die prädierte Wahrscheinlichkeitsdichte  $f^p(\underline{x}_k)$  wird nun in der Filte-

rung aktualisiert, das Ergebnis ist wieder eine geschätzte Wahrscheinlichkeitsdichte  $f^e(\underline{x}_k)$ . Hierbei wird die Information aus der aktuellen Messung in die Zustandsschätzung eingefügt.

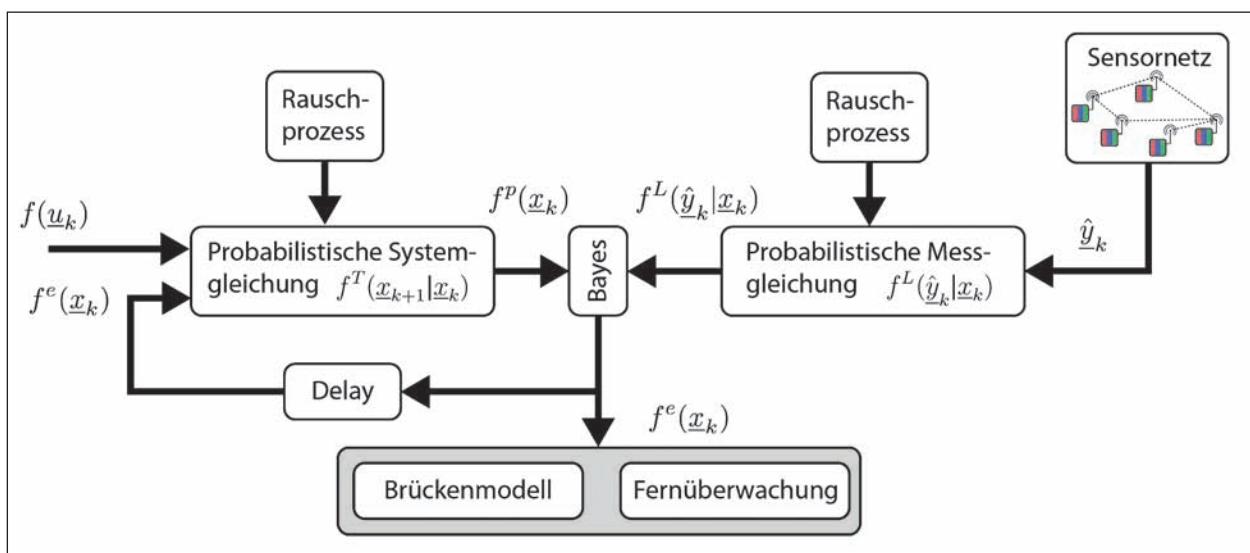
Im Folgenden wird näher auf die beiden Hauptkomponenten eines modellbasierten Zustandsschätzers, die Prädiktion und die Filterung, eingegangen.

### Prädiktionsschritt

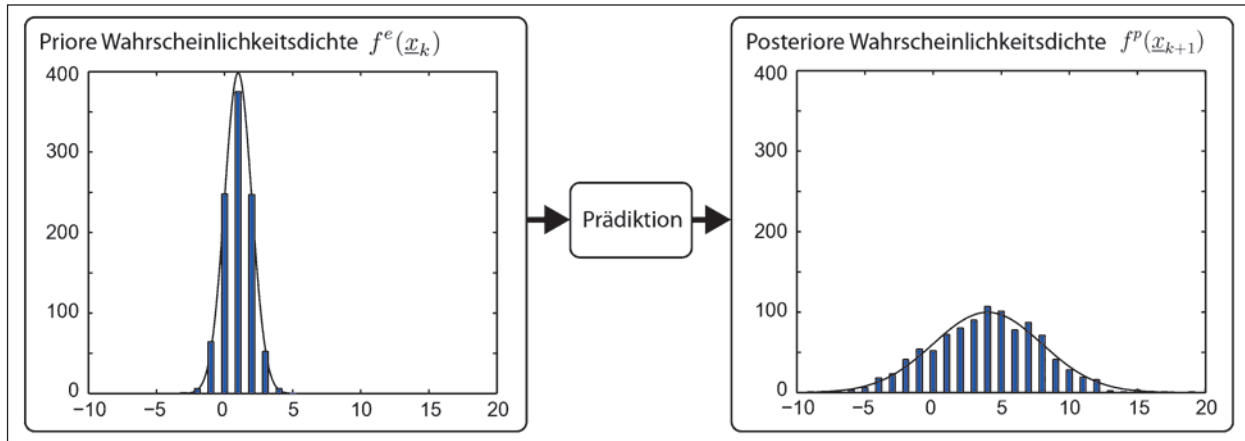
Die Prädiktion dient dem Fortschreiben der geschätzten Wahrscheinlichkeitsdichte  $f^e(\underline{x}_k)$  über die Zeit. Dies geschieht mithilfe eines probabilistischen Systemmodells  $f^T(\underline{x}_{k+1}|\underline{x}_k)$ , welches eine Vorhersage über den zukünftigen Systemzustand  $\underline{x}_{k+1}$  abhängig vom aktuellen Systemzustand  $\underline{x}_k$  beschreibt. Dieses probabilistische Systemmodell wird oft aus einer deterministischen Systemgleichung hergeleitet, welche die Abhängigkeit des zukünftigen Systemzustands vom aktuellen Systemzustand sowie weiterer Störgrößen beschreibt.

### Beispiel Prädiktion

Im Folgenden wird ein einfaches Einführungsbeispiel zur Prädiktion gegeben. Es wird angenommen, dass die Wahrscheinlichkeitsdichte normalverteilt mit Erwartungswert  $\hat{x} = 1$  und Standardabweichung  $\gamma = 1$  ist, es gilt also  $f^e(x_k) = N(x - 1, 1)$ . Die priore (a priori) Wahrscheinlichkeitsdichte  $f^e(x_k)$  ist in Bild 24 dargestellt.



**Bild 23:** Konzept des modellbasierten Zustandsschätzers für die Filterung von relevanten Information aus den störungsbehafteten Mess- und Prüfdaten. Als Ausgangsgröße werden gefilterte Kennwerte und zusätzliche qualifizierte Monitoringinformation für ein nachgelagertes Brückenmodell und Plausibilitätsaussagen über einzelne Sensoren für ein überlagertes Fernüberwachungssystem bereitgestellt



**Bild 24:** Prädiktion – eine normalverteilte Zufallsvariable wird über eine Systemgleichung prädiziert

Die Systemgleichung zur Beschreibung des Zusammenhangs zwischen dem aktuellen Systemzustand und dem zukünftigen Systemzustand ist gegeben durch  $x_{k+1} = 4 \cdot x_k$ . Anschaulich kann man nun die Anwendung der Systemgleichung so verstehen, dass Stichproben (Samples) aus der Zufallsvariablen  $x_k$ , welche über die priore Wahrscheinlichkeitsdichte  $f^e(x_k)$  gegeben ist, über die Systemgleichung auf  $x_{k+1}$  abgebildet werden. Die posteriore (a posteriori) Wahrscheinlichkeitsdichte  $f^p(x_{k+1})$  beschreibt dann  $x_{k+1}$ .

In der linken Abbildung sind die Wahrscheinlichkeitsdichte  $f^e(x_k)$  sowie ein Histogramm über 1.000 zufällig gewählte Stichproben (Histogramm) dargestellt. Das Histogramm auf der rechten Seite ist die Abbildung der Stichproben über die Systemgleichung. Ein bevorzugter Ansatz zur Abbildung von Zufallsvariablen ist die direkte Berechnung der Wahrscheinlichkeitsdichte von  $x_{k+1}$ . In diesem Fall wäre das Ergebnis  $f^p(x_{k+1}) = N(x - 4, 4)$ , also eine Normalverteilung mit Erwartungswert 4 und Standardabweichung 4.

Dies lässt sich zum Beispiel direkt aus den Kalman-Filter-Gleichungen berechnen und benötigt in der Regel deutlich weniger Rechenaufwand als die Verarbeitung einer Vielzahl von Stichproben. Die Lösung ist in der rechten Abbildung als durchgezogene Linie dargestellt und ist in Übereinstimmung mit dem Histogramm.

### Filterschritt

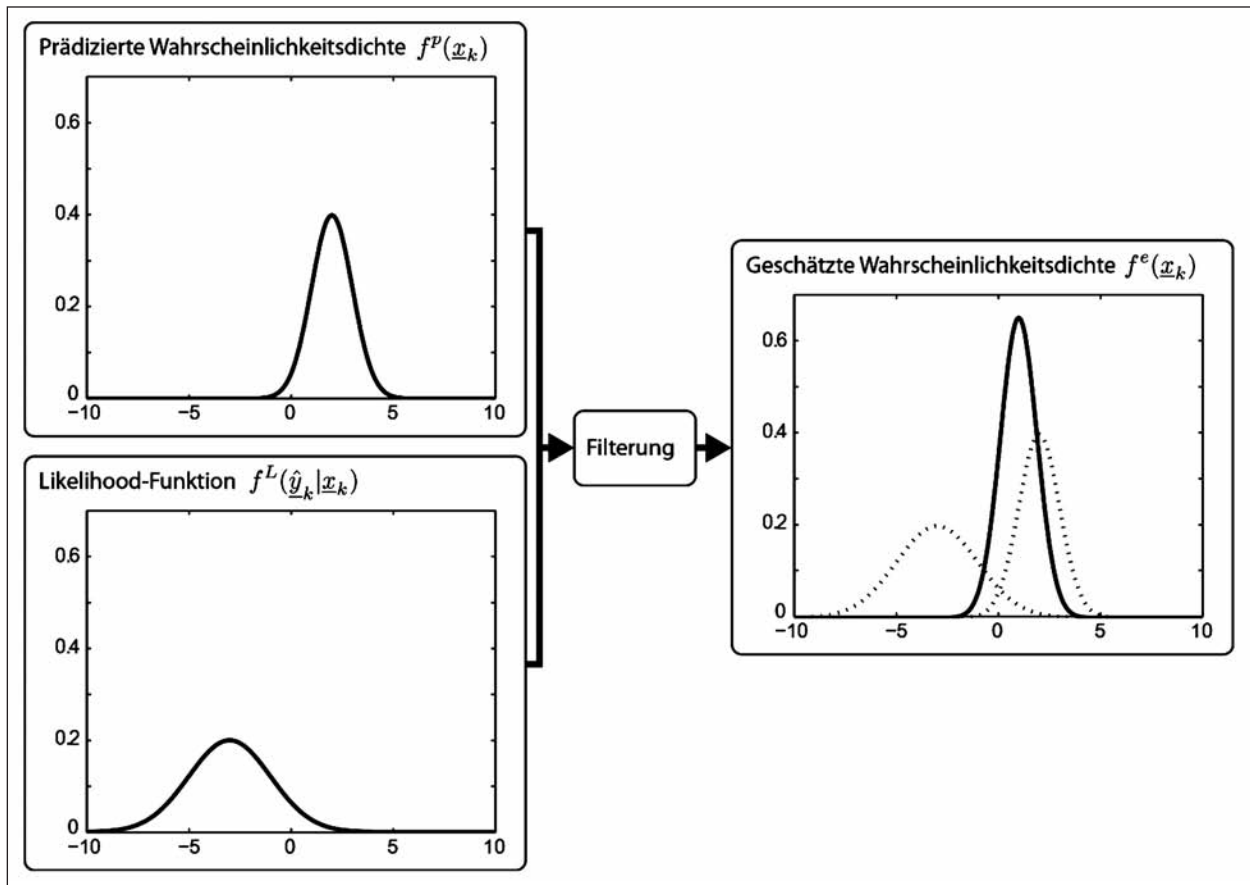
Durch die Filterung wird die prädizierte Zustandsschätzung  $f^p(x_k)$  mit einer gegebenen Messung verarbeitet und dadurch die Zustandsschätzung aktualisiert. Zur Aktualisierung der Zustandsschät-

zung wird die prädizierte Dichte mit dem probabilistischen Messmodell, der sog. Likelihood-Funktion  $f^L(\hat{y}_k | x_k)$  verarbeitet. Diese Likelihood-Funktion beschreibt die Wahrscheinlichkeit, dass ein bestimmter Wert  $\hat{y}_k$  gemessen wird unter der Annahme, dass der Systemzustand einen bestimmten Wert hat. Die Likelihood-Funktion berücksichtigt Unsicherheiten und Störungen, die auf den Messwert einwirken. Äquivalent zur Systemgleichung existiert eine Messgleichung, die es ermöglicht, den Zusammenhang zwischen Systemzustand  $x_k$  und Messung  $\hat{y}_k$  in einer Formel zu beschreiben.

In Bild 25 ist eine Likelihood-Funktion als gepunktete Kurve dargestellt. Sie zeigt an, dass aus einer erhaltenen Messung berechnet wurde, dass Systemzustände um den Wert 3 herum die höchste Wahrscheinlichkeit aufweisen. Die Likelihood-Funktion  $f^L(\hat{y}_k | x_k)$  wird nun mit der prädizierten Wahrscheinlichkeitsdichte  $f^p(x_k)$  entsprechend dem Bayes-Theorem verarbeitet. Dies entspricht der (punktweisen) Multiplikation der prädizierten Wahrscheinlichkeitsdichte mit der Likelihood-Funktion und der anschließenden Normierung des Ergebnisses. Das Ergebnis der Berechnung ist die geschätzte Wahrscheinlichkeitsdichte  $f^e(x_k)$ . Hier ist auch oft eine analytische Lösung möglich, bei der nur Parameter der Wahrscheinlichkeitsdichte abgebildet werden, um von einer prädizierten Wahrscheinlichkeitsdichte zur geschätzten Wahrscheinlichkeitsdichte zu gelangen. Für bestimmte Systeme lässt sich dies mit den Kalman-Filter-Gleichungen lösen.

### Beispiel Filterung

In Bild 25 ist beispielhaft ein Filterschritt dargestellt. Die prädizierte Wahrscheinlichkeitsdichte  $f^p(x_k) = N(x - 2, 1)$  wird mit der Likelihood-Funktion



**Bild 25:** Filterung – Verarbeitung einer prädizierten Wahrscheinlichkeitsdichte und einer Likelihood-Funktion zur geschätzten Wahrscheinlichkeitsdichte

$f^L(\hat{y}_k|x_k) = N(x - 3, 2)$  multipliziert. Das Ergebnis der Filterung ist die geschätzte Wahrscheinlichkeitsdichte  $f^e(x_k) = N(x - 1, \sqrt{2/3})$ , also eine Normalverteilung mit Erwartungswert  $\hat{x} = 1$  und Standardabweichung  $\sigma = \sqrt{2/3}$ . An diesem Beispiel lässt sich sehr gut der Einfluss der Unsicherheit der verarbeiteten Größen darstellen. Die prädizierte Wahrscheinlichkeitsdichte hat mit der Standardabweichung  $\sigma = 1$  eine deutlich geringere Unsicherheit als die Likelihood-Funktion mit Standardabweichung  $\sigma = 2$ . Das Ergebnis, die geschätzte Wahrscheinlichkeitsdichte, liegt aber „näher“ an der prädizierten Wahrscheinlichkeitsdichte, der Einfluss der sichereren Größe auf das Schätzergebnis ist also größer als der Einfluss der unsichereren Größe. Prinzipiell lässt sich sagen, dass, je größer die Unsicherheit ist, desto kleiner ist der Einfluss auf das Verarbeitungsergebnis.

#### 4.2.4 Datenplausibilisierung

Der modellbasierte Zustandsschätzer kann weiterhin für die Überprüfung der Plausibilität von Mess- und Prüfdaten verwendet werden. Dabei wird die

prädizierte Messung, d. h. die Vorhersage aus dem Prozessmodell, mit der aktuellen Messung verglichen. Gibt es hierbei größere Abweichungen so deutet dies auf implausible Messungen hin. Für die Plausibilisierung kann das Prozessmodell auf verschiedene Arten mit der aktuellen Messung verglichen werden.

#### Mahalanobis-Distanz

Ausreißer oder implausible Messungen können das Ergebnis des Zustandsschätzers verfälschen. Um Ausreißer in den Messdaten zu erkennen, kann ein Gating mittels der Mahalanobis-Distanz durchgeführt werden. Dafür werden die Wahrscheinlichkeitsdichte der möglichen Messungen und die aktuellen Messungen verwendet, d. h., es wird verglichen, inwieweit der aktuelle Messwert mit der Modellerwartung übereinstimmt. Die Mahalanobis-Distanz kann als ein Ellipsoid betrachtet werden, wenn die Distanzen gleich eines Schwellenwerts sind. Damit beschreibt das Ellipsoid eine Konfidenzregion. Der Schwellenwert der Mahalanobis-Distanz wird über eine Chi-Quadrat-Verteilung hergeleitet (44), um eine Aussage über die Konfidenz



zu geben (z. B. Punkt bzw. Messwert liegt im 90%-Konfidenz-Bereich einer Normalverteilung).

Das eigentliche Gating erfolgt dann wie folgt: Liegt die Mahalanobis-Distanz oberhalb des Schwellenwerts, wird die Messung verworfen und der Zustand wird nicht mit der Messung fusioniert, d. h., es wird nur eine Prädiktion durchgeführt. Hier ist die Annahme, dass die neue Messung nicht zu den alten Messungen und dem Systemmodell passt und somit ein Ausreißer vorliegt. Hingegen im anderen Fall, wenn die Mahalanobis-Distanz kleiner gleich des Schwellenwerts ist, wird der Zustand mit der Messung im Filterschritt aktualisiert. Dieser Ansatz ist sowohl für univariate Mess- und Prüfgrößen sowie auch für multivariate Mess- und Prüfgrößen oder die Kombination mehrerer Größen (45, 29, 19) möglich.

### Überwachung der Innovation

Die Innovation oder auch der Vorhersagefehler ist das Residuum zwischen Messung und prädikterter Messung (von der aktuellen Zustandsschätzung erwarteter Messwert). Im Falle von linearen Systemen und bekannten System- und Rauschparametern muss die Innovationssequenz erwartungswertfrei, weiß und normalverteilt sein. Treten Sensoroffset-Fehler auf oder verändern sich die Systemstruktur, Systemparameter oder die Varianz des System- bzw. Messrauschens, so sind die beiden genannten Eigenschaften der Innovationssequenz nicht mehr erfüllt. Diese Eigenschaften können mit zwei statistischen Hypothesentests (Zero-Mean Test, Whiteness Test) überwacht werden (46, 47). Für die Tests werden der Stichprobenmittelwert und die Stichprobenkovarianz basierend auf der Innovationssequenz verwendet.

#### 4.2.5 Das Kalman-Filter für einfache lineare Probleme

Das Kalman-Filter hat durch seine einfache Struktur sowie Eignung für eine Vielzahl technischer Systeme eine weite Verbreitung und Bekanntheit erfahren. Das Kalman-Filter erfüllt die sog. BLUE-Eigenschaft (Best Linear Unbiased Estimator) und ist somit das beste Filter für lineare Systeme. Dies bedeutet, dass die berechneten Erwartungswerte korrekt sind und die Unsicherheiten (Varianzen) so klein wie möglich berechnet sind (17).

Eine weitere wichtige Eigenschaft ist, dass alle Wahrscheinlichkeitsdichten nicht explizit dargestellt

werden, sondern nur Erwartungswert und Kovarianzmatrix zur Verarbeitung benötigt werden. Somit lassen sich Normalverteilungen fehlerfrei verarbeiten. Weiterhin versucht das Kalman-Filter, den (Schätz-)Fehler zu minimieren, und hat große Ähnlichkeiten zu Kleinste-Quadrate-Schätzern, wie sie zum Beispiel in der Ausgleichsrechnung verwendet werden (48).

Zur Zustandsschätzung mit dem Kalman-Filter werden alle benötigten Größen in der System- und der Messgleichung spezifiziert. Die Systemgleichung hat die Form

$$x_{k+1} = A_k \cdot x_k + B_k \cdot u_k + w_k$$

und wird als „linear“ bezeichnet.  $A_k$  und  $B_k$  sind Matrizen, die den aktuellen Zustand  $x_k$  sowie eine gegebene Eingangsgröße  $u_k$  linear abbilden. Der Term  $w_k$  ist eine erwartungswertfreie, normalverteilte und zeitlich unabhängige Zufallsvariable (i. i. d.-verteilt), welche die Störungen und Unsicherheiten des probabilistischen Prozessmodells vereint. Die lineare Messgleichung besitzt die Form

$$\hat{y}_k = H_k \cdot x_k + v_k$$

mit der Matrix  $H_k$  als lineare Abbildung vom Zustand  $x_k$  in den Messraum sowie der normalverteilte erwartungswertfreie und zeitlich unabhängige Zufallsvariable  $v_k$ . Ähnlich wie  $w_k$  in der Systemgleichung beschreibt  $v_k$  hier die Unsicherheit der Messung mit allen möglicherweise auftretenden Störungen. Hier ist noch zu erwähnen, dass der Filteralgorithmus nicht zwischen Ein- und Mehr-Größen-Sensoren oder mehreren Sensoren unterscheidet. Ein Unterschied ergibt sich nur durch eine andere Modellierung des Messprozesses, zum Beispiel durch eine andere Messgleichung.

#### Beispiel Kalman-Filter – Temperatursensor

Im Folgenden werden die Gleichungen des Kalman-Filters beispielhaft für den Temperatursensor angegeben. Die Filtergleichungen für das Kalman-Filter lassen sich nach dem Festlegen der System- und Messgleichung (siehe Beispiel Temperatursensor – PV-Modell und Beispiel Multiring-Elektrode – Messgleichung) anwenden, um neue Werte für Erwartungswert  $\hat{x}_k$  und Kovarianzmatrix  $C_k$  der aktuellen Zustandsschätzung zu erhalten (17). Im einfachsten Fall ergeben sich die folgenden Filtergleichungen:

Update Erwartungswert

$$\hat{x}_k^e = \hat{x}_k^p + K_k \cdot (\hat{y}_k - H_k \cdot \hat{x}_k^p),$$

Update Kovarianzmatrix

$$C_k^e = C_k^p - K_k \cdot H_k \cdot C_k^p,$$

Kalman-Gain

$$K_k = C_k^p \cdot H_k^T \cdot (H_k \cdot C_k^p \cdot H_k^T + C_k^v)^{-1}$$

wobei  $\hat{x}_k^p$  und  $C_k^p$  der prädierte Erwartungswert und Kovarianzmatrix (Prädiktionsschritt),  $\hat{x}_k^e$  und  $C_k^e$  der geschätzte Erwartungswert und Kovarianzmatrix (Filterschritt) und  $\hat{y}_k$  die aktuelle Messung zum Zeitpunkt  $t_k$  sind. Für die Datenplausibilisierung können die Innovation und die Mahalanobis-Distanz wie folgt berechnet werden

Innovation

$$I_k = \hat{y}_k - H_k \cdot \hat{x}_k^p$$

Mahalanobis-Distanz

$$d_k = \sqrt{(I_k)^T \cdot (H_k \cdot C_k^p \cdot H_k^T + C_k^v)^{-1} \cdot I_k}$$

welche anschaulich die Differenz der prädierten Schätzung  $\hat{x}_k^p$  und der aktuellen Messung  $\hat{y}_k$  darstellen. Überschreitet diese Distanz einen bestimmten, vorher festgelegten Wert, so passt die Messung nicht mehr zu der Prädiktion und kann somit als nicht plausibel klassifiziert werden.

Eine wichtige Eigenschaft dieser Filtergleichungen ist deren rekursive Darstellungsform. Das heißt, dass für die Berechnung eines Verarbeitungsschritts nur die Parameter der aktuellen Zustandsschätzung notwendig sind, es müssen also nie mehr als der Erwartungswert und die Kovarianzmatrix für die Verarbeitung gespeichert werden – auch schon verarbeitete Messungen können verworfen werden. Hierdurch ergibt sich ein weiterer Vorteil dieses Verfahrens, die Echtzeitfähigkeit. Unabhängig von der aktuellen Zustandsschätzung werden immer dieselben Filtergleichungen verarbeitet und somit ist der Verarbeitungsaufwand unabhängig von der vorherigen Verarbeitung konstant. Dies ist eine wichtige Eigenschaft, die auch viele Schätzalgorithmen für nichtlineare Modelle aufweisen.

#### 4.2.6 Zustandsschätzer für komplexe nichtlineare Probleme

Im Wesentlichen wird zwischen Schätzalgorithmen für lineare und nichtlineare Probleme unterschieden. Lineare Probleme lassen sich üblicherweise mit dem im vorherigen Kapitel vorgestellten Kalman-Filter lösen. Für nichtlineare Schätzprobleme existiert eine Vielzahl von spezialisierten Algorithmen,

von denen ein paar ausgewählte kurz vorgestellt werden. Die Klassifikation erfolgt hier nach der Art der Repräsentation der Zustandsschätzung, also dem Typ der Wahrscheinlichkeitsdichte, die verarbeitet wird (17).

#### Normalverteilung

Die Normalverteilung zur Dichterepräsentation wird von vielen Arten von „nichtlinearen Kalman-Filtern“ verwendet. Bekannte Vertreter sind das Extended-Kalman-Filter (EKF) sowie das Unscented-Kalman-Filter (UKF). Diese Filter linearisieren die nichtlinearen System- und Messgleichungen und erhalten so ein lineares System, welches eine approximative Lösung darstellt. Je nach verwendetem Algorithmus kann diese Linearisierung unterschiedlich ausfallen und zu einem besseren oder schlechteren Schätzergebnis führen. Beschreibungen dieser Algorithmen finden sich zum Beispiel in (48, 20). Das Unscented-Kalman-Filter stammt aus der Klasse der Linear-Regression-Kalman-Filter (LRKF), welche mehrere Punkte durch die nichtlinearen Gleichungen abbilden und durch Regression ein linearisiertes Modell bestimmen. Das UKF verwendet die sogenannte „Unscented Transform“. Hierbei wird eine Normalverteilung an bestimmten Punkten abgetastet, diese Samples werden durch das nichtlineare Modell abgebildet und aus den Samples wird wieder eine Normalverteilung approximiert.

#### Gaußmischverteilung

Gaußmischverteilungen sind gewichtete Normalverteilungen, mit denen es prinzipiell möglich ist, beliebige Wahrscheinlichkeitsverteilungen zu approximieren. Damit lassen sich zum Beispiel multimodale Wahrscheinlichkeitsdichten repräsentieren und nicht eindeutig lösbare Schätzprobleme verarbeiten. Mit Gaußmischverteilungen lassen sich auch direkt die bedingten Wahrscheinlichkeitsdichten für das probabilistische Prozessmodell und das probabilistische Messmodell beschreiben und somit beliebige nichtlineare Zusammenhänge darstellen. Ein Vertreter von Algorithmen zur Verarbeitung dieser Wahrscheinlichkeitsdichten ist das Gaussian-Sum-Filter (18).

#### Partikel

Partikelbasierte Ansätze, auch Sample- oder Stichproben-basierte Algorithmen genannt, repräsentieren eine Wahrscheinlichkeitsverteilung durch eine

(gewichtete) Summe von Dirac-Impulsen (17). Es existiere eine große Bandbreite an Verfahren zur deterministischen oder zufälligen Auswahl von Samples und deren Verarbeitung. Ein Nachteil dieser Verfahren ist der hohe Rechenaufwand, der üblicherweise linear mit der Anzahl Samples steigt. Dies kann vor allem für hochdimensionale Zustandsräume problematisch werden.

### Hybride Wahrscheinlichkeitsverteilungen

Hybride Wahrscheinlichkeitsverteilungen besitzen kontinuierliche Anteile, wie Gauß-(Misch-)Verteilungen, und diskrete Anteile, wie eine Summe von Dirac-Impulsen. Für unterschiedliche Teilräume des Zustandsraums werden andere Dichterepräsentationen abhängig vom Grad der Nichtlinearität verwendet. Dadurch soll das Schätzproblem in ein „einfaches“ und ein „schwieriges“ Teilproblem zerlegt werden, welche mit spezialisierten Algorithmen verarbeitet werden können. Beispiele für diese Klasse von Schätzverfahren sind (49) und (50).

### Smoothing (17, 51)

Durch die Verwendung von Smoothing-Verfahren (17, 51) kann im Vergleich zur Filterung eine glattere Schätzung berechnet werden, wobei aber die Zustandsaussage sich nicht auf den aktuellen (Mess-)Zeitpunkt bezieht. Betrachtet man den bedingte Erwartungswert  $x_{l|k} = E(x_l | y_0, \dots, y_k)$ , so ist dies der Zustand zum Zeitpunkt  $l$  unter Einbeziehung der Messungen bis zum Zeitpunkt  $k$ . Smoothing, Filterung oder Prädiktion liegen vor, wenn  $l < k$ ,  $l = k$  oder  $l > k$  ist.

### Rauch-Tung-Striebel-Smoother (52)

Der Rauch-Tung-Striebel-Smoother auch RTS-Smoother genannt, ist ein rechnerisch effizientes Verfahren, um ein geglättetes Schätzergebnis zu erhalten. Die Glättung erfolgt mittels des Systemmodells. Voraussetzung für den RTS-Smoother ist, dass ein lineares System vorliegt und die Wahrscheinlichkeitsverteilungen für den Zustand und die Rauschgrößen normalverteilt ist. Der RTS-Smoother besteht aus zwei Schritten. Im ersten Schritt wird ein Kalman-Filter verwendet, welcher vorwärts in der Zeit die Messungen bis zum aktuellen Zeitpunkt verarbeitet. Im zweiten Schritt wird rückwärts in der Zeit der Zustand geglättet basierend auf dem geschätzten Zustand und dem Systemmodell.

### Unscented Rauch-Tung-Striebel-Smoother (53)

Der unscented Rauch-Tung-Striebel-Smoother (uRTS-Smoother) kann im Falle von einem nicht-linearen Systemmodell angewendet werden. Der uRTS-Smoother ist ähnlich wie der RTS-Smoother aufgebaut. Im ersten Schritt wird ein EKF/UKF/LRKF verwendet, um die Messdaten zu verarbeiten. Im zweiten Schritt wird zu jedem Zeitpunkt die Verbunddichte zwischen den geschätzten und prädierten Zuständen mittels des UKF berechnet, um eine Linearisierung durchzuführen. Mithilfe der ersten beiden Momente dieser Verteilungen (Erwartungswert Kovarianz) wird dann die Glättung vorgenommen.

### Interactive Multiple Model (IMM) (28)

Die Beschreibung des Systems (Systemmodell/ Messmodell) kann in vielen Fällen nicht durch ein einzelnes Modell hinreichend genau beschrieben werden. Daher wird eine endliche Anzahl von Modellen angenommen, die die unterschiedlichen Systemverhalten beschreiben. Diese Modelle können sich z. B. im Rauschpegel, in der Systemstruktur/ Parameter oder in der Dimensionalität des Zustands unterscheiden. Ein Signal z. B., welches zu unterschiedlichen Zeitpunkten zwischen langsamen und schnellen Veränderungen wechselt, kann mit zwei Systemmodellen beschrieben werden. Treten im Signal z. B. Ausreißer auf, so können zwei Modelle für das Messrauschen verwendet werden.

Algorithmen, die ein Multiple Model (MM) verwenden, können in statische und dynamische MM-Verfahren unterschieden werden. Bei statischen MM-Verfahren können die Modelle über die Zeit nicht wechseln. Bei dynamischen MM-Verfahren wechseln die einzelnen Modelle basierend auf einer Markov-Kette mit bekannter Übergangsmatrix. Praktikable dynamische MM-Verfahren sind das „Generalized Pseudo-Bayesian“- (GPB-) und das „Interacting Multiple Model“- (IMM-)Verfahren. Die Algorithmen verarbeiten gleichzeitig mehrere Hypothesen, wobei jede Hypothese mit einem Modell korrespondiert. Neben einer kontinuierlichen Wahrscheinlichkeitsdichte über den Zustand berechnet das Verfahren eine diskrete Modellwahrscheinlichkeit.

Dieses gemischt kontinuierliche/diskrete Schätzproblem kann nicht exakt gelöst werden, da die exakte Lösung eine Gaußmischverteilung ist, bei

der die Anzahl der Komponenten mit der Zeit exponentiell ansteigt. Um diesen exponentiellen Anstieg der Komponenten zu vermeiden, werden approximative Ansätze wie GPB- und IMM-Verfahren verwendet. Hinsichtlich Approximationsgüte und Implementierungsaufwand bietet das IMM-Verfahren den besten Kompromiss. Für jedes Modell wird genau ein Kalman-Filter verwendet. Zudem werden aus der Interaktion und Gewichtung der Modelle resultierende Mischverteilungen durch Normalverteilung approximiert. Zudem ermöglicht das IMM-Verfahren eine Interpolation zwischen den Modellen. Das IMM-Verfahren wurde bereits in Kapitel 3.2.4 bei den Multiple-Modelle-Ansätzen erwähnt.

### **Robuste Kalman-Filter (54)**

Das Kalman-Filter ist optimal, wenn angenommen wird, dass das Systemmodell und die Wahrscheinlichkeitsverteilung des Rauschens bekannt sind. Sind diese Annahmen verletzt, kann das Kalman-Filter degenerieren, d. h. eine zu sichere Schätzung abgeben, die nicht der Wahrheit entspricht. Befindet sich z. B. in den Messdaten ein Ausreißer und wird dieser nicht erkannt, so kann dieser zu einem großen Fehler im Schätzergebnis führen. Dies ist der Fall, wenn das Filter stärker der Messung als der Vorhersage (Systemmodell) vertraut. Robuste Kalman-Filter können diesem Verhalten entgegenwirken, indem diese adaptiv auf unterschiedliche und veränderliche Störeinflüsse reagieren und sich daraufhin anpassen. Somit sind robuste Kalman-Filter robust gegenüber Ausreißern, nicht-normalverteilterm Rauschen (z. B. Heavy-tailed-Verteilung (55)) und sich zeitlich verändernde Rauschcharakteristiken.

## **4.2.7 Zusammenfassung**

### **Plausibilisierung**

Die Verfahren der modellbasierten Zustandsschätzung sind gut für die Plausibilisierung von Mess- und Erfassungsdaten im robusten Brückenmonitoring geeignet. Im Allgemeinen wird dabei die prädierte Messung, d. h. die Vorhersage aus dem Prozessmodell, mit der aktuellen Messung verglichen; eine größere Abweichung deutet auf implausible Messungen hin. Je nach Anwendung stehen hier verschiedene Algorithmen zur Verfügung, für lineare Problemstellungen eignet sich das Kalman-Filter bzw. Interactive-Multiple-Modell, wohingegen für nichtlineare Problemstellungen entsprechend nicht-

lineare Zustandsschätzer eingesetzt werden sollten. Der Vorteil der modellbasierten Herangehensweise ist die gute Rückverfolgbarkeit, d. h. die genaue Nachvollziehbarkeit der Plausibilisierungsergebnisse, und es kann durch die systematische Betrachtung der Unsicherheiten jederzeit eine Aussage darüber getroffen werden, wie sicher die Schätzung bzw. Plausibilitätsaussage ist. Als Nachteil ist zu erwähnen, dass bei allen Verfahren der modellbasierten Zustandsschätzung Expertenwissen in Form von physikalischen Modellen notwendig ist. Insbesondere handelt es sich beim robusten Brückenmonitoring um physikalische Modelle mit sehr vielen (unbekannten) Parametern (z. B. Materialkonstanten, Diffusionskonstanten) und sogar inhomogene Modelle. Durch einige Vereinfachungen, wie beispielsweise die Berücksichtigung von sehr allgemeingültigen physikalischen Gesetzen (z. B. Trägheitseigenschaften), so wie sie in Kapitel 3.2 vorgestellt wurden, kann diese Aussage ein wenig entschärft werden.

### **Fusion von Sensordaten**

Die Verfahren der modellbasierten Zustandsschätzung sind gut für die Fusion von Mess- und Erfassungsdaten im robusten Brückenmonitoring geeignet. Im Allgemeinen wird ein explizites physikalisches Modell, welches die physikalischen Eigenschaften und Zusammenhänge des zu untersuchenden Prozesses beschreibt, angenommen, z. B. zeitunabhängige Stoffgesetze, analytische Lebensdauermodelle sowie Modelle zur Beschreibung des Last- und Verformungsverhaltens, siehe Kapitel 3.2. Bei der modellbasierten Zustandsschätzung wird dieses physikalische Hintergrundwissen implizit mit berücksichtigt, sodass die Mess- und Erfassungsdaten bei der Fusion (beispielsweise Temperatur- und Feuchtigkeitssensor) bezüglich Genauigkeit und Glattheitseigenschaften verbessert werden können. Allerdings ist eine entsprechende mathematische Modellierung der physikalischen Zusammenhänge zwischen den einzelnen Sensoren notwendig. Es ist zwar eine Fusion der Mess- und Erfassungsdaten ohne ein entsprechendes physikalisches Modell möglich, dies führt allerdings zu ungenaueren Ergebnissen.

### **Interpolation**

Die Verfahren der modellbasierten Zustandsschätzung sind gut für die zeitliche und örtliche Interpolation geeignet. Im Allgemeinen bestehen die Algo-

	Plausibilisierung	Fusion von Sensordaten	Interpolation	Ableitung höherwertiger Information	Datenreduktion
Kalman-Filter	Green	Yellow	Green	Yellow	Green
Smoothing	Yellow	Red	Green	Red	Red
Interactive Multiple Modell	Yellow	Green	Green	Yellow	Yellow
Robuste Kalman-Filter	Red	Green	Green	Yellow	Yellow
Nichtlineare Zustandsschätzer	Green	Green	Green	Yellow	Green

rithmen aus einem Prädiktionsschritt und einem Filterschritt, die sich jeweils abwechseln. Sind aktuell keine Messungen vorhanden, entweder für einen bestimmten Zeitpunkt oder für einen bestimmten Ort, so kann mittels des Prädiktionsschritts basierend auf dem physikalischen Modell die letzte Messung fortgeschrieben werden. Je genauer die Modellierung des unterlagerten Prozesses, desto genauer ist auch die Interpolation. Sind nach einer gewissen Zeit wieder Messungen vorhanden, so können diese mittels des Filterschrittes für eine Verbesserung der aktuellen Schätzung genutzt werden. Durch die systematische Berücksichtigung der Unsicherheit kann jederzeit eine Aussage darüber getroffen werden, wie sicher die Interpolation ist; beispielsweise vergrößert sich die Unsicherheit automatisch, je länger das Interpolationsintervall ist.

### Ableitung höherwertiger Information

Die Verfahren der modellbasierten Zustandsschätzung sind gut für die Ableitung höherwertiger Information geeignet. Die systematische Herangehensweise bietet die Möglichkeit zur Identifikation von unbekanntem Parametern, wie z. B. Materialkonstanten, Bauwerkseigenschaften, Elastizitätsmodulen, Diffusionskonstanten usw. Dabei wird das Zustandsschätzproblem mathematisch so umformuliert, dass diese unbekanntem Parameter mit im Systemzustand auftauchen und somit mit geschätzt werden können; dies stellt dann ein sogenanntes adaptives Identifikationssystem dar. Allerdings sollte die Anzahl der unbekanntem, zu bestimmenden Parameter je nach Anwendung eine bestimmte Grenze nicht überschreiten, da sonst die Konvergenz zum richtigen Parameter nicht sichergestellt ist. Die identifizierten Parameter stellen die höherwertigen Informationen, die aus den Mess- und Erfassungsdaten extrahiert wurden, dar. Das einfachste Beispiel ist die Bestimmung von Änderungsraten, z. B. Tem-

peraturänderungen. Hierbei wird der Systemzustand durch die Geschwindigkeit wie in Kapitel 3.2.3 beschrieben (PV-Modell) erweitert und kann somit identifiziert werden.

### Datenreduktion

Die Verfahren der modellbasierten Zustandsschätzung sind gut für die Datenreduktion geeignet. Eine der Eigenschaften ist, dass bei jeder aktuellen Schätzung die gesamte Information aller vergangenen Mess- und Erfassungsdaten steckt. Dadurch ist es möglich, dass beispielsweise die Sensoren lokal vor Ort mit einer hohen Abtastrate die Messdaten erfassen und lokal verarbeiten; in entsprechend größeren Intervallen können diese dann in reduzierter Form an einen zentralen Rechner geschickt werden. Weiterhin ist es je nach Anwendungsszenario möglich, sich auf eine ausschließliche Übertragung der entsprechenden Zustandsparameter anstatt der Messrohdaten zu beschränken.

## 4.3 Maschinelle Lernalgorithmen

### 4.3.1 Überblick und Ziele

Die Sensoren, die beim robusten Brückenmonitoring eingesetzt werden, unterliegen starken mechanischen und umweltbedingten Beanspruchungen, welches die Brauchbarkeit der Mess- und Prüfdaten und Lebensdauer der Sensoren stark einschränkt. Für die Verwendung der Erfassungsdaten in einem nachgeschalteten Brückenmodell zur Bestimmung der Systemzuverlässigkeit ist es somit zwingend erforderlich, diese auf Plausibilität zu beurteilen und somit ein Mindestmaß an Vertrauen in die Qualität der Daten zu haben. Es ist vorteilhaft, bereits am Anfang der Mess- und Prüfkette eine Plausibilitätskontrolle der Daten durchzuführen. Dadurch kann verhindert werden, dass offensicht-

lich fehlerhafte Signale zu falschen Vorhersagen der Systemzuverlässigkeit führen. In diesem Kapitel werden Konzepte und Algorithmen zur automatischen robusten Überprüfung der Mess- und Prüfdaten auf Plausibilität vorgestellt.

Eine der größten zu lösenden Aufgabenstellungen bei der automatischen robusten Überprüfung der Mess- und Prüfdaten auf Plausibilität ist die zuverlässige Erkennung von Auffälligkeiten, wie beispielsweise Ausreißern und Anomalien. Das Ziel besteht darin, aus einem gegebenen Mess- oder Prüfsignal die gesuchten Zusammenhänge und charakteristischen Eigenschaften zu erkennen und basierend darauf Daten, die nicht diesem Muster entsprechen, als Auffälligkeit bzw. als Fehler zu klassifizieren. Um die Genauigkeit der Plausibilisierung zu erhöhen, wird gegebenenfalls zusätzliches Prozesswissen in Form von physikalischen Modellen bei der Berechnung berücksichtigt. Kann dieses Hintergrundwissen nicht vom Betreiber des robusten Brückenmonitorings zur Verfügung gestellt werden, müssen die erforderlichen mathematischen Zusammenhänge entweder angenommen werden (z. B. lineare Interpolation) oder, basierend auf Trainingsdaten gelernt werden. Für die zuverlässige Erkennung von zeitlichen Veränderungen und Abweichungen vom „Normal-Zustand“ in den Mess- und Prüfdaten beim robusten Brückenmonitoring werden in diesem Kapitel Konzepte und Algorithmen vorgestellt.

#### 4.3.2 Univariate, multivariate und verteilte Mess- und Prüfgrößen


Bei der Plausibilisierung von univariaten Mess- und Prüfgrößen wird jedes Signal für sich betrachtet und nach verschiedenen Gesichtspunkten auf Plausibilität hin überprüft beispielsweise Überschreitung von Grenzwerten, Zunahme von Rauschen oder Brummen. In Bild 26 ist ein Beispiel für

die Plausibilisierung eines Temperatursensors dargestellt. Dabei wurde das „Normal“-Verhalten des Sensorsignals aus einer großen Menge an Trainingsdaten mittels künstlichen neuronalen Netzen bestimmt. Durch den Vergleich der aktuellen Temperaturmessung mit dem gelernten Modell des „Normal“-Verhaltens kann ein sogenannter Implausibilitäts-Index berechnet werden und somit Auffälligkeiten erkannt werden, hier die Zunahme des Rauschens im zweiten Drittel des Bildes.

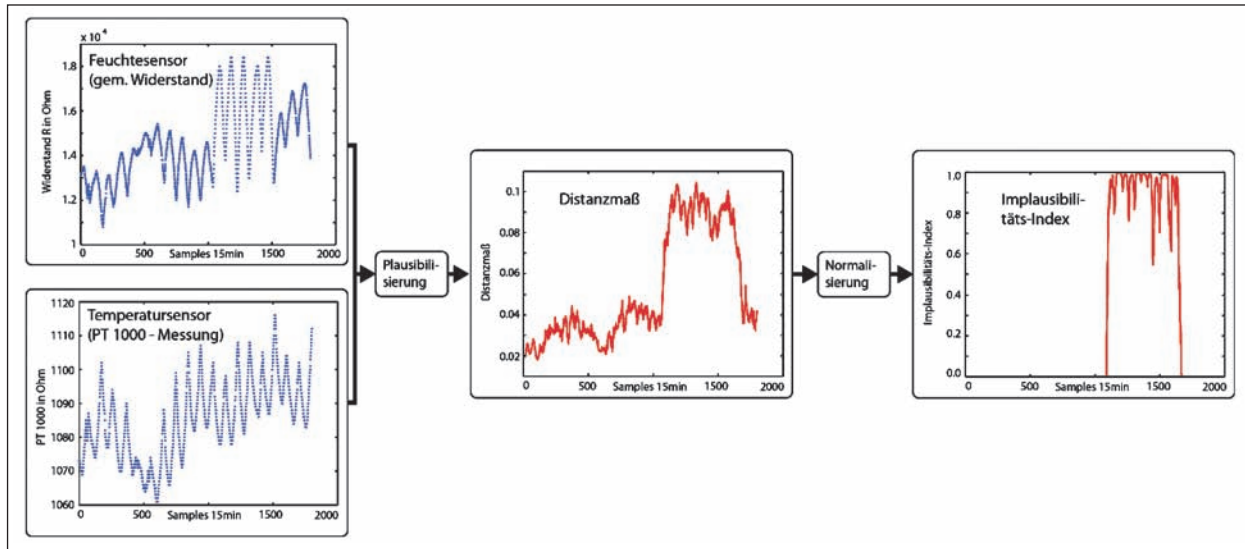
Bei der Plausibilisierung von multivariaten Mess- und Prüfgrößen werden verschiedene Signale die entweder von einem oder mehreren Sensoren stammen, in Kombination betrachtet und nach verschiedenen Gesichtspunkten überprüft; beispielsweise wenn die Temperatur steigt, muss auch die Feuchte tendenziell steigen. In Bild 27 ist ein Beispiel für die Plausibilisierung eines Feuchtesensors in Kombination mit einem Temperatursensor dargestellt. Im zweiten Drittel liefert der Feuchtesensor relativ zum Temperatursensor überproportionale Werte und kann somit als nicht plausibel gelten. Diese detektierte Implausibilität würde in diesem Fall auf einen Defekt des Feuchtesensors (im Speziellen bei der Verstärkung) hindeuten.

Bei der Plausibilisierung von verteilten Mess- und Prüfgrößen werden die verschiedenen Signale des Sensornetzes an verschiedenen Positionen in Kombination betrachtet und nach verschiedenen Gesichtspunkten auf Plausibilität hin überprüft. Als Beispiel soll hier ein Array von Temperatursensoren betrachtet werden. Für plausible Sensorwerte sollte der Verlauf der Temperatur an nahe liegenden Stellen  $x_1$  und  $x_2$  ähnlich sein; beispielsweise beide Temperaturverläufe steigen tendenziell.

Im Folgenden werden einige Ansätze für die automatische Überprüfung der Mess- und Prüfdaten auf Plausibilität vorgestellt. Diese Ansätze können je nach der genauen Problemstellung beim robusten



**Bild 26:** Automatische Überprüfung von univariaten Mess- und Prüfgrößen mittels künstlichen neuronalen Netzen. Im zweiten Drittel nimmt das Rauschen des Temperatursensors zu. Diese Auffälligkeit kann automatisch und zuverlässig erkannt werden [Quelle: reale Sensordaten einer Multiring-Elektrode bereitgestellt durch BAST]



**Bild 27:** Automatische Überprüfung von multivariaten Mess- und Prüfgrößen mittels künstlichen neuronalen Netzen. Im zweiten Drittel liefert der Feuchtesensor relativ zum Temperatursensor überproportionale Werte [Quelle: reale Sensordaten einer Multiring-Elektrode bereitgestellt durch BAST]

Brückenmonitoring entweder einzeln oder in Kombination angewendet werden, um robuste, belastbare Aussage und Kennwerte zu bekommen. Dabei liegt der Fokus auf automatischen und gedächtnis-behafteten Konzepten und Algorithmen.

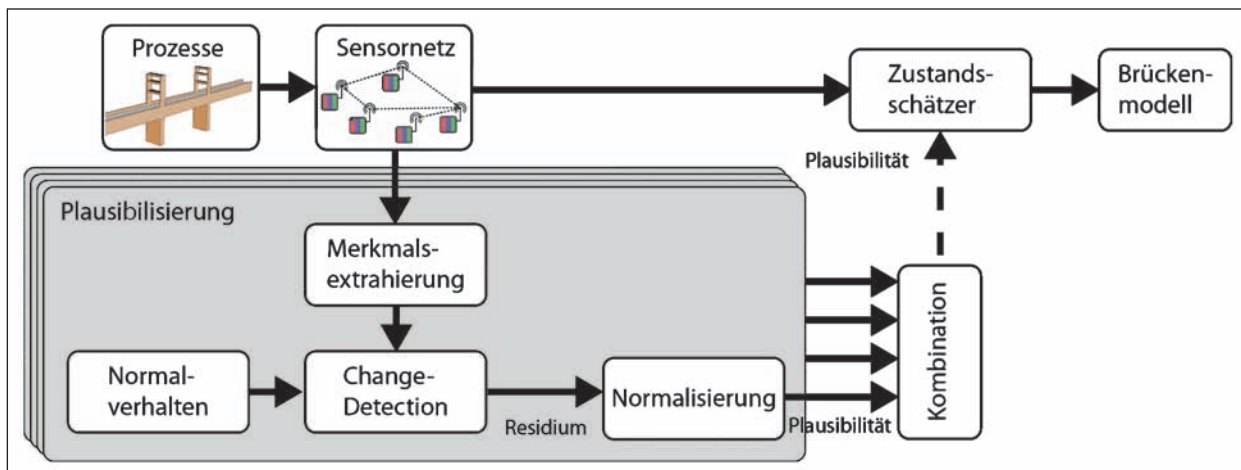
#### 4.3.3 Unüberwachte Lernalgorithmen zur Plausibilisierung

Als unüberwachtes Lernen (im Englischen: Unsupervised Learning) werden maschinelle Lernalgorithmen bezeichnet, die ohne im Voraus bekannte Zielwerte arbeiten. Die Klassenzugehörigkeit der Trainingsbeispiele ist also unbekannt. Die Algorithmen versuchen, in den Eingabedaten Muster zu erkennen, die vom strukturlosen Rauschen abweichen. Stellvertretend für eine ganze Reihe von Algorithmen sollen in dieser Arbeit die künstlichen neuronalen Netze, siehe Kapitel 4.3.5, betrachtet werden (PCA, SOM und GTM stellen Sonderfälle dar). Diese orientieren sich an der Ähnlichkeit zu den Eingabedaten und adaptieren die Gewichte der einzelnen Neuronen entsprechend. Die Algorithmen erzeugen für eine gegebene Menge von Trainingsdaten ein Modell, das die prinzipielle Struktur der Daten beschreibt und sogar Vorhersagen ermöglicht. Dabei gibt es Clustering-Verfahren, die die Daten in mehrere Klassen bzw. Kategorien einteilen, die sich durch charakteristische Muster voneinander unterscheiden. Bei der Plausibilisierung von Sensordaten im Brückenmonitoring ist meistens für den Trainingsdatensatz nicht bekannt,

ob es sich um plausible oder implausible Daten handelt.

Für die Überprüfung der Mess- und Prüfdaten auf Plausibilität können auch maschinelle Lernalgorithmen, insbesondere aus dem Bereich des unüberwachten Lernens (56), verwendet werden. Beim unüberwachten Lernen geht es darum, mittels Merkmalsextraktion und Clusteringverfahren den typischen, normalen Signalverlauf der Mess- und Prüfdaten zu lernen.

In der sogenannten Lernphase wird eine Art Abdruck bzw. Modellbeschreibung über das „Normal“-Verhalten basierend auf einer bestimmten Menge an Trainingsdaten generiert. In der Einsatzphase werden dann die Mess- und Prüfdaten mit der Beschreibung des „Normal“-Verhaltens auf eventuell vorhandene Abweichung bzw. Implausibilitäten hin überprüft. Gibt es Diskrepanzen zwischen dem gelernten „Normal“-Verhalten und dem gemessenen Signalverlauf, wird dieser von der weiteren Verarbeitung ausgeschlossen, um fehlerhafte Ergebnisse basierend auf falschen Eingangswerten zu vermeiden. Weiterhin kann eine entsprechende Meldung an die überlagerte Schicht der Fernüberwachung des Messsystems und des Bauwerks gegeben werden. In Bild 28 ist das Konzept der Plausibilisierung von Mess- und Prüfdaten mittels maschineller Lernalgorithmen dargestellt.



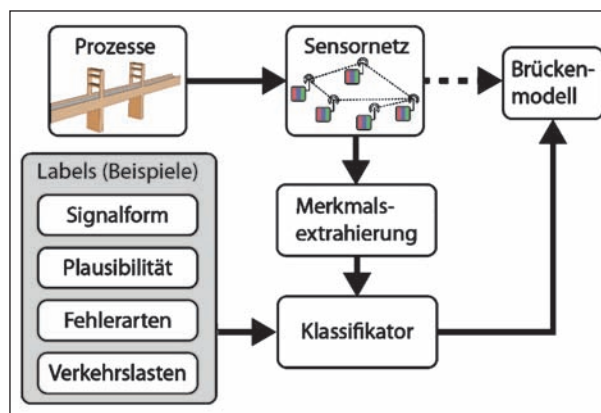
**Bild 28:** Konzept für die Plausibilisierung von Mess- und Prüfdaten mittels maschineller Lernalgorithmen. In der Lern-Phase wird eine Modellbeschreibung des „Normal“-Verhaltens generiert. In der Evaluierungs-Phase wird der gemessene Signalverlauf mit dem gelernten Verhalten abgeglichen und eventuelle Abweichungen bestimmt

#### 4.3.4 Überwachte Lernalgorithmen zur Extraktion von höherwertigen Information

Als überwachtes Lernen (im Englischen Supervised Learning) werden maschinelle Lernalgorithmen bezeichnet, die mit bekannten Zielwerten arbeiten, d. h., die Ein- und Ausgaben des Algorithmus sind bekannt und somit auch die Klassenzugehörigkeit der Trainingsbeispiele. Bei der Plausibilisierung von Mess- und Prüfdaten im Brückenmonitoring muss für die Trainingsdaten also bekannt sein, ob es sich um plausible oder implausible Daten handelt (hier gibt es zwei Klassen bzw. Labels: <Daten plausibel> und <Daten implausibel>).

Diese Verfahren erlauben es, ohne vorheriges Modellwissen relevante Merkmale und Information aus umfangreichem Datenmaterial herauszufiltern. Im ersten Schritt werden relevante Merkmale mittels der im Kapitel 4.3.3 vorgestellten unüberwachten Lernalgorithmen extrahiert. Anschließend werden diese Merkmale (oder auch Features genannt) in einer Lernphase mit Labels versehen, siehe Bild 29. Die Labels hängen davon ab, welche Informationen in der späteren Einsatzphase aus den Daten extrahiert werden sollen. Im Bereich des robusten Brückenmonitorings sind die folgenden Arten von Labels denkbar:

- Signalform – verschiedene Arten von Signalformen, wie beispielsweise überproportionaler Anstieg, Sinusschwingung, Sprünge, Einschwingverhalten bei Aufwärmvorgängen usw.,
- Plausibilität – handelt es sich um plausible oder implausible Mess- und Erfassungsdaten,

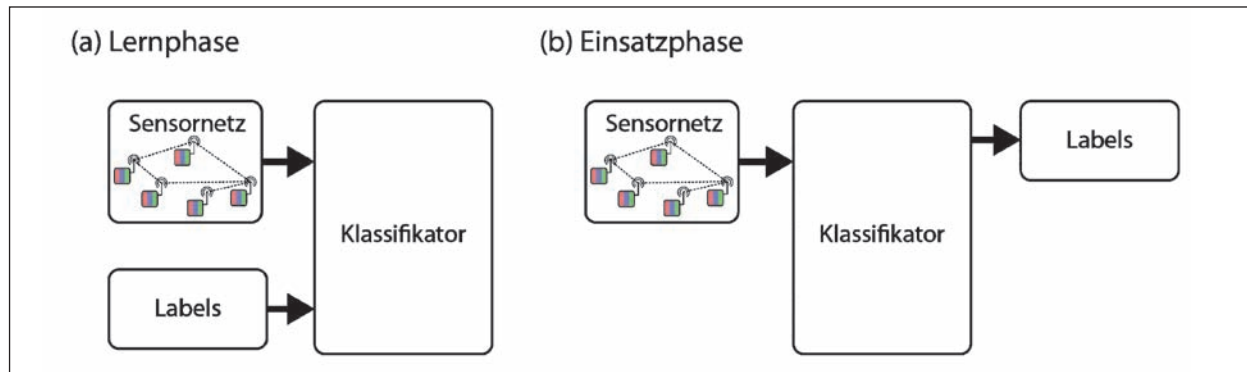


**Bild 29:** Konzept für die Extraktion höherwertiger Information mittels maschineller Lernalgorithmen. Im ersten Schritt werden relevante Merkmale aus den Daten extrahiert und anschließend mit Labels versehen. Mittels eines Klassifikators können dann in der Evaluierungsphase automatisch die gelabelte Information aus den Daten extrahiert werden

- Fehlerarten – verschiedene Arten von Fehlern entweder im Brückenbauwerk oder im Sensorsystem, unerlaubtes Brummen, sprunghafte Rissbreitenänderungen usw.,
- Verkehrslasten – genauere Information über überquerende Fahrzeuge, z. B. Achszahl, Fahrzeugtypen usw.

Im zweiten Schritt wird die Beziehung bzw. die Abhängigkeit zwischen den extrahierten Merkmalen und den definierten Labels mittels eines Klassifikators gelernt, siehe Bild 30 (a). Im Allgemeinen sind Klassifikationsverfahren Methoden und Kriterien zur Einteilung von Objekten, Situationen oder Merkmalsräumen in Klassen. Klassifikatoren sind immer anwendungsbezogen, sodass viele verschiedene Methoden existieren.





**Bild 30:** Einsatz von Klassifikatoren zur Extraktion höherwertiger Information

In der Einsatzphase werden nun aus den Mess- und Erfassungsdaten die Merkmale extrahiert und anschließend mittels des vorher gelernten Klassifikators die entsprechenden Labels, z. B. Signalform, Fehlerarten oder Verkehrslasten, extrahiert, siehe Bild 30 (b). An dieser Stelle ist es wichtig zu erwähnen, dass diese Phasen ohne Expertenwissen in Form von physikalischen Modellen automatisch durchgeführt werden. Im Normalfall wird die Lern- und Einsatzphase getrennt und nacheinander durchgeführt; aber unter bestimmten Rahmenbedingungen ist ein „Nachlernen“ des Klassifikators, d. h. eine Adaption der mathematischen Modelle für die Einsatzphase, möglich.

Die besondere Eigenschaft des maschinellen Lernverfahrens ist seine selbstständige Lernfähigkeit, d. h., basierend auf einen Trainingsdatensatz können diese selbstständig bestimmte Aufgaben erlernen, ohne explizit dafür programmiert zu werden. Die Leistungsfähigkeit und die Möglichkeit der Erfüllung der gestellten Aufgaben hängen hingegen von der Struktur und Anordnung der Verfahren ab. Ist diese einmal für eine bestimmte Problemklasse definiert, so können die Verfahren diese automatisch durchführen und diese selbstständig erlernen.

#### 4.3.5 Übersicht über maschinelle Lernverfahren

Einen Überblick über die zahlreichen Verfahren aus dem Bereich des maschinellen Lernens wird aufgrund des großen Umfangs des Gebiets an dieser Stelle nicht erfolgen. Einige Arbeiten, die eine Einführung solcher Algorithmen für den speziellen Bereich des robusten Brückenmonitorings liefern, sind beispielsweise (57, 58, 59, 60).

Beispiele, wie die Algorithmen des maschinellen Lernens bei der Überprüfung der Plausibilität von uni- und multivariaten Mess- und Prüfdaten im

Bereich des robusten Brückenmonitorings angewendet werden können, sind in Bild 26 und Bild 27 dargestellt. Weiterhin wird in Kapitel 5.1 ein reales Szenario – Multiring-Elektrode mit Temperatursensor PT 1000 – detaillierter betrachtet und die Ergebnisse einer Plausibilisierung der Erfassungsdaten dargestellt.

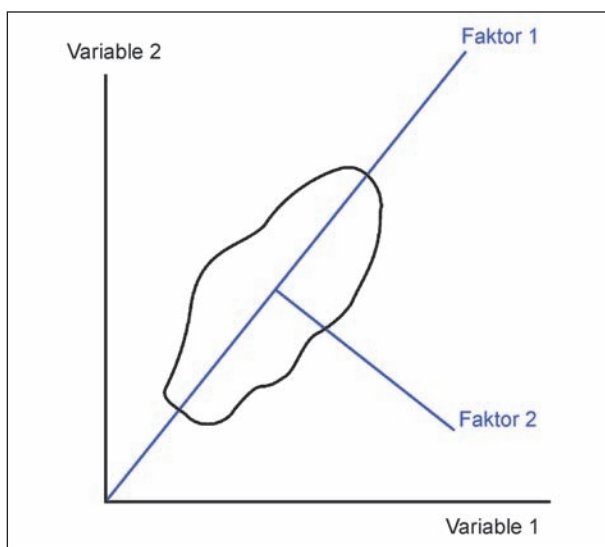
Im Folgenden werden einige Algorithmen, welche im Rahmen dieses Forschungsprojektes detailliert untersucht wurden und für einen Einsatz im Bereich des robusten Brückenmonitoring, als besonders geeignet angesehen werden, kurz erläutert.

#### Principal Component Analysis (PCA)


Die Principal Component Analysis (Hauptkomponentenanalyse) ist ein Verfahren der multivariaten Statistik (57, 61, 62). Eine Vielzahl statistischer Variablen wird durch eine geringere Zahl möglichst aussagekräftiger Linearkombinationen angenähert. Basierend auf der mittels Trainingsdaten gelernten Linearkombination (siehe Bild 31) können ein erwarteter Messwert und dadurch die Abweichung zum tatsächlichen Messwert berechnet werden. PCAs haben den Vorteil der leichten Parametrierung. Allerdings ist es schwierig, eine Unsicherheit in Form von Wahrscheinlichkeitsdichten für die Erkennung von Implausibilitäten zu berechnen. Weiterhin ist es schwierig, bei komplexeren Signalverläufen zwischen Normalverhalten und Auffälligkeiten zu unterscheiden.

#### Künstliche neuronale Netze (KNN)

Die künstlichen neuronalen Netze sind mathematische Beschreibungen, die versuchen, die Struktur und Informationsarchitektur eines Nervensystems von Tieren oder Menschen näherungsweise abzubilden. Diese Netze bestehen aus einer großen Anzahl Neuronen, welche über Synapsen miteinander



**Bild 31:** Principal Component Analysis: zwei Hauptkomponenten einer zweidimensionalen Punktwolke (Quelle: Wikipedia)



**Bild 32:** Vereinfachte Darstellung eines künstlichen neuronalen Netzes (Quelle: Wikipedia)

verknüpft sind und sich Informationen zusenden können, siehe Bild 32. Die besondere Eigenschaft der künstlichen neuronalen Netze ist ihre selbstständige Lernfähigkeit, d. h., basierend auf einem Trainingsdatensatz können diese selbstständig bestimmte Aufgaben erlernen, ohne explizit dafür programmiert zu werden. Die eigentliche Herausforderung ist, die Anordnung der Neuronen bzw. die richtige Struktur des Netzes für bestimmte Aufgaben zu finden. Ein sehr guter Überblick ist in (38) zu finden.

### Self-Organizing Maps (SOM)

Die Self-Organizing Maps sind eine spezielle Art von künstlichen neuronalen Netzen für das unüberwachte Lernen von Merkmalen in Mess- und Prüf-

daten (63, 64, 62). Die gelernten Merkmale können zur Überprüfung der Plausibilität der Mess- und Prüfdaten, also ob Auffälligkeiten vorhanden sind, genutzt werden. SOMs haben den Vorteil der leichten Parametrierung; für das Lernen der Merkmale ist nur wenig Vorwissen in Form von mathematischen Modellen notwendig, allerdings eine große Anzahl an Trainingsdaten. Die Nachteile liegen bei der schwierigen Erweiterung auf Zeitreihen und der systematischen Berücksichtigung von Unsicherheiten. Eine Möglichkeit ist, die SOMs durch ein überlagertes Hidden Markov Model (HMM) zu erweitern; sodass dieser Ansatz auch für Zeitreihen möglich ist.

### Generative Topographic Mapping (GTM)

Das Generative Topographic Mapping kann als probabilistische Erweiterung der SOMs gesehen werden; die Unsicherheiten in den Mess- und Prüfdaten und dem gelernten Modell können systematisch berücksichtigt werden. Ähnlich wie die SOMs können die GTMs bei Vorhandensein einer großen Menge Trainingsdaten sehr einfach parametrierbar werden und sind in der Lage, die Daten sehr schnell auf Plausibilität zu überprüfen. Auch bei den GTMs liegen die Nachteile bei der schwierigen Erweiterung auf Zeitreihen. Eine Möglichkeit ist, die GTMs durch ein überlagertes Hidden Markov Model (HMM) zu erweitern; sodass dieser Ansatz auch für Zeitreihen möglich ist.

### 4.3.6 Zusammenfassung

#### Plausibilisierung

Die maschinellen Lernverfahren eignen sich im Allgemeinen sehr gut für die Plausibilisierung von Mess- und Erfassungsdaten im Bereich des robusten Brückenmonitorings. Diese bieten die Möglichkeit, aus einem Trainingsdatensatz automatisch eine Art Modell zu lernen, welches das „Normal“-Verhalten des Signals und somit des Brückenbauwerks und des Sensorsystems charakterisiert. Bei der Plausibilisierung müssen lediglich die Mess- und Erfassungsdaten mit dem vorher gelernten Modell verglichen werden. Gibt es Diskrepanzen zwischen dem gelernten „Normal“-Verhalten und dem gemessenen Signalverlauf, wird dieser von der weiteren Verarbeitung ausgeschlossen, um fehlerhafte Ergebnisse basierend auf falschen Eingangswerten zu vermeiden. Weiterhin kann eine entsprechende Meldung an die überlagerte Schicht der Fernüberwachung des Messsystems und des Bauwerks

gegeben werden. Der große Vorteil dieser Verfahren ist, dass nur eine geringe Menge Prozesswissen notwendig ist und der automatische Charakter. Der Nachteil ist die große Menge an Trainingsdaten die für das Lernen notwendig sind, diese hängen sehr stark von der zu erlernenden Aufgabenstellung ab.

### Fusion von Sensordaten

Die maschinellen Lernverfahren eignen sich nur sehr begrenzt für die Fusion von Sensordaten.

### Interpolation

Die maschinellen Lernverfahren eignen sich nur begrenzt für die Interpolation von Mess- und Erfassungsdaten.

### Extraktion höherwertiger Information

Die maschinellen Lernverfahren eignen sich gut für die Extraktion höherwertiger Information. Diese Verfahren erlauben es, ohne vorheriges Modellwissen relevante Merkmale und Information aus umfangreichem Datenmaterial herauszufiltern. Voraussetzung für die Extraktion höherwertiger Information und somit für das Treffen fachtechnischer Aussagen ist, dass für eine gewisse Menge an Daten die gewünschte Aussage in Form von Labels vorgegeben werden kann. Beispielsweise muss für die Identifikation von Verkehrslasten für die einzelnen Daten vorgegeben werden, welche Verkehrslast aktuell vorherrscht. Auch hier hängt die Menge der notwendigen Mess- und Erfassungsdaten sehr stark von dem jeweiligen Anwendungsfall ab.

### Datenreduktion

Die maschinellen Lernverfahren eignen sich sehr gut für die Reduktion von Mess- und Erfassungs-

daten im Bereich des robusten Brückenmonitorings. Basierend auf dem Trainingsdatensatz wird mittels Lernverfahren automatisch ein mathematisches Modell gelernt. Dieses Modell bildet die Mess- und Erfassungsdaten auf deren wesentliche, charakteristische Merkmale ab. Durch diese Extraktion der relevanten Merkmale findet also automatisch eine Reduktion der großen Datenmenge statt.

## 5 Untersuchungen der Machbarkeit mittels realer Erfassungsdaten

In diesem Kapitel wird die Machbarkeit einer praktischen Umsetzung der entwickelten und untersuchten Verfahren und Ansätze zur Plausibilisierung, Sensordatenfusion, Interpolation und Ableitung höherwertiger Information anhand von realen Mess- und Erfassungsdaten erprobt und evaluiert. Dabei werden in verschiedenen Szenarien verschiedene Aspekte des robusten Brückenmonitorings einzeln untersucht. Für die folgenden typischerweise eingesetzten Sensoren standen reale Mess- und Erfassungsdaten zur Verfügung und wurden entsprechende Untersuchungen der Algorithmen und Konzepte durchgeführt:

- Multiring-Elektrode mit Temperatursensor PT 1000 (Datenquelle: BAST),
- Temperatur-Array von Kanalbrücke Berkenthin (Datenquelle: BAST),
- Wegaufnehmer erhoben am realen Bauwerk (Datenquelle: Uni Braunschweig),
- Dehnmessstreifen (Datenquelle: Laborversuch),
- Verkehrslastdaten (Datenquelle: Uni Weimar).

	Plausibilisierung	Fusion von Sensordaten	Interpolation	Ableitung höherwertiger Information	Datenreduktion
PCA	Green	Red	Yellow	Red	Green
KNN	Green	Red	Yellow	Green	Green
SOM	Green	Red	Yellow	Yellow	Yellow
GTM	Green	Red	Yellow	Yellow	Yellow

## 5.1 Multiring-Elektrode mit Temperatursensor PT 1000

Die Multiring-Elektrode ist ein erprobtes Verfahren zur Messung der Betonfeuchtigkeit und Betontemperatur. Diese besteht aus mehreren, meistens jedoch acht, übereinander angeordneten Edelstahlringen. Zwischen zwei benachbarten Ringen kann ein Wechselstromwiderstand gemessen werden und daraus ein Widerstandsprofil über die gesamte Einbautiefe des Sensors bestimmt werden. Durch eine materialabhängige Kalibrierkurve kann diese in ein Feuchteprofil umgerechnet werden (4).

Der für die Machbarkeitsuntersuchung verwendete Datensatz wurde von der BAST bereitgestellt und besteht aus realen Messungen von zwei Sensoren zur Bestimmung der Betonfeuchte und der Temperatur. Als Sensoren wurden ein Multiring-Elektrodenpaar bei 22 mm und ein Temperatursensor PT 1000 bei 27 mm Einbautiefe verwendet. Das Abtastintervall beträgt 15 Minuten.

### 5.1.1 Plausibilisierung mittels maschineller Lernalgorithmen

Basierend auf dem Datensatz des Temperatursensors PT 1000 wurde ein mehrlagiges künstliches neuronales Netz so gelernt, dass es jegliche Abweichung von dem Trainingsdatensatz als Auffälligkeit klassifiziert. Das künstliche neuronale Netz besitzt zwei Layers mit jeweils 64 Neuronen. Das Ausgangssignal des künstlichen neuronalen Netzes ist ein sogenannter Implausibilitäts-Index, der ein Indiz dafür ist, wie implausibel das angelegte Eingangssignal, hier die PT-1000-Messungen, ist. Nach der Lernphase wurde in einen Testdatensatz an zufällig verteilten Stellen ein Rauschsignal auf die PT-1000-Messungen addiert. In Bild 34 ist das Ergeb-

nis der Überprüfung der PT-1000-Messungen mittels des gelernten künstlichen neuronalen Netzes dargestellt. Es ist deutlich zu erkennen, dass alle Implausibilitäten in Form von erhöhtem Sensorrauschen zuverlässig, robust erkannt wurden. In einem realen Szenario könnten die Messwerte an diesen Stellen von der weiteren Verarbeitung ausgeschlossen werden, um falsche Ergebnisse basierend auf implausiblen Messdaten zu verhindern. Weiterhin könnten eine bestimmte Meldung und Ergebnisse weiterer Untersuchungen an ein übergeordnetes Fernüberwachungssystem weiter geleitet werden.

### 5.1.2 Filterung mittels modellbasierter Zustandsschätzer

Für die Extraktion und Filterung der relevanten Zustandsgrößen aus den Messdaten der Multiring-Elektrode können die in diesem Projekt vorgestellten modellbasierten Zustandsschätzer verwendet werden.

Für die Modellierung der Temperatur und Betonfeuchte wurden mehrere lineare Systemmodelle verwendet, die jeweils die unterschiedlichen zeitlichen Veränderungen berücksichtigen (siehe SysMo2 und SysMo3). Dabei wurde der Zustand in die Komponenten Trend, Geschwindigkeit des Trends und periodische Tag-/Nacht-Schwankungen für jeweils die Temperatur und Betonfeuchte aufgeteilt (siehe SysMo4). D. h., für den Trend und der Geschwindigkeit des Trends wurde ein „näherungsweise konstantes Geschwindigkeit-Modell“ (29) verwendet. Die Tag-/Nacht-Schwankungen werden mit einem dynamischen sinusförmigen Modell (30) beschrieben. Für die Modellierung des Zusammenhangs zwischen den Sensordaten der Multiring-Elektrode und der Temperatur und Betonfeuchte wurde eine zwei-dimensionale Messab-





Bild 33: Multiring-Elektrode und schematische Darstellung des Messprinzips (4)




**Bild 34:** Künstliche neuronale Netze: Ergebnis der Plausibilisierung von PT-1000-Messungen. Es ist deutlich, dass alle Implausibilitäten in Form von erhöhtem Rauschen zuverlässig, robust erkannt wurden (Zeitfenster 41 Tage)

bildung verwendet. Beim Temperaturfühler wurde ein linearer Messzusammenhang zwischen Temperatur und Messung angenommen. Bei der Multiring-Elektrode liegt ein nichtlinearer Zusammenhang zwischen Temperatur, Betonfeuchte und Messung zugrunde (siehe MessMo1). Als Messrauschen wurde ein additiver normalverteilter Rauschprozess angenommen. Da eine nichtlineare Messabbildung vorliegt, wurde als Zustandsschätzer ein LRKF verwendet. Zudem wurde ein Smoother mit einer Intervallgröße von 12 Stunden verwendet.


In Bild 35 sind die Messwerte der Multiring-Elektrode (gemessener Widerstand) und des PT-1000-Elements aufgetragen. In Bild 36 ist der Temperaturverlauf gezeigt. Das obere Bild zeigt den Verlauf, wenn die inverse Abbildung der Messabbildung verwendet wird (direkte Umrechnung, keine Berücksichtigung von Messrauschen). Die beiden unteren Bilder zeigen den Erwartungswert für den Trend und die periodischen Schwankungen der Temperatur inklusive des 3-Sigma-Bandes. Der Verlauf der Betonfeuchte ist in Bild 37 gezeigt. Das obere Bild zeigt den Verlauf der Betonfeuchte, wenn die Messdaten direkt umgerechnet werden. Die beiden unteren Bilder zeigen den Erwartungswert für den Trend und die periodischen Schwankungen der Betonfeuchte inklusi-

ve des 3-Sigma-Bandes. Zusatzinformationen wie die Geschwindigkeit des Trends sind in Bild 38 dargestellt.


Bei einer direkten Umrechnung verursachen Messfehler bei Temperaturfühler und Multiring-Elektrode direkt Fehler in der Betonfeuchte. Beim Zustandsschätzer werden die Messfehler des Temperaturfühlers und der Multiring-Elektrode in den beiden Messabbildungen getrennt berücksichtigt. Zudem können die Abtastzeitpunkte des Temperaturfühlers und der Multiring-Elektrode unterschiedlich sein, d. h., zu einem Messzeitpunkt müssen nicht beide Messungen zur Verfügung stehen. Bei einer direkten Umrechnung hingegen müssen der Temperaturfühler und die Multiring-Elektrode gleichzeitig ausgewertet werden. Beim Zustandsschätzer werden wenn ein Messwert von der Multiringelektrode verarbeitet wird, gleichzeitig die geschätzte Temperatur und Betonfeuchte aktualisiert. Zudem verhindert beim Zustandsschätzer ein Gating, dass Ausreißer verarbeitet werden. Bei einer direkten Umrechnung ist dies nicht möglich, da vergangene Werte nicht in der Verarbeitung berücksichtigt werden.




**Bild 35:** Zweidimensionale Messdaten – das obere Bild zeigt den Verlauf des gemessenen Widerstands der Multiring-Elektrode. Das untere Bild zeigt den zeitlichen Verlauf vom gemessenen Widerstand des Temperaturfühlers



**Bild 36:** Sensordatenfusion: Temperaturverlauf – im oberen Bild wurde eine direkte Umrechnung vorgenommen. Die beiden unteren Bilder zeigen das Schätzergebnis des Zustandsschätzers für den Temperaturtrend und die Tag-/Nacht-Temperatur-schwankungen



**Bild 37:** Sensordatenfusion: Betonfeuchte – im oberen Bild wurde eine direkte Umrechnung vorgenommen. Die beiden unteren Bilder zeigen das Schätzergebnis des Zustandsschätzers für den Feuchtetrend und die Tag-/Nacht-Feuchteschwankungen



**Bild 38:** Sensordatenfusion: Geschwindigkeitsschätzung des Trends. Das obere Bild zeigt die Geschwindigkeitsschätzung für die Temperatur und das untere für die Betonfeuchte

## 5.2 Temperatursensoren (Kanalbrücke Berkenthin)

In diesem Kapitel werden die Plausibilisierung, Interpolation und Extraktion höherwertiger Information mittels maschineller Lernalgorithmen basierend auf realen Temperatur- und Feuchtedaten der Straßenbrücke B 208/Elbe-Lübeck-Kanal in der Ortslage Berkenthin im Kreis Herzogtum Lauenburg untersucht (65). Ein Foto der Kanalbrücke Berkenthin (von Osten) und dessen Lage im Straßennetz sind in Bild 39 dargestellt.

Der von der BAST zur Verfügung gestellte Datensatz besteht unter anderem aus 19 Thermoelementen zur Messung der Fahrbahntemperatur an drei verschiedenen Stellen der Brücke. Die Messdaten wurden über 2-mal 3 Monate im 20-Minuten-Takt erhoben. In Tabelle 9 sind die Kanal-Nr. und Position der einzelnen Sensoren dargestellt.

Basierend auf dem Datensatz wurde ein künstliches neuronales Netz gelernt. Die besondere Eigenschaft der künstlichen neuronalen Netze ist ihre selbstständige Lernfähigkeit, d. h., basierend auf dem Trainingsdatensatz (Messkanäle M23-M35) können diese selbstständig bestimmte Aufgaben erlernen ohne explizit dafür programmiert zu werden. Die Aufgabe des in diesem Projekt gelernten neuronalen Netzes besteht darin, das Ausgangssignal zu rekonstruieren und Abweichungen vom Normalverhalten (d. h. Ausreißer oder andere Implausibilitäten) zu erkennen.

### Rahmenbedingung

Das gelernte künstliche neuronale Netz besteht aus zwei Schichten mit jeweils 32 Neuronen, welche

über Synapsen miteinander verknüpft sind und sich Informationen zusenden können. Der Trainingsdatensatz besteht aus insgesamt 7.565 Samples (jeweils für Messkanäle M23-M35). Das neuronale Netz wurde im sogenannten Online-Modus gelernt, d. h., jedes Datensample wurde nur einmal zum Lernen verwendet. Die gesamte Berechnungszeit

Sensorposition Q1 – 5 Sensoren	
M34	Temperatur Oberfläche Fahrbahnmitte
M35	Temperatur Oberfläche Fahrbahnmitte
M36	Temperatur Oberfläche Fahrbahnrand
M37	Temperatur Oberfläche Fahrbahnrand
M38	Temperatur ca. 2 cm Tiefe Fahrbahnmitte
M03	Pyrometer 3
Sensorposition Q2 – 8 Sensoren	
M29	Temperatur Oberfläche Fahrbahnmitte
M30	Temperatur Oberfläche Fahrbahnmitte
M31	Temperatur Oberfläche Fahrbahnrand
M33	Temperatur Oberfläche Fahrbahnrand
M20	Lufttemperatur unter der Brücke
M21	Deckblechtemperatur Unterseite
M22	Deckblechtemperatur Unterseite
M02	Pyrometer 2
Sensorposition Q3 – 6 Sensoren	
M23	Lufttemperatur neben der Fahrbahn
M24	Temperatur Oberfläche Fahrbahnmitte
M25	Temperatur Oberfläche Fahrbahnmitte
M26	Temperatur ca. 2 cm Tiefe Fahrbahnmitte
M27	Temperatur Oberfläche Fahrbahnrand
M28	Temperatur Oberfläche Fahrbahnrand
M01	Pyrometer 1

Tab. 9: Sensortyp und Position der einzelnen Sensoren



Bild 39: Kanalbrücke Berkenthin und dessen Lage im Netz (65)



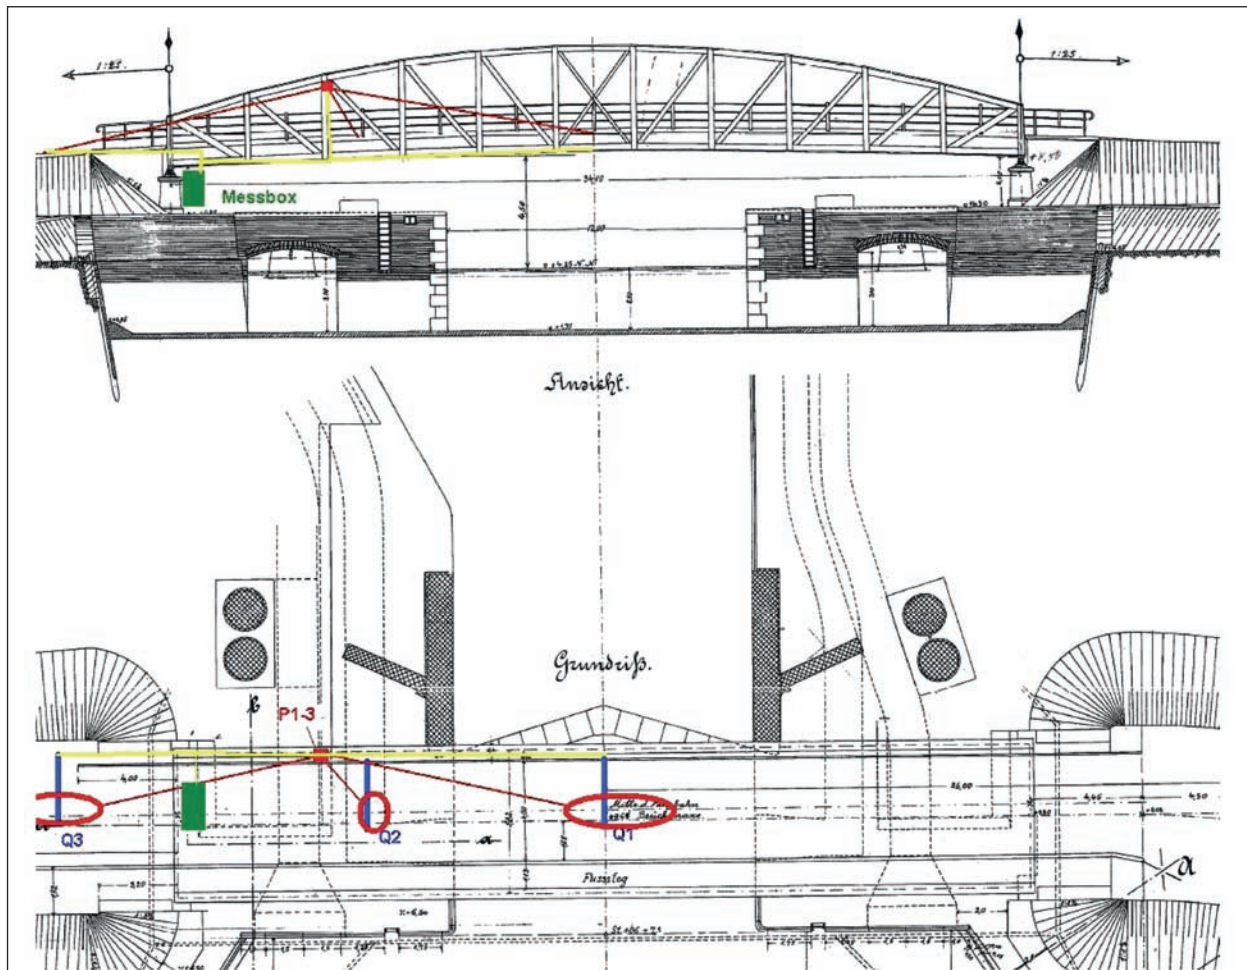
der Lernphase betrug unter Matlab – einer Rapid-Prototyping-Umgebung – auf einen COTS-(Commercial-off-the-shelf-)Rechner (Intel Core i5) insgesamt ca. 5 Minuten. Eine optimierte Implementierung des Algorithmus unter einer anderen Programmiersprache (wie z. B. C++ oder Java) würde erfahrungsgemäß zu einer Erhöhung der Berechnungsgeschwindigkeit um den Faktor 100 bis 1.000 führen. Der Trainingsdatensatz beinhaltet zwar implausible Messdaten (genauer Messausreißer), allerdings ist deren Anzahl im Verhältnis zu der Gesamtgröße des Datensatzes gering, sodass diese nur einen geringen Einfluss auf das gelernte Modell haben, siehe Bild 56 und Bild 57 im Anhang.

Die Sensordaten des Messkanals M36 (Oberflächentemperatur an Sensorposition Q1) wurden zur Evaluierung des gelernten neuronalen Netzes herangezogen. Dieser Datensatz enthält eine Vielzahl an Ausreißern, die detektiert werden sollen. Das gelernte neuronale Netz kann nun für verschiedene Aufgaben, die beim robusten Brücken-

monitoring eine Rolle spielen, genutzt werden: (1) Filterung des Eingangssignals, (2) Erkennung von Implausibilitäten und (3) Extraktion höherwertiger Information. Diese sollen im Folgenden beispielhaft demonstriert werden.

### Filterung des Eingangssignals

In Bild 41 ist das Ergebnis der Filterung bzw. Rekonstruktion dargestellt, die blaue Kurve ist das Eingangssignal und die rote Kurve ist das vom neuronalen Netz rekonstruierte Signal. Dieses Signal ist bereinigt von Sensorfehlern wie beispielsweise Rauschen, Ausreißern und anderen Störsignalen und kann somit als geglättetes Eingangssignal für ein nachgeschaltetes Brückenmodell dienen. Es ist wichtig zu betonen, dass für das Lernen des Modells und für die Filterung bzw. Glättung der Mess- und Erfassungsdaten kein explizites Prozesswissen in Form von physikalischen Modellen notwendig ist. Eine Abweichung zwischen dem geglätteten bzw. rekonstruierten Signalverlauf und dem tat-



**Bild 40:** Bauwerksskizze, Übersicht Messquerschnitt und Darstellung der Sensorposition Q1, Q2 und Q3 [Quelle: bereitgestellt durch BAST]

sächlich gemessenen kann als erstes Indiz für implausible Eingangsdaten dienen.


### Erkennung von Implausibilitäten

In Bild 42 ist das Ergebnis der Plausibilisierung dargestellt, die obere Kurve ist das Eingangssignal in das neuronale Netz und die untere Kurve ist das automatisch bestimmte Implausibilitätsmaß. Es ist deutlich zu erkennen, dass alle Ausreißer bzw. Implausibilitäten robust und zuverlässig erkannt werden. Weiterhin ist zu erwähnen, dass dieses Ver-


fahren eine hohe Sensitivität aufweist, d. h., sind die Ausreißer nur halb so groß, so ist der Peak im Implausibilitätsmaß auch nur halb so groß wie dargestellt und bietet somit noch ausreichend Abstand zum Normalverhalten, um zuverlässig als Ausreißer bzw. Implausibilität erkannt zu werden.

### Extraktion höherwertiger Information


Mittels des gelernten neuronalen Netzes können auch höherwertige Information bzw. Muster extrahiert und erkannt werden, siehe Kapitel 4.3.4.



**Bild 41:** Künstliche neuronale Netze: Darstellung der Eingangssignale (blaue Kurven) und des rekonstruierten geglätteten Signals (rote Kurve). Die Abweichung zwischen diesen beiden Kurven ist ein Indiz für implausible Eingangsdaten bzw. Sensordaten



**Bild 42:** Künstliche neuronale Netze: Darstellung des Eingangssignals (obere Kurve) und des bestimmten Implausibilitätsmaßes. Es ist deutlich zu erkennen, dass alle Ausreißer bzw. Implausibilitäten robust und zuverlässig erkannt werden (Zeitfenster 10 Tage)



**Bild 43:** Künstliche neuronale Netze: Extraktion von höherwertigen Information bzw. Mustern aus dem Eingangssignal. Im oberen Bild ist das Eingangssignal (Messkanal M33) dargestellt und im unteren Bild die Antwort der Neuronen (Zeitfenster 6 Tage). Die Verläufe in dem roten und grünen Kästen wurden jeweils als ähnlich erkannt, d. h., der Verlauf der Neuronen ist ähnlich. Wenn der Verlauf in dem roten Kasten beispielsweise einen Fehlerfall darstellen soll (wurde von einem Operator so als Fehler markiert), so kann dieser aus dem Verlauf der Neuronen zuverlässig erkannt werden (trotz unterschiedlichen Wertenniveaus)

Dadurch können verschiedene Signalverläufe bzw. Fehlersituationen erkannt werden und weiter analysiert werden. In Bild 43 ist die Extraktion von höherwertigen Information aus dem Eingangssignal dargestellt. Im oberen Bild ist das Eingangssignal (Messkanal M33) dargestellt und im unteren Bild die Antwort der Neuronen. Die Verläufe in dem roten und grünen Kästen wurden jeweils als ähnlich erkannt, d. h., der Verlauf der Neuronen ist ähnlich. Wenn der Verlauf in dem roten Kasten beispielsweise einen Fehlerfall darstellen soll (wurde von einem Operator so als Anomalie bzw. Implausibilität markiert), so kann dieser aus dem Verlauf der Neuronen zuverlässig erkannt werden.

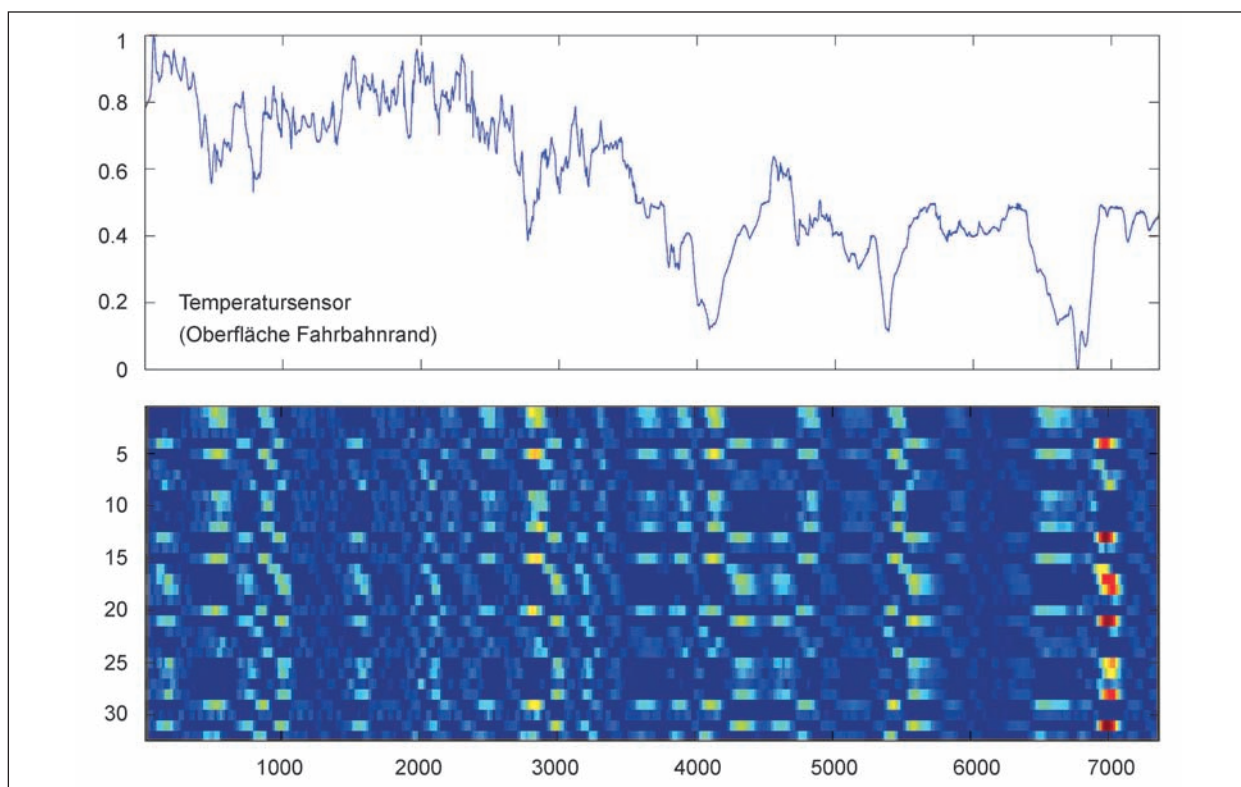
In einem zweiten Schritt müssten für die jeweiligen extrahierten Muster entsprechende Labels definiert werden. In diesem Fall könnte man sich vorstellen, die Muster in dem roten Kasten als <Peak> und die im grünen Kasten als <Plateau> zu labeln. Mittels eines Klassifikators kann nun die Beziehung zwischen den extrahierten Mustern und den vorher definierten Labels gelernt werden, siehe Bild 29. In

der Einsatzphase kann dann direkt von den Mess- und Erfassungsdaten auf die Labels <Peak> und <Plateau> geschlossen werden. Aufgrund unserer Erfahrung reicht die Trennschärfe der extrahierten Muster aus, um mittels eines Klassifikators aus den Mess- und Erfassungsdaten scharfe fachtechnische Aussagen zu extrahieren.

In Bild 44 ist das Ergebnis der Extraktion höherwertiger Information mittels eines vereinfachten Berechnungsverfahrens dargestellt. Es ist deutlich zu erkennen, dass die Muster keine so große Trennschärfe aufweisen, allerdings je nach Anwendungsfall doch genügend Informationen extrahiert werden können. Deutlich sind auch die lokalen Minima zu erkennen.

### 5.3 Wegaufnehmer

In diesem Kapitel werden die Plausibilisierung und Extraktion höherwertiger Information mittels maschineller Lernalgorithmen für Wegaufnehmer



**Bild 44:** Künstliche neuronale Netze: Extraktion von höherwertigen Informationen bzw. Mustern aus dem Eingangssignal. Im oberen Bild ist das Eingangssignal (Messkanal M33) dargestellt und im unteren Bild die Antwort der Neuronen

erhoben am realen Brückenbauwerk erprobt und deren Einsatzfähigkeit evaluiert. Von der BAST wurden zwei Datensätze mit Roh-Messdaten (Abtast-rate 100 Hz) zur Verfügung gestellt.

Basierend auf dem Datensatz wurde ein künstliches neuronales Netz gelernt. Die besondere Eigenschaft der künstlichen neuronalen Netze ist ihre selbstständige Lernfähigkeit, d. h., basierend auf dem Trainingsdatensatz können diese selbstständig bestimmte Aufgaben erlernen, ohne explizit dafür programmiert zu werden. Die Aufgabe des in diesem Anwendungsszenario gelernten neuronalen Netzes besteht darin, das Ausgangssignal zu rekonstruieren, Implausibilitäten zu erkennen und relevante Muster zu extrahieren.

### Rahmenbedingung

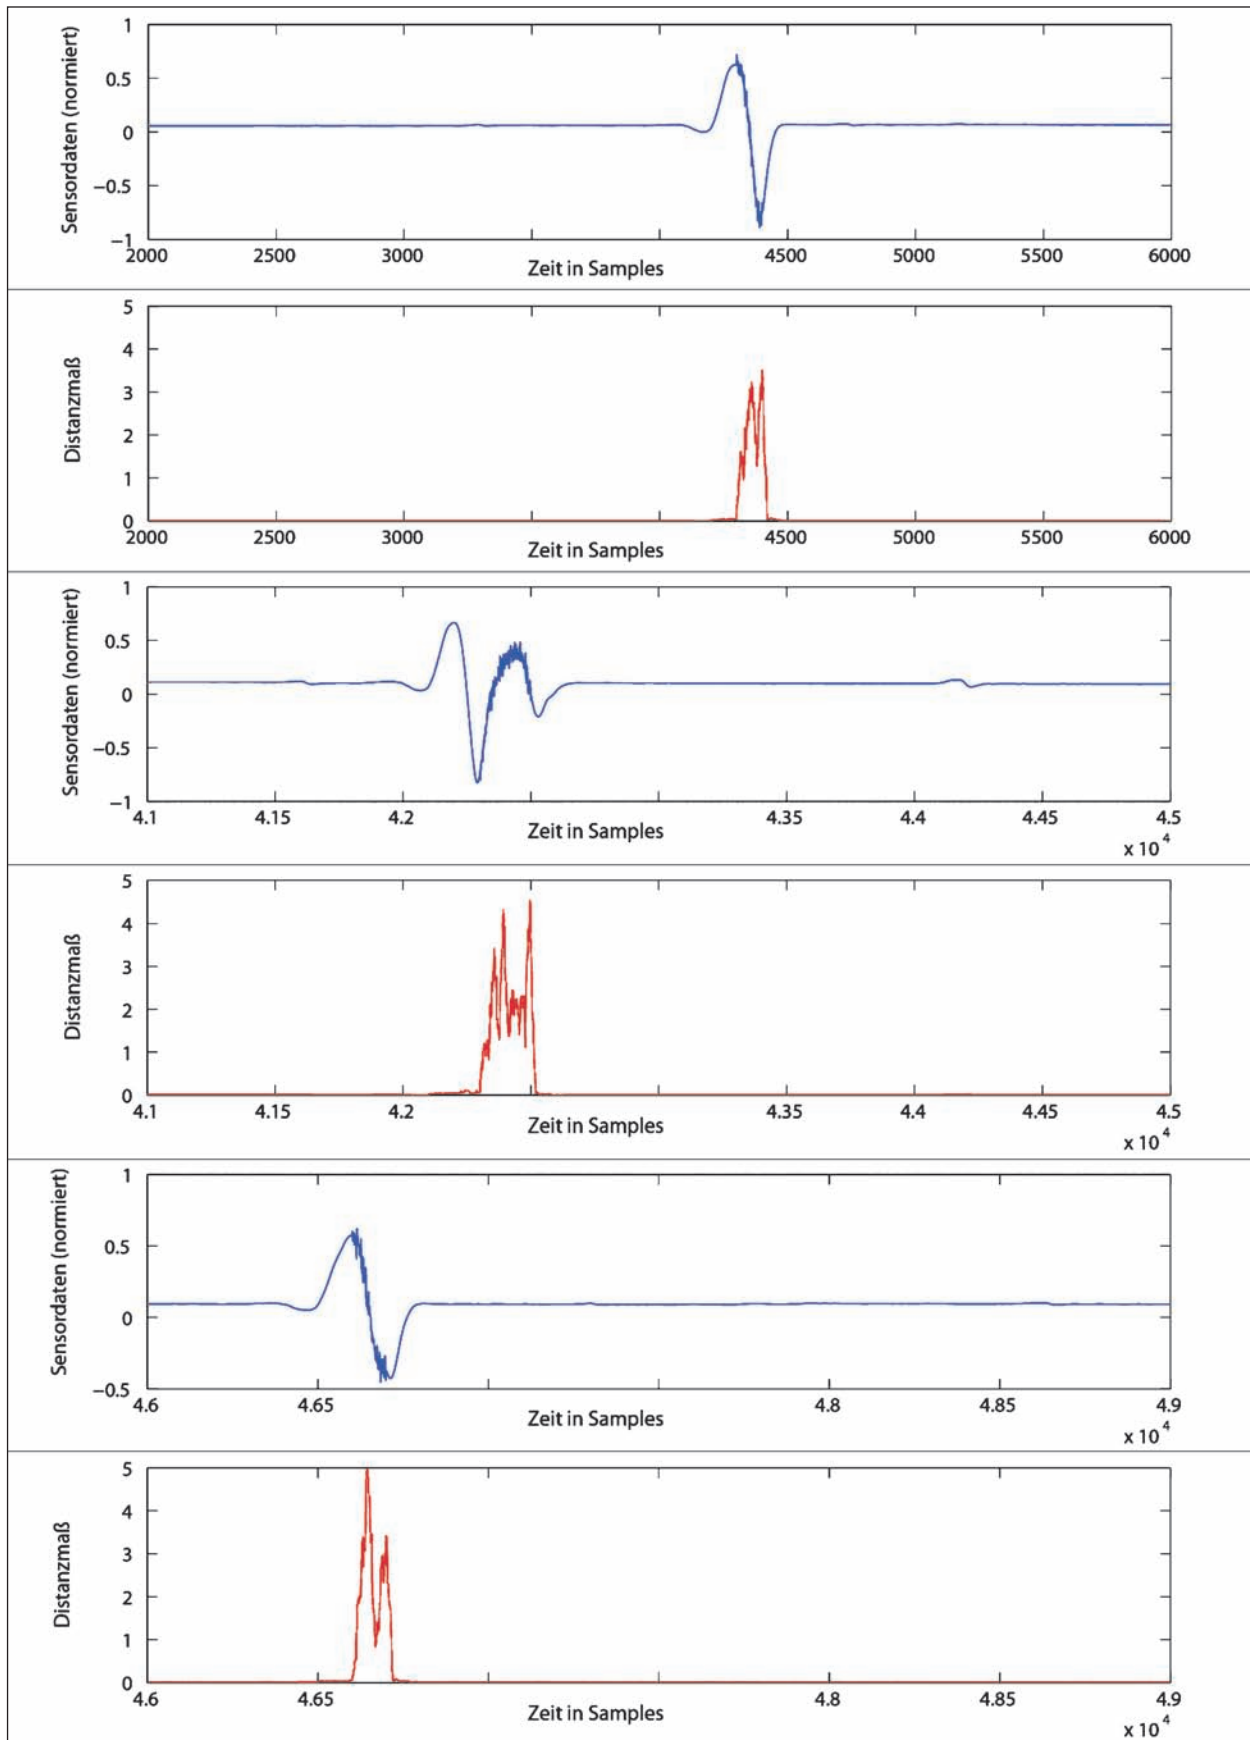
Das gelernte künstliche neuronale Netz besteht aus zwei Schichten mit jeweils 64 Neuronen, welche über Synapsen miteinander verknüpft sind und sich Informationen zusenden können. Die gesamte Berechnungszeit der Lernphase betrug unter Matlab – einer Rapid-Prototyping-Umgebung – auf einem COTS- (Commercial-off-the-shelf-)Rechner (Intel Core i5) für 348.718 Datenpunkte insgesamt

ca. 4 Minuten. Eine optimierte Implementierung des Algorithmus unter einer anderen Programmiersprache (wie z. B. C++ oder Java) würde erfahrungsgemäß zu einer Erhöhung der Berechnungsgeschwindigkeit um Faktor 100 bis 1.000 führen. Eine grobe Verbrauchsschätzung wird in Tabelle 11 gegeben.

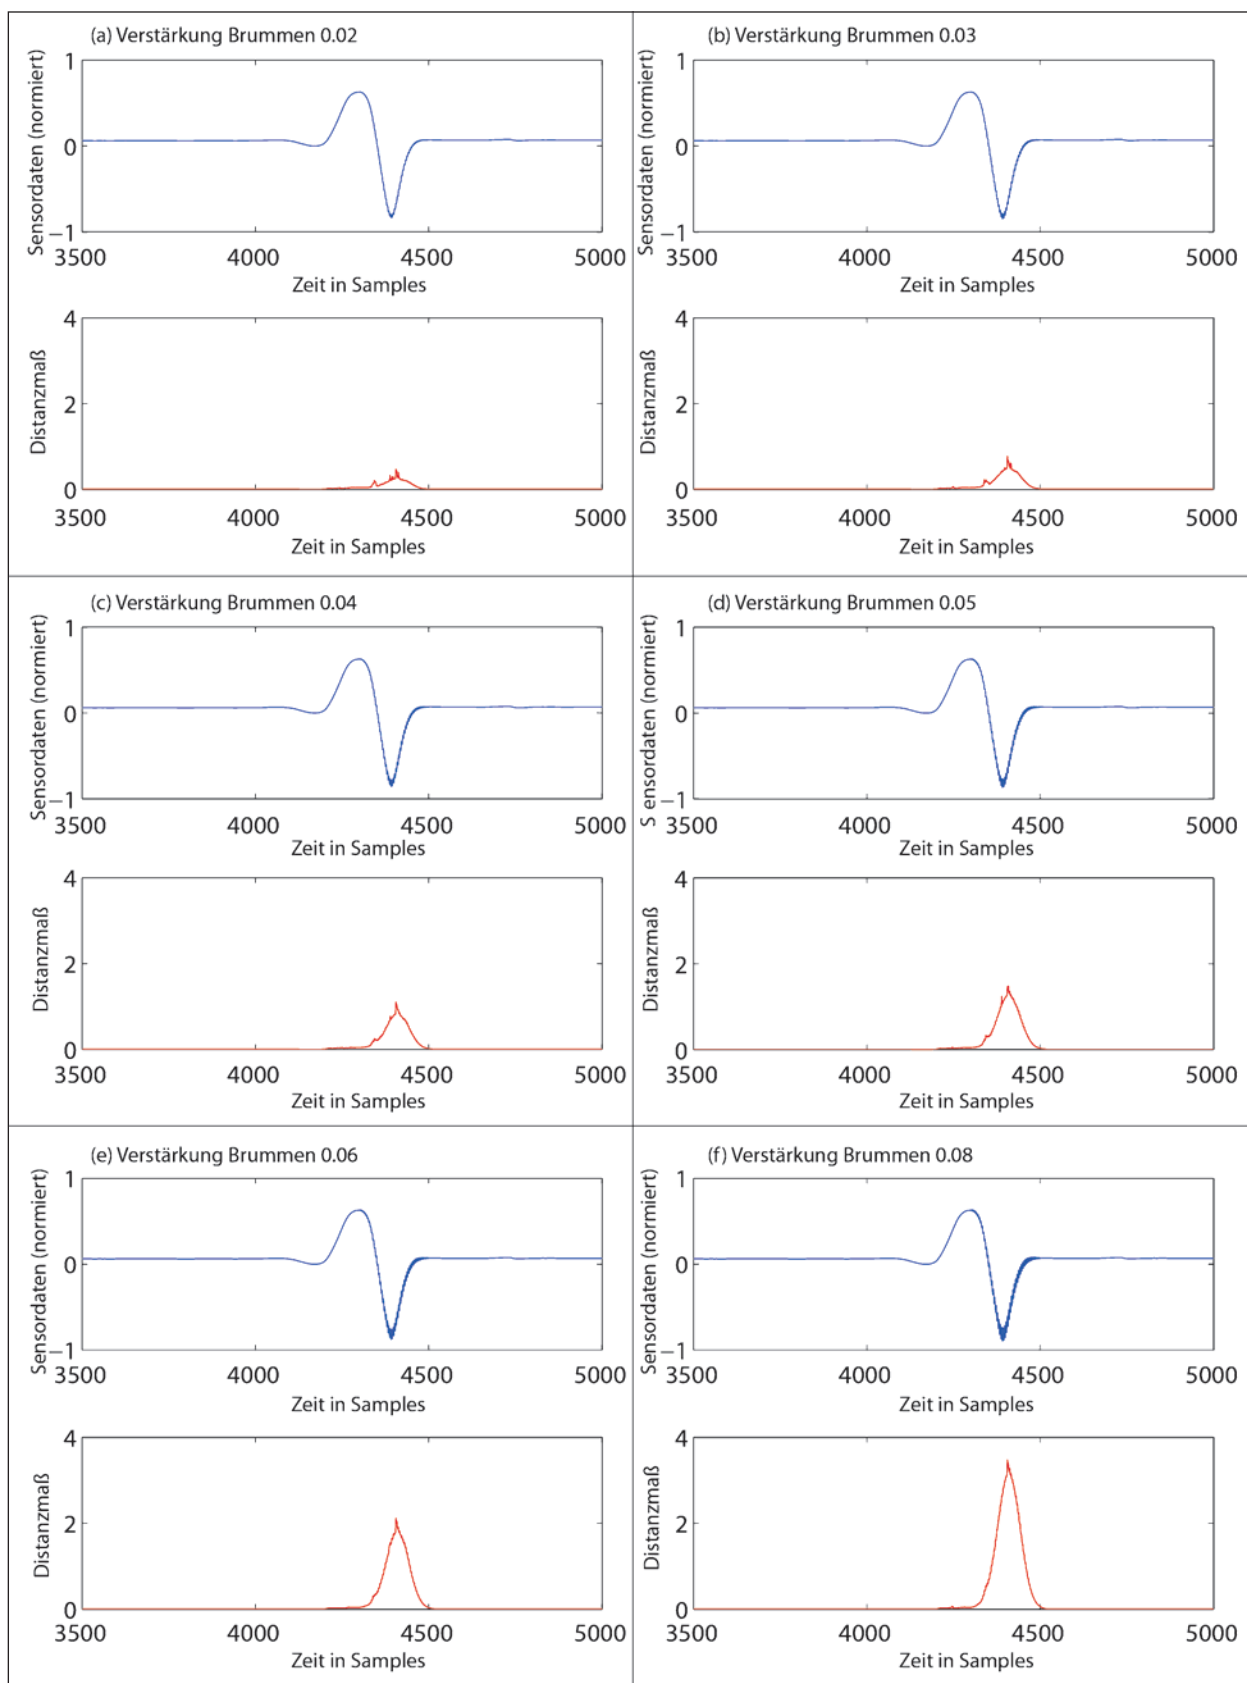
### Plausibilisierung

Nach der Lernphase wurde in einem Testdatensatz an zufällig verteilten Stellen ein Rauschsignal auf die Messdaten addiert. In Bild 45 ist das Ergebnis der Überprüfung der Wegaufnahmevideos dargestellt. Es ist deutlich zu erkennen, dass alle Implausibilitäten in Form von erhöhtem Sensorrauschen zuverlässig, robust erkannt wurden. In einem realen Szenario könnten die Messwerte an diesen Stellen von der weiteren Verarbeitung ausgeschlossen werden, um falsche Ergebnisse basierend auf implausiblen Messdaten zu verhindern. Weiterhin könnten bestimmte Meldungen an ein übergeordnetes Fernüberwachungssystem weiter geleitet werden.


Als ein zweites, in der Praxis häufig zu findendes Störsignal wurde ein Brummburst (50 Hz) mit



**Bild 45:** Künstliche neuronale Netze: Ergebnis der Plausibilisierung von Wegaufnehmerdaten mit erhöhtem Rauschen. An ausgewählten Stellen wurde zu den realen Messdaten ein erhöhtes Rauschen hinzugefügt. Es ist deutlich, dass alle Implausibilitäten zuverlässig, robust erkannt wurden (Zeitfenster 40 bzw. 30 Sekunden)



**Bild 46:** Künstliche neuronale Netze: Ergebnis der Plausibilisierung von Wegaufnehmerdaten mit unterlagertem 50-Hz-Brummen. An einer ausgewählten Stelle wurde zu den realen Messdaten ein 50-Hz-Brummen mit verschiedenen Verstärkungen hinzugefügt (Verstärkung von (a) 0.02, (b) 0.03, (c) 0.04, (d) 0.05, (e) 0.06, (f) 0.08). Es ist deutlich, dass alle Implausibilitäten zuverlässig, robust erkannt wurden. Auch ist die hohe Sensitivität deutlich erkennbar, selbst bei einer Verstärkung von 0.02 ist noch ein leichter Anstieg des Distanzmaßes zu erkennen (Zeitfenster 15 Sekunden)



**Bild 47:** Künstliche neuronale Netze: Extraktion von höherwertigen Informationen bzw. Mustern aus den Eingangssignalen. Im oberen Bild ist das Eingangssignal (Wegaufnehmer) dargestellt und im unteren Bild die Antwort der Neuronen (Zeitfenster 40 bzw. 30 Sekunden)

unterschiedlicher Verstärkung ausgewählt. Das mittels einer Gaußfunktion gefensterete Störsignal wurde an einer bestimmten Stelle auf das eigentliche Nutzsignal aufaddiert und das Ergebnis der Plausibilisierung evaluiert. Weiterhin wurde die Verstärkung variiert, um die Sensitivität zu analysieren. In Bild 46 ist das Ergebnis der Überprüfung der Wegaufnehmerdaten dargestellt. Es ist deutlich, dass alle Implausibilitäten zuverlässig, robust erkannt wurden. Auch ist die hohe Sensitivität deutlich erkennbar, selbst bei einer Verstärkung von 0.02 ist noch ein leichter Anstieg des Distanzmaßes zu erkennen. Wenn der Brumburst über eine längere Zeit anhält, würde auch das Distanzmaß auf einem konstant hohen Wert bleiben.

### Extraktion höherwertiger Information

Mittels des gelernten neuronalen Netzes können auch höherwertige Information bzw. Muster extrahiert werden, siehe Kapitel 4.3.4. Dadurch können verschiedene Signalverläufe bzw. Fehlersituationen erkannt werden und weiter analysiert werden. In Bild 47 ist das Ergebnis dargestellt. Im oberen Bild ist das Eingangssignal (Wegaufnehmer) dargestellt und im unteren Bild die Antwort der Neuronen. Die Verläufe in dem roten Kasten wurden jeweils als ähnlich erkannt, d. h., der Verlauf der Neuronen ist ähnlich. Vergleicht man die extrahierten Muster mit den Wegaufnehmerdaten in der ersten Hälfte des roten Kastens mit den der zweiten Hälfte, so wird deutlich, dass diese sich unterscheiden, d. h., verschiedene Signalverläufe führen zu verschiedenen Musterverläufen. Diese Muster können als Basis für eine weitergehende Diagnose bzw. Analyse eines überlagerten Überwachungssystems bzw. des nachgeschalteten FEM-Brückenmodells dienen. Aufgrund unserer Erfahrung reicht die Trennschärfe der extrahierten Muster aus, um mittels eines Klassifikators aus den Mess- und Erfassungsdaten scharfe fachtechnische Aussagen zu extrahieren. Es ist deutlich, dass alle Implausibilitäten zuverlässig, robust erkannt wurden. Auch ist die hohe Sensitivität deutlich erkennbar, selbst bei einer Verstärkung von 0.02 ist noch ein leichter Anstieg des Distanzmaßes zu erkennen.

## 5.4 Dehnmessstreifen (dynamischer Schwingversuch) – Erkennung von Sensordrifts

In diesem Kapitel wird die Plausibilisierung mittels maschineller Lernalgorithmen für Kraft-Wegmessungen erprobt und deren Einsatzfähigkeit evaluiert. Sollen Sensoren bei dem robusten Brückenmonitoring über einen sehr langen Zeitraum zum Einsatz kommen, ist die automatische zuverlässige Erkennung von Sensordrifts notwendig. Insbesondere die rauen Umgebungsbedingungen, die beim Brückenmonitoring auf die Sensoren einwirken, lassen diese schneller altern, was in den meisten Fällen zu einem „Wegdriften“ bestimmter Sensorsignale führt. Für die Erkennung bzw. die Kalibrierung gibt es verschiedene Ansätze. Im Allgemeinen wird das zu überprüfende Sensorsignal mit einem „Normal“ verglichen. Die Ansätze unterscheiden sich eigentlich nur in der Wahl des „Normals“; die folgenden sind grundsätzlich denkbar:

- Andere Sensoren

Es wird die Beziehung (z. B. in Form von Kennlinien) zwischen verschiedenen Signalen (gleiche oder unterschiedliche Messparameter) ausgenutzt, um zu überprüfen, ob diese für bestimmte Signalwerte noch erfüllt sind. Die Beziehung kann entweder in mathematischer Form vorgegeben werden oder basierend auf Lerndaten gelernt werden (siehe Machbarkeitsstudie in diesem Kapitel).

- Andere interne Größen im Sensor

Es wird die Beziehung (z. B. in Form von Kennlinien) zwischen internen Größen, die nur innerhalb des Sensors zu Verfügung stehend ausgenutzt, z. B. Spannung, Stromstärke, um zu überprüfen ob diese für bestimmte Signalwerte noch erfüllt sind. Die Beziehung kann entweder in mathematischer Form vorgegeben werden oder basierend auf Lerndaten gelernt werden (siehe Machbarkeitsstudie in diesem Kapitel).

- Präzise Modellierung

Es wird das Verhalten des Sensorsignals unter verschiedenen Bedingungen (Umweltbedingungen) präzise modelliert, um zu überprüfen ob diese für bestimmte Signalwerte noch erfüllt sind. Diese Herangehensweise stellt die aufwändigste dar, da in einem ersten Schritt eine präzise Modellierung notwendig ist.



In diesem Kapitel wird die Machbarkeit einer Sensordrifterkennung mittels eines künstlichen neuronalen Netzes überprüft. Wie in dieser Forschungsarbeit schon an mehreren Stellen gezeigt wurde, ist die besondere Eigenschaft der künstlichen neuronalen Netze ihre selbstständige Lernfähigkeit. Die Aufgabe des in diesem Anwendungsszenario gelernten neuronalen Netzes besteht darin, die Beziehung zwischen verschiedenen Sensoren zu lernen und basierend auf diesem erlernten mathematischen Modell Sensordrifts zu erkennen.

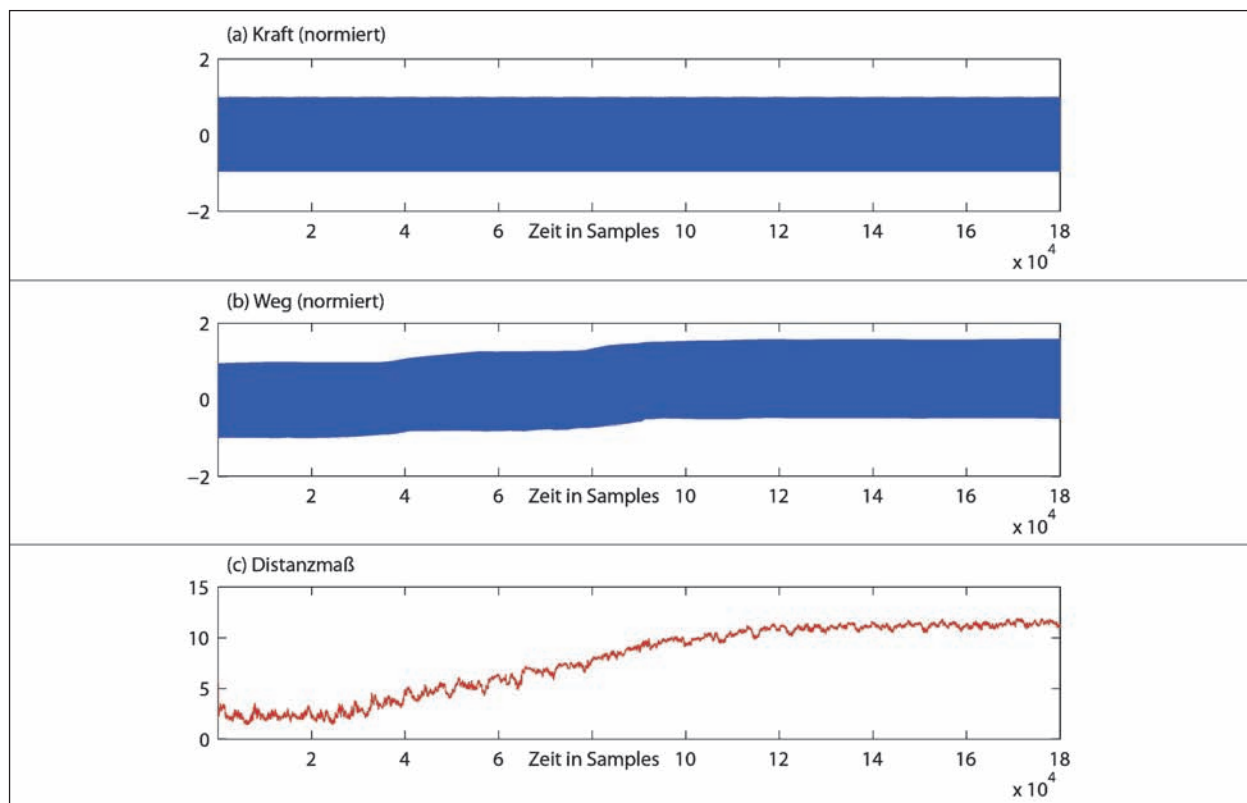
### Rahmenbedingung

Das gelernte künstliche neuronale Netz besteht aus zwei Schichten mit jeweils 64 Neuronen, welche über Synapsen miteinander verknüpft sind und sich Informationen zusenden können. Die gesamte Berechnungszeit der Lernphase betrug unter Matlab – einer Rapid-Prototyping-Umgebung – auf einen COTS- (Commercial-off-the-shelf-)Rechner (Intel Core i5) für 25.000 Datenpunkte insgesamt ca. 1 Minute. Eine optimierte Implementierung des Algorithmus unter einer anderen Programmiersprache (wie z. B. C++ oder Java) würde erfahrungsgemäß zu einer

Erhöhung der Berechnungsgeschwindigkeit um den Faktor 100 bis 1.000 führen.

### Sensordrifterkennung

In Bild 48 ist das Ergebnis der Überprüfung der Sensordrifterkennung mittels des gelernten künstlichen neuronalen Netzes dargestellt. Es handelt sich um einen dynamischen Schwingversuch, bei dem ein Objekt in Schwingung versetzt wird; es wird mittels Dehnmessstreifen der Weg gemessen und die einwirkenden Kräfte mittels einer Kraftmessdose. Deutlich ist zu erkennen, dass, sobald die Beziehung zwischen der Kraft und dem resultierenden Weg nicht mehr dem „Normalzustand“, d. h. dem gelernten Verhalten entspricht, steigt das vom künstlichen neuronalen Netz bestimmte Distanzmaß an. Ein Benutzer muss im Vorfeld einen Schwellwert bestimmen, ab welchem das Verhalten noch als „normal“ angesehen werden kann und ab welchem eine Implausibilität bzw. in diesem Anwendungsszenario eine Sensordrift vorherrscht. An dieser Stelle muss erwähnt werden, dass dieser Ansatz nicht in der Lage ist, die Ursache des Sensordrifts zu bestimmen; d. h., er kann nicht bestimmen, ob diese durch Sensor-



**Bild 48:** Künstliche neuronale Netze: Erkennung von Sensordrifts am Beispiel eines Schwingversuchs, Messsignal ist Kraft und Weg (bestimmt durch ein DMS). Deutlich ist zu erkennen, dass statistische Analyseverfahren prinzipiell in der Lage sind, Signaldrifts (entweder verursacht durch fehlerhafte Sensoren oder Bauwerke) zu erkennen (Zeitfenster 25 Minuten)

oder Bauwerksdefekte hervorgerufen wird (in diesem Anwendungsszenario hat es sich um Bauwerksdefekte gehandelt, Sensordefekte würden sich allerdings ähnlich verhalten). Statistische Analyseverfahren sind also prinzipiell in der Lage, Signaldrifts (entweder verursacht durch fehlerhafte Sensoren oder Bauwerke) zu erkennen.

## 5.5 Verkehrslastdaten

In diesem Kapitel werden die Plausibilisierung und Extraktion höherwertiger Information mittels maschineller Lernalgorithmen für Verkehrslastdaten erprobt und deren Einsatzfähigkeit evaluiert. Von der BASt wurden Messdaten von zwei Dehnungsmessstellen mit zugehörigem Zeitkanal (Abtast-rate 600 Hz) zur Verfügung gestellt.

Basierend auf dem Datensatz wurde ein künstliches neuronales Netz gelernt. Die Aufgabe des in diesem Anwendungsszenario gelernten neuronalen Netzes besteht darin, das Ausgangssignal zu rekonstruieren, Abweichungen vom Normalverhalten zu erkennen und relevante Muster zu extrahieren.

### Rahmenbedingung

Das gelernte künstliche neuronale Netz besteht aus zwei Schichten mit jeweils 64 Neuronen, welche über Synapsen miteinander verknüpft sind und sich Informationen zusenden können. Die gesamte Berechnungszeit der Lernphase betrug unter Matlab – einer Rapid-Prototyping-Umgebung – auf einen COTS- (Commercial-off-the-shelf-)Rechner (Intel Core i5) für 108.022 Datenpunkte insgesamt ca. 2 Minuten. Eine optimierte Implementierung des Algorithmus unter einer anderen Programmiersprache (wie z. B. C++ oder Java) würde erfahrungsgemäß zu einer Erhöhung der Berechnungsgeschwindigkeit um den Faktor 100 bis 1.000 führen.

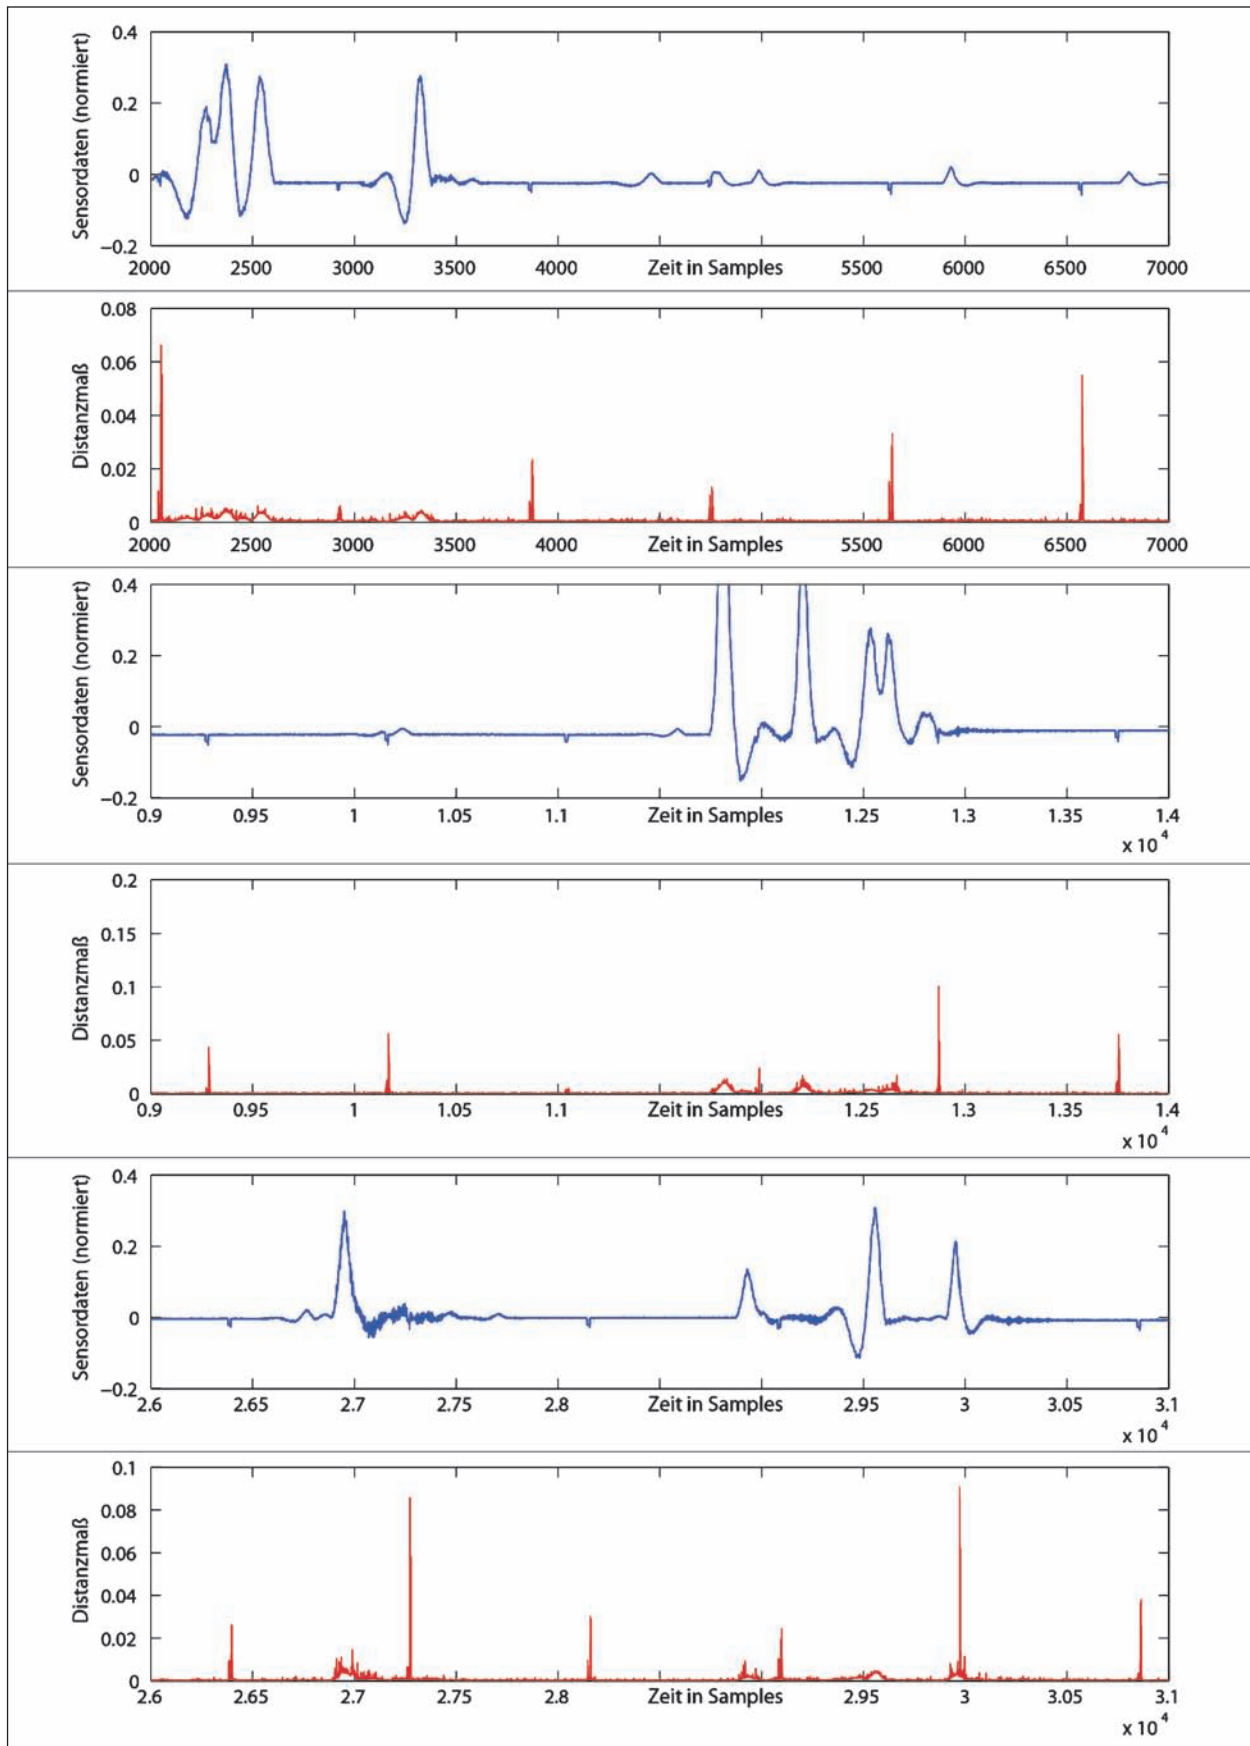
### Plausibilisierung

In dem Testdatensatz befinden sich in regelmäßigen Abständen kleine Plateaus, welche nicht zum eigentlichen Messsignal gehören. Nach der Lernphase wurde erprobt, ob diese Implausibilitäten erkannt wurde. In Bild 49 ist das Ergebnis der Überprüfung der Verkehrslastdaten mittels des gelernten künstlichen neuronalen Netzes dargestellt. Es ist deutlich zu erkennen, dass alle Implausibili-

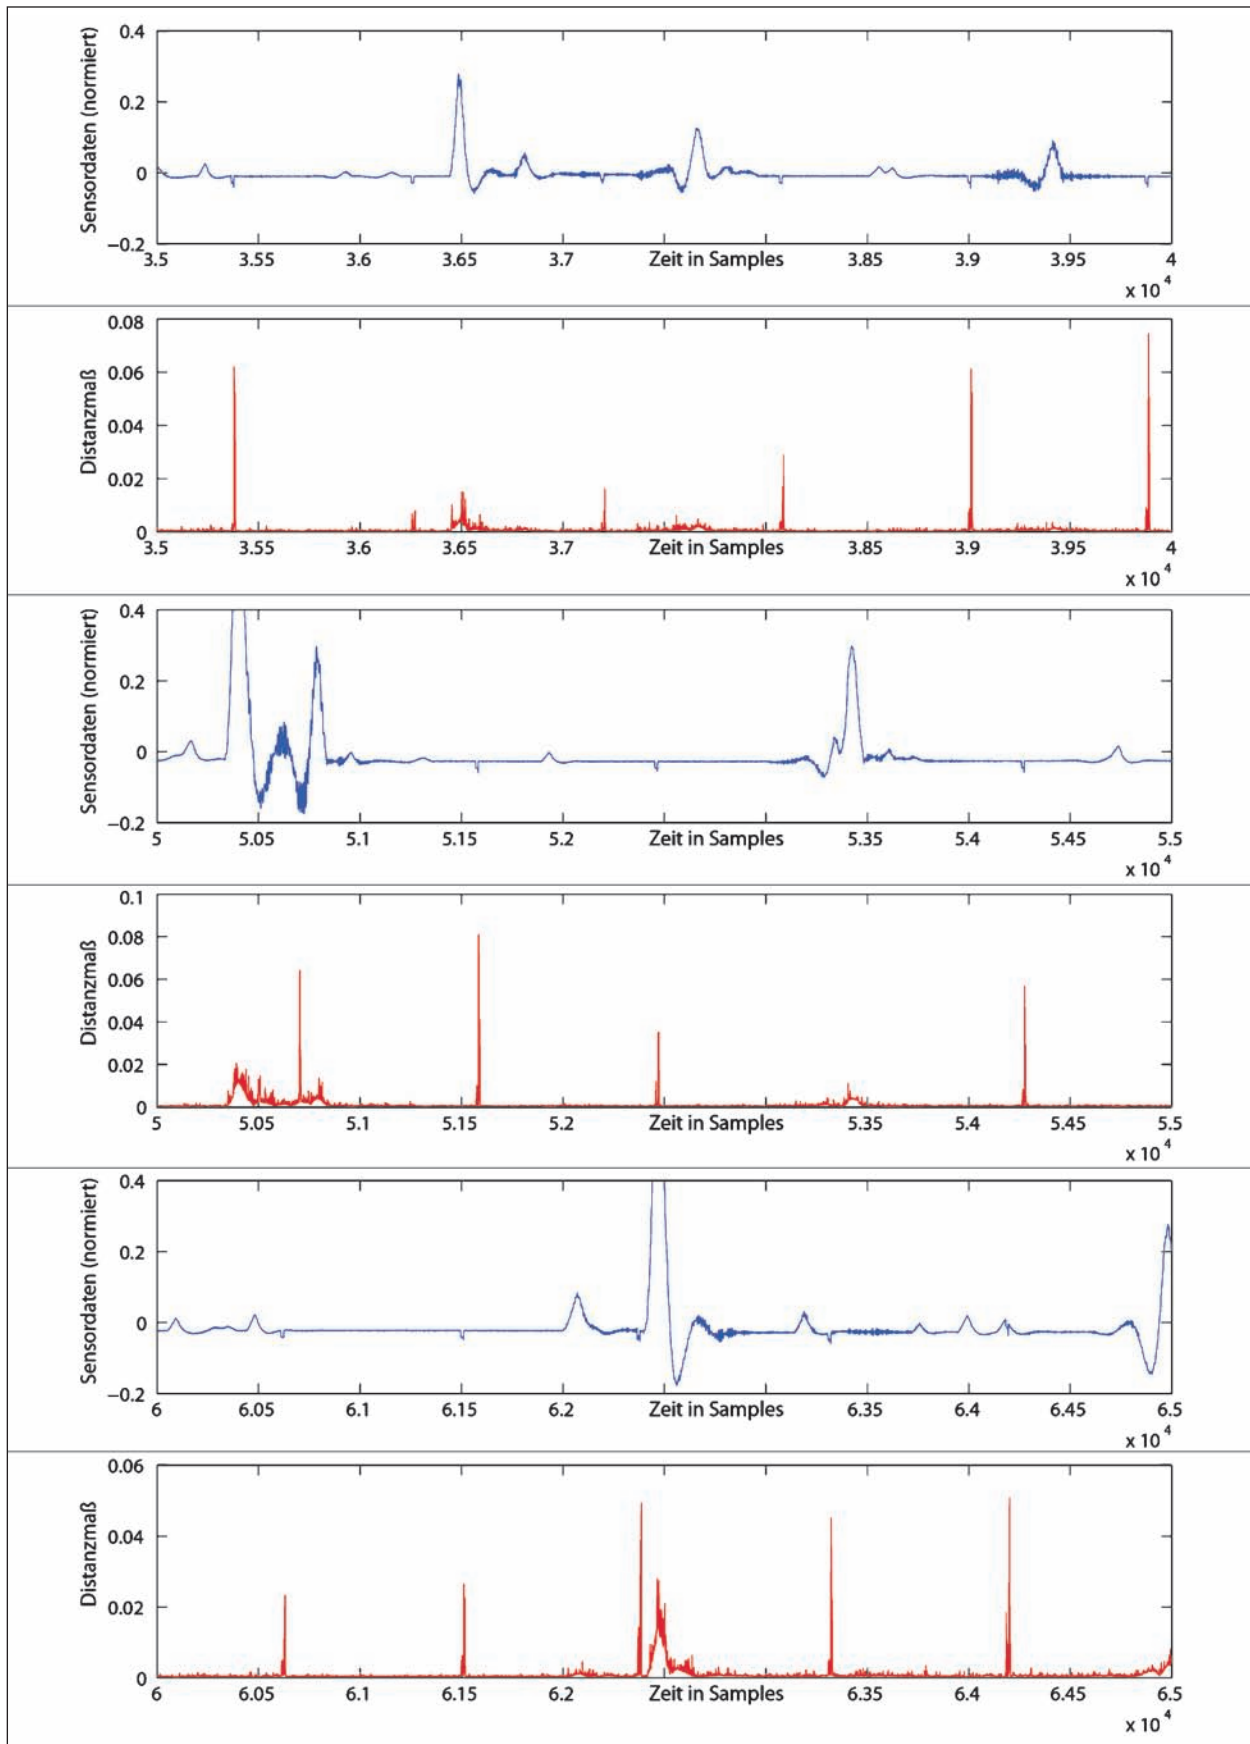
täten zuverlässig, robust erkannt wurden. In einem realen Szenario könnten die Messwerte an diesen Stellen von der weiteren Verarbeitung ausgeschlossen werden, um falsche Ergebnisse basierend auf implausiblen Messdaten zu verhindern. Weiterhin könnten eine bestimmte Meldung und Ergebnisse weiterer Untersuchungen an ein übergeordnetes Fernüberwachungssystem weiter geleitet werden.

### Extraktion höherwertiger Information

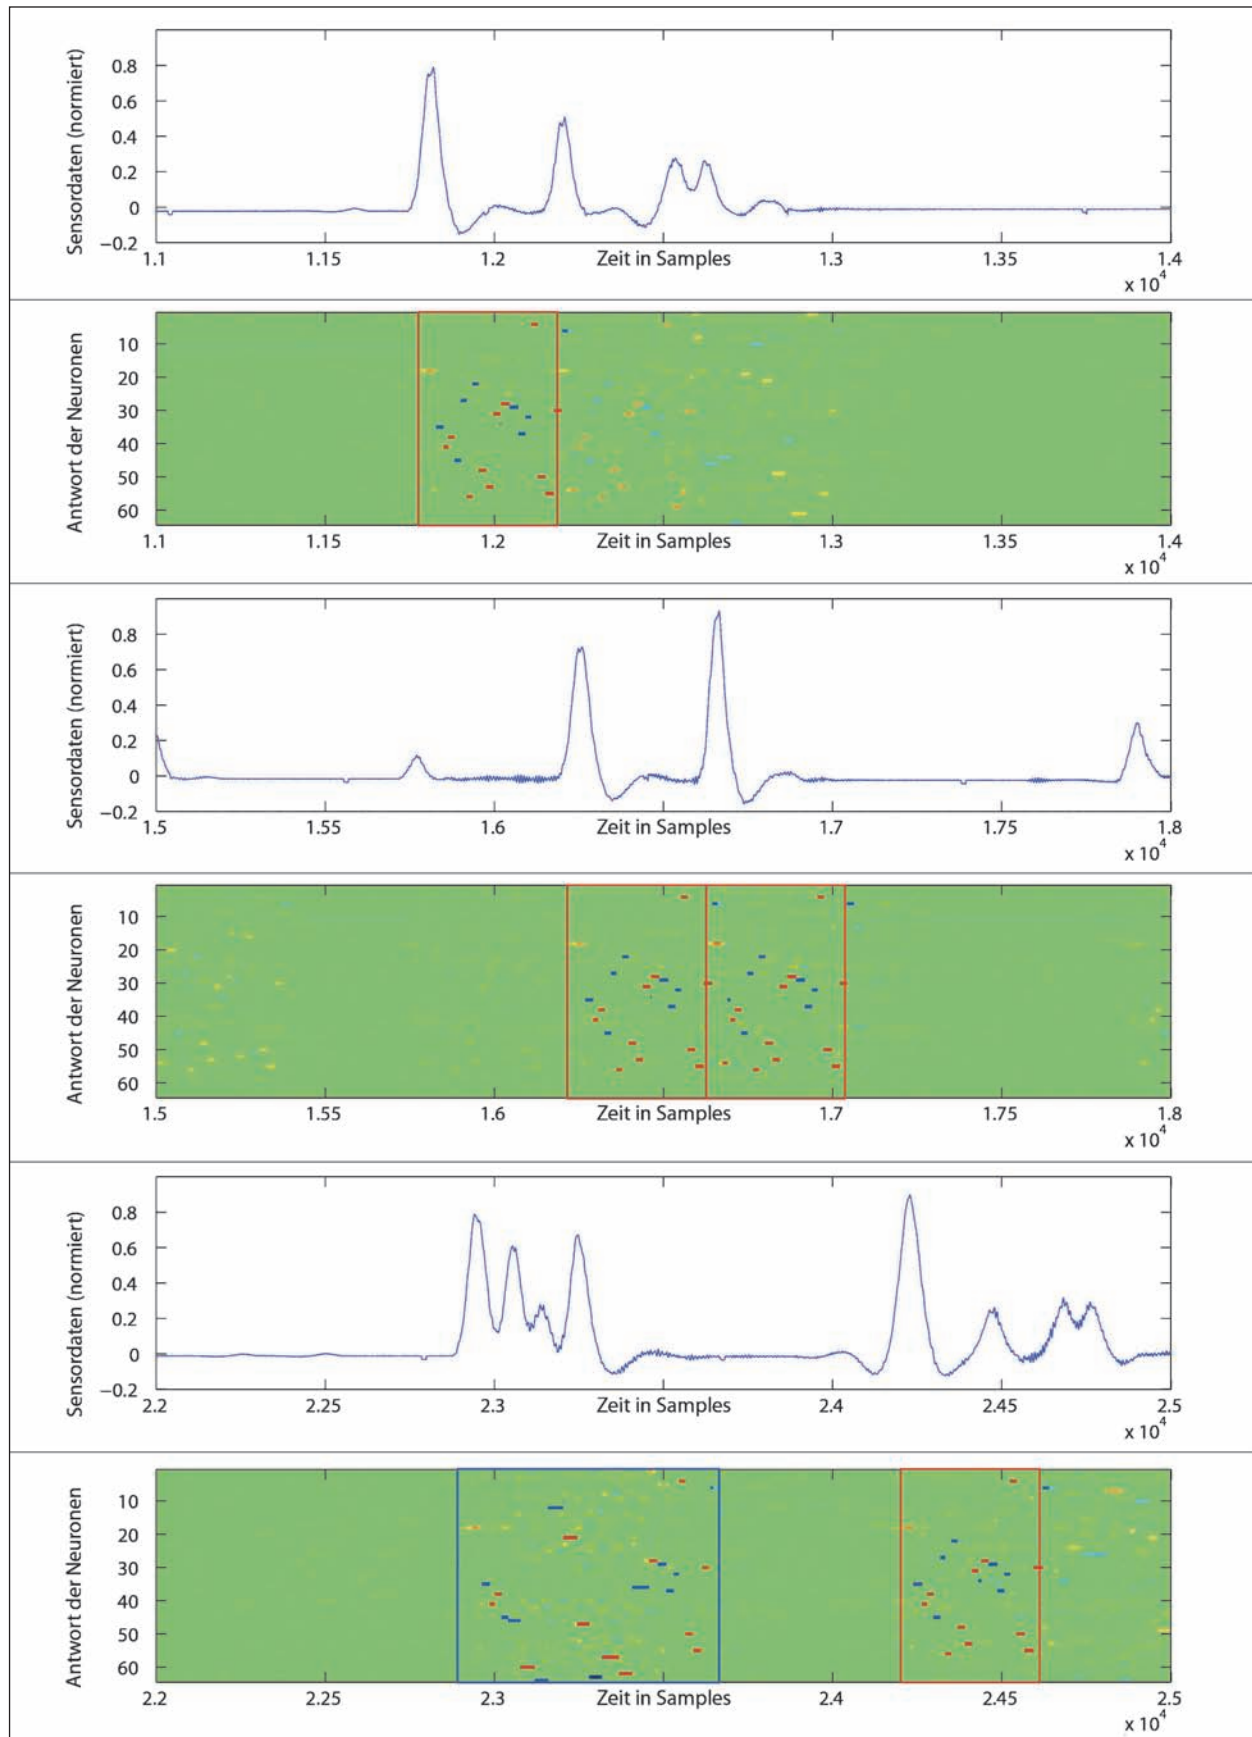
Das gelernte neuronale Netz liefert nicht nur das rekonstruierte Signal und ein Implausibilitätsmaß, sondern es können auch höherwertige Informationen bzw. Muster extrahiert und erkannt werden, siehe Kapitel 4.3.4. Dadurch können verschiedene Signalverläufe bzw. Fehlersituationen erkannt werden und weiter analysiert werden. In Bild 51 und Bild 52 ist die Extraktion von höherwertigen Informationen bzw. Mustern aus den Eingangssignal dargestellt. Im oberen Bild ist das Eingangssignal (Verkehrslastdaten) dargestellt und im unteren Bild die Antwort der Neuronen. Die Verläufe in den roten und blauen Kästen wurden jeweils als ähnlich erkannt, d. h., der Verlauf der Neuronen ist ähnlich. Diese Muster können als Basis für eine weitergehende Diagnose z. B. zur Bestimmung der Achsanzahl oder des Typs des Fahrzeugs dienen. Aufgrund unserer Erfahrung reicht die Trennschärfe der extrahierten Muster aus, um mittels eines Klassifikators aus den Mess- und Erfassungsdaten scharfe fachtechnische Aussagen zu extrahieren.




**Bild 49:** Künstliche neuronale Netze: Ergebnis der Plausibilisierung von Verkehrslastdaten. Es ist deutlich, dass alle Implausibilitäten zuverlässig, robust erkannt wurden (Zeitfenster ca. 8 Sekunden)



**Bild 50:** Künstliche neuronale Netze: Ergebnis der Plausibilisierung von Verkehrslastdaten. Es ist deutlich, dass alle Implausibilitäten zuverlässig, robust erkannt wurden (Zeitfenster ca. 8 Sekunden)



**Bild 51:** Künstliche neuronale Netze: Extraktion von höherwertigen Informationen bzw. Mustern aus dem Eingangssignal. Im oberen Bild ist das Eingangssignal (Verkehrslastdaten) dargestellt und im unteren Bild die Antwort der Neuronen (Zeitfenster 5 Sekunden)



**Bild 52:** Künstliche neuronale Netze: Extraktion von höherwertigen Informationen bzw. Mustern aus dem Eingangssignal. Im oberen Bild ist das Eingangssignal (Verkehrslastdaten) dargestellt und im unteren Bild die Antwort der Neuronen (Zeitfenster 5 Sekunden)

## 6 Aspekte der praktischen Umsetzung und Implementierung

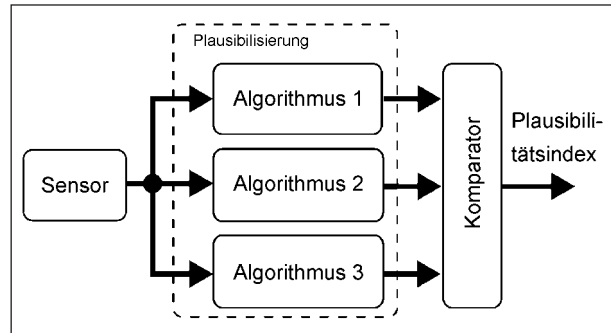
### 6.1 Redundanz zur Erhöhung der Zuverlässigkeit der Datenplausibilisierung

Zur Erhöhung der Zuverlässigkeit und Aussagekraft der Messdaten sind sowohl die Algorithmen als auch die Verarbeitungseinheit redundant auszugestalten, insbesondere bei einer Echtzeitanwendung. Prinzipiell wird in der Datenverarbeitung zwischen Hardware-, Software-, Informations- und Zeitredundanz unterschieden (66). Diese Konzepte lassen sich je nach Anwendungsfall und Anforderungen an die Ausfallsicherheit der Datenplausibilisierung kombinieren.

#### 6.1.1 Hardwareredundanz

Bei der Hardwareredundanz werden (Hardware-) Teilsysteme mehrfach ausgelegt. Im Fall der Datenplausibilisierung beim Brückenmonitoring können Sensoren, die Kommunikationskanäle oder auch die Verarbeitungseinheit mehrfach vorhanden sein. Der Ausfall einer Einzelkomponente beeinträchtigt die Funktionalität des Gesamtsystems in diesem Fall nicht, da die jeweils andere Komponente die Aufgabe des Teilsystems übernimmt. Mit einer redundanten Auslegung der Sensoren ist hier gemeint, dass zwei Sensoren am selben Ort eine gemeinsame Größe messen – der Fall von mehreren verteilten Sensoren ist im Kapitel 6.1.3 aufgeführt.

Der für die Datenplausibilisierung wichtigste Fall der Hardwareredundanz ist die mehrfache Auslegung der Recheneinheiten. Hierbei stehen mindestens zwei Recheneinheiten für die Verarbeitung zur Verfügung. Der Einsatz von zwei Recheneinheiten erlaubt eine gegenseitige Überwachung der Recheneinheiten und eine Überprüfung des berechneten Ergebnisses. Bei einem abweichenden Ergebnis kann somit ein Fehler erkannt werden. Auch Fehler, die zu Abstürzen der Algorithmen führen, können durch eine gegenseitige Überwachung erkannt werden. In diesem Fall übernimmt die jeweils noch funktionierende Recheneinheit die Verarbeitung. Dieser Vorgang nennt sich „Failover“ und wird in Hot-Standby-Systemen eingesetzt. Bei mehr als zwei Rechenknoten ist es zusätzlich unter bestimmten Voraussetzungen möglich, einen erkannt-



**Bild 53:** Erhöhung der Datenplausibilität durch dreifache Softwareredundanz


ten Fehler zu korrigieren. Oft wird bei einem Vergleich ab dreifacher Redundanz der Ergebnisse ein Mehrheitsentscheid durchgeführt, welcher das häufigste Ergebnis als das richtige auswählt.

#### 6.1.2 Softwareredundanz


Softwareredundanz soll Programmfehler durch den Einsatz mehrerer Algorithmen erkennen und gegebenenfalls korrigieren. Hierbei wird eine bestimmte Aufgabe, wie die Datenplausibilisierung, mit verschiedenen Algorithmen verarbeitet. Die Algorithmen können auf grundlegend unterschiedlichen Ansätzen beruhen, wie zum Beispiel ein Algorithmus mittels Wertebereichs- und Trendüberwachung und ein zweiter komplexer Algorithmus, der die Plausibilisierung mittels modellbasierter Zustandsschätzer durchführt. Aber auch gleiche Ansätze können durch unterschiedliche Implementierungen desselben Algorithmus durch verschiedene Entwickler redundant ausgelegt werden, siehe Bild 53.

#### 6.1.3 Informationsredundanz

Als Informationsredundanz wird im informationstechnischen Sinn die Redundanz übertragener Daten in einem unsicheren Kommunikationskanal bezeichnet. Im Bereich des Bauwerksmonitoring, können verschiedene Arten von Störungen innerhalb der Verarbeitungskette vom Sensor hin zu einer zentralen Auswerteeinheit auftreten. Beispielsweise können drahtlose Datenübertragungslösungen anfällig für externe Störeinflüsse sein, aber auch fehlerhafte oder gealterte Verkabelung von Sensoren kann oft zu Störungen und Sensorausfällen führen. Um diese Kommunikation robust zu gestalten, gibt es eine Vielzahl von Fehlerkorrekturverfahren, die in fast allen Anwendungen und Datenübertragungsprotokollen Einsatz finden. Zur Übersicht sei hier nur auf (67) verwiesen, siehe Bild 54.



**Bild 54:** Erhöhung der Datenplausibilität durch Informationsredundanz, d. h. Nutzung von mehreren Informationsquellen (hier Mess- und Prüfdaten und mathematische Modelle)



**Bild 55:** Erhöhung der Datenplausibilität durch Zeitredundanz. In diesem Beispiel werden fünf Messwerte gemittelt und somit Ausreißer entfernt und auf Plausibilität hin überprüft

Eine weitere Form der Informationsredundanz wird durch eine Vielzahl der in diesem Bericht beschriebenen Algorithmen durch die Verwendung mehrerer Messwerte erreicht. Prinzipiell liegen zwei Informationsquellen vor, die empfangenen Messwerte und das mathematische Modell zur Beschreibung des unterlagerten physikalischen Prozesses, siehe Kapitel 3.2. Dadurch ist zu jeder Zeit ein Vergleich der Mess- und Prüfdaten mit der vom Modell erwarteten Größe möglich. Die Plausibilisierung eines Messwerts ergibt sich hiermit durch einen Modellvergleich.

#### 6.1.4 Zeitredundanz

Ähnlich wie die Informationsredundanz wird bei der Zeitredundanz das dynamische Verhalten des Bauwerks und dadurch der Messwerte berücksichtigt. So kann Modellwissen, wie zum Beispiel das Temperaturverhalten, über den Tag genutzt werden, um unpassende Messwerte, also nicht plausible Daten, zu erkennen. Dieses Modellwissen kann zum Beispiel in einem modellbasierten Zustandschätzer zur Plausibilisierung verwendet werden, indem gezielt die Zeitredundanz ausgenutzt wird, siehe Bild 55).

Ein einfaches Beispiel ist die Messung einer bestimmten physikalischen Größe über einen gewissen Zeitraum. Bei statischen bzw. quasi-statischen

Systemen können die in diesem Zeitfenster aufgenommenen Messwerte so gemittelt werden und dadurch ein einzelner plausibilisierter Messwert berechnet werden. Im einfachsten Fall können durch einen Mittelwertfilter oder Medianfilter somit Ausreißer entfernt werden und auch eine Reduktion der Datenmenge erreicht werden.

## 6.2 Energieverbrauchsschätzung modellbasierter und statistischer Analyseverfahren

In diesem Kapitel soll für die vorgestellten modellbasierten und statistischen Analyseverfahren eine grobe Aufwands- und Energieverbrauchsschätzung gegeben werden. Die Angabe für alle Algorithmen und für alle möglichen Einsatzfelder übersteigt den Rahmen dieses Projekts. Deshalb sollen diese Angaben nur exemplarisch an dem ausgewählten Beispiel der Multiring-Elektrode gegeben werden. Diese Aufwands- und Energieverbrauchsschätzung gibt nur einen groben Anhaltspunkt für die tatsächliche Laufzeit und Verbräuche der Algorithmen. Operationen wie Vergleiche, Zuweisungen, Sprünge und Speicherzugriffe sind zunächst nicht berücksichtigt. Für diese Operationen wird ein Overhead von 100 % angenommen. Die Schätzungen basieren auf der von der BASt zur Verfügung gestellten Modellinstrumentierung, siehe Bild 16.

Für die Berechnung der Energieverbräuche wird beispielhaft der Mikrocontroller TMS320F2806x von Texas Instruments mit integrierter FPU (Floating Point Unit) angenommen. Die folgenden Dokumente wurden für die Berechnung zugrunde gelegt:

- TMS320F2806x (Piccolo) MCUs SPRS698D, Seite 72, Dezember 2012,
- TMS320x2806x Piccolo Technical Reference Manual SPRUH18D, Kapitel 9.6.3, Februar 2013.

Der Mikrocontroller TM320F2806x verbraucht  $225 \text{ mW}$  bei einer Taktrate von  $10 \text{ MHz}$  und  $861 \text{ mW}$  bei einer Taktrate von  $90 \text{ MHz}$ . Somit ergibt sich eine Spanne von  $22.5 \text{ nJ/Takt}$  bis  $86.1 \text{ nJ/Takt}$  (Nanojoule pro Takt). Eine Rechenoperation (Addition, Subtraktion, Multiplikation) benötigt einen Taktzyklus. Damit ergeben sich die in Tabelle 10 und Tabelle 11 angegebenen Energieverbräuche pro Berechnungsschritt bzw. Zeitschritt. Diese Verbräuche gelten lediglich für den



Systemmodell	Messmodell	Zustands-schätzer	Operationen (FLOP)	Anzahl Taktzyklen Overhead	Energieverbrauch in mJ (Millijoule)
P-Modell	Direkte Messung	Kalman-Filter	20	40	0.90-3.44
PV-Modell	Direkte Messung	Kalman-Filter	50	100	2.25-8.61
PVA-Modell	Direkte Messung	Kalman-Filter	200	400	9.00-34.44
Multiple Modelle (P, PV)	Direkte Messung	IMM	150	300	6.75-25.83
PV-Modell	Multiring-Elektrode (Temperatur, Feuchte)	Unscented Kalman-Filter	550	1.100	24.75-94.71
Separierung (Tag-/Nacht-schwankungen)	Multiring-Elektrode (Temperatur, Feuchte, Tag-Nachtschwankung)	Unscented Kalman-Filter	1.400	2.800	63-241.08

Tab. 10: Aufwands- und Energieverbrauchsschätzung verschiedener Algorithmen zur Zustandsschätzung

	Operationen (FLOP)	Anzahl Taktzyklen Overhead	Energieverbrauch in mJ (Millijoule)
Principal Component Analysis	ca. 6.400	ca. 12.800	288-1.102
Self-organizing Maps (SOM)	ca. 9.000	ca. 18.000	405-1.549
Künstliche neuronale Netze (Lernphase), 32 Neuronen, Beobachtungsfenster von 20 Samples	ca. 80.000	ca. 160.000	3600-13.776
Künstliche neuronale Netze (Evaluierungsphase), 32 Neuronen, Beobachtungsfenster von 20 Samples	ca. 6.400	ca. 12.800	288-1.102

Tab. 11: Aufwands- und Energieverbrauchsschätzung verschiedener Algorithmen zur statistischen Analyse, (a) Principal Component Analysis, (b) Self-organizing Maps, (c) künstliche neuronale Netze mit 32 Neuronen, Beobachtungsfenster von 20 Samples (ähnliche Konfiguration wie in den Machbarkeitsstudien in dieser Forschungsarbeit)

Berechnungsalgorithmus, nicht berücksichtigt sind die Aufnahme, Speicherung und Kommunikation der Sensordaten.

Im Gegensatz zu den modellbasierten Analyseverfahren ist eine allgemeingültige Aufwands- und Energieverbrauchsschätzung von statistischen Analyseverfahren nur sehr schwer möglich. Diese hängt sehr stark von vielen Faktoren ab, wie beispielsweise der eigentlichen Anwendung bzw. von der Charakteristik der Mess- und Erfassungsdaten, der genauen Implementierung, der Größe des Beobachtungsfensters, der Komplexität (bei künstlichen neuronalen Netzen ist dies die Anzahl der Neuronen) und so weiter. Trotzdem soll der Versuch gemacht werden zumindest für die statistischen Analyseverfahren, die in der Machbarkeitsstudie dieser Forschungsarbeit berücksichtigt wurden, eine grobe Aufwands- und Energieverbrauchsschätzung zu geben, siehe Tabelle 11. Im Allgemeinen sind für die statistischen im Vergleich zu den modellbasierten Analyseverfahren mehr Rechenoperationen notwendig und somit auch ein höherer Energieverbrauch. Bei dem künstlichen neuronalen Netz ergibt sich für die Lernphase ein deutlich höherer Energieverbrauch als in der Evaluierungs-

phase (bis zu Faktor 10). Dies bedeutet für die praktische Umsetzung, dass die Lernphase nicht lokal vor Ort im Sensorknoten (also auf dem Mikrocontroller) durchgeführt werden kann; hierfür reicht die Rechenpower nicht aus. Die Evaluierungsphase könnte jedoch auf einem Mikrocontroller durchgeführt werden.

### 6.3 Sensorbusse aus der industriellen Messtechnik

Sensorbusse (oder auch Feldbusse genannt) dienen zur Vernetzung von Messfühlern (Sensoren), Stellgliedern (Aktoren) und Steuerungen zwecks Kommunikation. Hierbei werden die Kommunikationsteilnehmer nicht wie bei der analogen Signalübertragung über eine Vielzahl von Einzelleitungen, sondern über ein gemeinsames Buskabel miteinander verbunden. Um eine Kollision der Daten auf der Busleitung zu vermeiden, muss festgelegt sein, wer (Kennung) was (Messwert, Befehl) wann (Initiative) auf den Bus sendet. Alle an einen Feldbus angeschlossenen Geräte können zwar jederzeit Daten empfangen, jedoch darf zu einem gegebenen Zeitpunkt immer nur einer der Kommunikationsteilnehmer

mer Daten senden. Hierfür gibt es normierte Protokolle. Das Buszuteilungsverfahren, das für den betreffenden Feldbus definiert ist, beschreibt, welcher Teilnehmer wann die Gelegenheit zum Senden erhält. Eine Übersicht über die industrielle Kommunikation mit Feldbussen findet sich in (68).

Die Anforderung an die Kommunikation zwischen den einzelnen Sensoren, Aktoren und Steuerung in den unterschiedlichen Branchen und Anwendungsbereichen haben dazu geführt, dass sich viele unterschiedliche Feldbusse am Markt etabliert haben. Dies betrifft insbesondere allgemeine Anforderungen an die Kommunikation, wie Übertragungsgeschwindigkeit, Sicherheit, Echtzeitfähigkeit. In Deutschland haben sich die CAN – Controller Area Network (69, 70, 71) Busse im Bereich der Fahrzeugtechnik und LON – Local Operation Network (72) in der Gebäudetechnik durchgesetzt, während in der chemischen und verfahrenstechnischen Industrie vorwiegend der PROFIBUS (73, 74) und der Foundation Fieldbus zum Einsatz kommen. CAN und PROFIBUS können für die Datenübertragung zum Beispiel RS-485 verwenden (75), was bei Feldbussen gebräuchlich ist. Zunehmend werden Echtzeit-Ethernet- bzw. Industrial-Ethernet-Lösungen anstelle klassischer Feldbusse verwendet. Eine detaillierte Beschreibung bestehender Standards ist unter anderem in (76, 77, 78) zu finden.

Mit der raschen Entwicklung des Internets wird die Frage der Interoperabilität von Feldbussystemen aus einer völlig neuen Richtung angegangen. Es wird zunehmend wichtiger, dass die Technik, sprich das Feldbussystem, in der Lage ist, sich in flexibler Weise an die jeweiligen Gegebenheiten des Anwenders anzupassen. Die Verwirklichung dieser Idee erfolgt mithilfe spezieller Netzwerkprotokolle, so wie zum Beispiel SOAP (ursprünglich Simple Object Access Protokoll). Dieses kann zum Austausch von Daten zwischen Kommunikationsteilnehmern in einer dezentralen, verteilten Umgebung benutzt werden. Bei SOAP handelt es sich eigentlich um ein zustandsloses One-way-Paradigma zum Nachrichtenaustausch. Komplexere Interaktionsformen, wie zum Beispiel request-response oder request-multiple-responses, können durch eine Kombination der einfachen Nachrichten mit protokollspezifischen Eigenheiten bzw. Anwendungslogik erreicht werden (78). SOAP stützt sich auf XML zur Repräsentation der Daten und auf Internet-Protokolle der Transport- und Anwendungsschicht zur Übertragung der Nachrichten. Die ge-

bräuchlichste Kombination ist SOAP über http und TCP (79). SOAP regelt, wie Daten in der Nachricht abzubilden und zu interpretieren sind, und gibt eine Konvention für entfernte Prozeduraufrufe mittels SOAP-Nachrichten vor. Die Flexibilität des Konzeptes wird durch Nachteile in Übertragungsvolumen und Rechenaufwand erkauft. Das XML-Dokument muss beim Sender zunächst aufgebaut und anschließend validiert werden (79, 78, 80).

## 7 Zusammenfassung und Ausblick

### 7.1 Modellbasierte Analyseverfahren

Die modellbasierten Analyseverfahren sind gut zur Darstellung von Sensorinformationen bzw. Zustandsaussagen, Plausibilitätssteigerung und Datenreduktion für das robuste Brückenmonitoring geeignet. Im Allgemeinen wird ein explizites mathematisches Modell, welches die physikalischen Eigenschaften und Zusammenhänge des zu untersuchenden Prozesses beschreibt, angenommen, z. B., zeitunabhängige Stoffgesetze, analytische Lebensdauermodelle sowie Modelle zur Beschreibung des Last- und Verformungsverhaltens. Je nach Anwendung stehen hier verschiedene Algorithmen zur Verfügung. Bei der modellbasierten Zustandsschätzung wird dieses physikalische Hintergrundwissen implizit mit berücksichtigt, sodass die Mess- und Erfassungsdaten (z. B. Fusion von Temperatur- und Feuchtigkeitssensor) bezüglich Genauigkeit und Glattheitseigenschaften verbessert werden können. Je genauer die Modellierung des unterlagerten Prozesses, desto genauer ist auch das Ergebnis des Analyseverfahrens.

Der Vorteil der modellbasierten Analyseverfahren ist die gute Rückverfolgbarkeit, d. h. die genaue Nachvollziehbarkeit der Ergebnisse. Durch die systematische Betrachtung der Unsicherheiten kann darüber hinaus jederzeit eine Aussage getroffen werden, wie zuverlässig bzw. vertrauenswürdig das Analyseergebnis ist; beispielsweise vergrößert sich die Unsicherheit automatisch, je mehr Zeit seit der letzten berücksichtigten Messung vergangen ist. Als Nachteil ist zu erwähnen, dass bei allen modellbasierten Analyseverfahren viel Expertenwissen in Form von physikalischen Modellen notwendig ist. Beim robusten Brückenmonitoring handelt es sich insbesondere um physikalische Modelle mit sehr vielen (meist unbekannt) Parametern (z. B.

	Plausibilisierung	Fusion von Sensordaten	Interpolation	Ableitung höherwertiger Information	Datenreduktion
Modellbasierte Analyseverfahren					

Materialkonstanten) und sogar inhomogene Modelle. Durch einige Vereinfachungen, wie beispielsweise die Berücksichtigung von sehr allgemeingültigen physikalischen Gesetzen (z. B. Trägheitseigenschaften, homogene Materialstrukturen), kann diese Aussage ein wenig entschärft werden. Hier können schon mit sehr einfachen Analyseverfahren insbesondere für die Plausibilitätssteigerung zufriedenstellende Ergebnisse erreicht werden.

Die Tabelle gibt eine abschließende Einschätzung für die Eignung modellbasierter Analyseverfahren in den unterschiedlichen Einsatzbereichen.

## 7.2 Statistische Analyseverfahren

Die statistischen Analyseverfahren (insbesondere die maschinellen Lernverfahren) eignen sich im Allgemeinen sehr gut für verschiedene Einsatzbereiche im robusten Brückenmonitoring. Die im vorherigen Kapitel beschriebenen modellbasierten Analyseverfahren benötigen ein mathematisches Modell, welches die physikalischen Eigenschaften und Zusammenhänge des zu untersuchenden Prozesses beschreibt. Es gibt zwei große Aufgabenstellungen, die bei modellbasierten Ansätzen gelöst werden müssen. Die eine zu lösende Teilaufgabe ist die hohe Komplexität und Rechenaufwand solcher Modelle, insbesondere wenn die Sensordaten lokal vor Ort, d. h. im Sensorknoten, ausgewertet und überprüft werden sollen. Die andere zu lösende Teilaufgabe ist die Vielzahl an unbekanntem Parametern. Dazu kommt, dass insbesondere bei einem inhomogenen System wie einer Brücke diese Parameter vom Ort abhängig sind. Die präzise Modellierung ist deshalb sehr aufwändig und steht in keinem Verhältnis zu dem Genauigkeits- und Robustheitsgewinn. Hierfür ist es lohnenswert, entweder einfachere Modelle zu finden, die für eine Plausibilisierung und Sensorfusion der Mess- und Erfassungsdaten ausreichen, oder einen statistischen Ansatz (wie maschinelle Lernverfahren) zu verfolgen.

Die besondere Eigenschaft der maschinellen Lernverfahren ist ihre selbstständige Lernfähigkeit, d. h., basierend auf einem Trainingsdatensatz können diese selbstständig bestimmte Aufgaben erlernen,

ohne explizit dafür programmiert zu werden. Die Leistungsfähigkeit und die Möglichkeit der Erfüllung der gestellten Aufgaben hängen von der Struktur und Anordnung der Verfahren ab. Die eigentliche Herausforderung ist, diese Struktur für bestimmte Aufgaben zu finden. Ist diese einmal für eine bestimmte Problemklasse bzw. Sensortyp definiert, so können die Verfahren diese automatisch durchführen und diese selbstständig erlernen.

Die statistischen Analyseverfahren eignen sich insbesondere für die Plausibilitätssteigerung und die Extraktion höherwertiger Information bzw. das Treffen fachtechnischer Aussagen.

### Leistungsfähige Plausibilisierung

Bei der Plausibilisierung wird aus einem Trainingsdatensatz automatisch eine Art Modell gelernt, welches das „Normal“-Verhalten des Signals und somit des Brückenbauwerks und des Sensorsystems charakterisiert. Danach müssen lediglich die Mess- und Erfassungsdaten mit dem vorher gelernten Modell verglichen werden. Gibt es Diskrepanzen zwischen dem gemessenen Signalverlauf und dem gelernten „Normal“-Verhalten, wird dieser von der weiteren Verarbeitung ausgeschlossen, um fehlerhafte Ergebnisse basierend auf falschen Eingangswerten zu vermeiden. Weiterhin kann eine entsprechende Meldung an die überlagerte Schicht der Fernüberwachung des Messsystems und des Bauwerks gegeben werden.

### Ableitung höherwertiger Information

Die maschinellen Lernverfahren erlauben es, ohne vorheriges Modellwissen relevante Merkmale und Information aus umfangreichem Datenmaterial herauszufiltern. Voraussetzung für die Extraktion höherwertiger Information und somit für das Treffen fachtechnischer Aussagen ist, dass für eine gewisse Menge an Daten die gewünschte Aussage in Form von Labels vorgegeben werden kann. Beispielsweise muss für die Identifikation von Verkehrslastdaten für die Lerndaten vorgegeben werden, welche Verkehrslast aktuell vorherrscht. Auch hier hängt die Menge der notwendigen Mess- und Erfassungsdaten sehr stark von dem jeweiligen

Anwendungsfall ab. Eine allgemeingültige Aussage kann leider nicht getroffen werden.

Der Ablauf der statistischen Analyseverfahren kann prinzipiell in zwei Phasen unterteilt werden. In der sogenannten Lernphase wird eine Art Abdruck bzw. Modellbeschreibung über das prinzipielle Signalverhalten basierend auf einer bestimmten Menge an Trainingsdaten generiert. In der Einsatzphase werden dann die Mess- und Prüfdaten basierend auf der vorher gelernten Modellbeschreibung ausgewertet. Im Allgemeinen ist die Lernphase sehr aufwändig und benötigt eine große Menge an Rechenaufwand; dies wird in der Praxis nur sehr schwer auf Sensorebene umsetzbar sein. Die Berechnungen für die Einsatzphase zum Beispiel für die Plausibilisierung hingegen sind sehr effizient und können sehr einfach auf Sensorebene umgesetzt werden. Weiterhin ist es möglich, während der Laufzeit die gelernte Modellbeschreibung immer weiter zu verfeinern, das Modell passt sich somit selbstständig, adaptiv Umgebungsänderungen an und die Berechnungen werden somit mit der Einsatzzeit immer genauer und zuverlässiger. Allerdings ist durch die automatische Anpassung an Umgebungsänderungen während der Einsatzphase eine Erkennung von Drifterscheinungen von Sensorik naturgemäß nicht oder zumindest schwer möglich.

Der große Vorteil der statistischen Analyseverfahren ist, dass nur eine geringe Menge an Prozesswissen notwendig ist und das selbstständige Anpassen bzw. Lernen der unterlagerten Modellstruktur zur Erfüllung der jeweiligen Aufgabe. Der Nachteil ist, die grobe Struktur und Anordnung der Verfahren für eine bestimmte Problemklasse bzw. Sensortyp zu finden und die große Menge an Trainingsdaten, die für das Lernen notwendig ist; diese hängt sehr stark von der zu erlernenden Aufgabenstellung ab. Weiterhin ist es in den meisten Fällen nicht möglich, eine Aussage zu treffen, wie vertrauenswürdig das Analyseergebnis ist; eine Rückverfolgbarkeit ist bei den maschinellen Lernverfahren nicht gegeben.

Die Tabelle gibt eine abschließende Einschätzung für die Eignung statistischer Analyseverfahren in den unterschiedlichen Einsatzbereichen.

### 7.3 Folgerung für die Praxis

Diese Forschungsarbeit hat mittels einer Machbarkeitsstudie und anhand von realen Erfassungsdaten gezeigt, dass modellbasierte sowie statistische Analyseverfahren für eine ganze Reihe von Einsatzbereichen beim robusten Brückenmonitoring eingesetzt werden können. Dabei hat sich gezeigt, dass die modellbasierten Analyseverfahren besonders für die Sensorfusion, zeitliche und örtliche Interpolation und für die Datenreduktion geeignet sind, wohingegen die statistischen Analyseverfahren besonders für die Plausibilisierung und die Ableitung höherwertiger Information geeignet sind. Je nach Anwendung gilt es, aus dem Spektrum an Analyseverfahren, die in dieser Forschungsarbeit berücksichtigt wurden, das passende auszuwählen. Auch eine Kombination verschiedener Verfahren ist für bestimmte Anwendungsfälle durchaus denkbar. Alle vorgestellten und untersuchten Verfahren sind so generisch, dass diese prinzipiell an eine Vielzahl an Problemstellung angepasst werden können.

Weiterhin hat diese Forschungsarbeit gezeigt, dass durch den Einsatz von leistungsfähigen gedächtnis-behafteten selbstlernenden Algorithmen für die Einsatzbereiche der Sensorfusion, Interpolation, Plausibilitätserhöhung und Treffen fachtechnischer Monitoringaussagen Ergebnisse erzielt werden können, die bezüglich der Verarbeitung von Mess- und Erfassungsdaten weit über den aktuellen Stand beim Brückenmonitoring hinausgehen. Anhand mehrerer Szenarien für die realen Erfassungsdaten zur Verfügung standen, wurde gezeigt, dass diese Verfahren sehr zuverlässig verschiedenste Signalstörungen wie Messausreißer, erhöhtes Rauschen und Brummeinstreuungen erkennen können. Nur durch die frühzeitige und zuverlässige Plausibilisierung von Sensordaten von Brückenbauwerken kann verhindert werden, dass offensichtlich fehlerhafte Messwerte (wie z. B. Messausreißer, störungsbehaftete Messungen) zu falschen Vorhersagen der Systemzuverlässigkeit von Brückenbauwerken durch rechnergestützte Systemmodelle führen.

Das Forschungsvorhaben FE 15.0548/2011/GRB bietet eine Vielzahl von Anknüpfungspunkten für

	Plausibilisierung	Fusion von Sensordaten	Interpolation	Ableitung höherwertiger Information	Datenreduktion
Statistische Analyseverfahren					

weitere Forschungsarbeiten. Aus der Erfahrung der Autoren sind die vorgestellten Analyseverfahren sehr generisch, d. h. allgemeingültig und für eine Vielzahl von Problemstellungen einsetzbar. Die prinzipielle Machbarkeit mittels der vorgestellten Verfahren für andere Problemstellungen im Bereich des robusten Brückenmonitorings muss allerdings noch gezeigt werden. Aus Sicht der Autoren sind dabei besonders interessant und lohnenswert die Detektion und Kompensation von Sensordrifts, Erkennung von langfristigen Veränderungen von Mustern im Sensorsignal und somit im Bauwerk, kombiniert mit kontinuierlichen und zeitdiskreten Messsignalen und hochdimensionalen Messgrößen bzw. Zustandsparameter (Array von Sensoren). Diese Forschungsarbeit bietet hierfür einen vielversprechenden Ansatzpunkt.

## 8 Literatur

1. FRADEN, J.: Handbook of Modern Sensors, Physics, Designs, and Applications, Fourth Edition. s.l.: Springer, 2010
2. YAO, C., LI, Y.: Research on Temperature Influences in Cable-Stayed Bridges' Health Monitoring. Applied Mechanics and Materials, S. Bd. 188, 162-167, 2012
3. SCHNELLENBACH-HELD, M., PEETERS, M., MIEDZINSKI, G.: Entwurf Schlussbericht „Intelligente Bauwerke“, Teilprojekt „Schädigungsrelevante Einwirkungen und Schädigungspotenziale von Brückenbauwerken aus Beton“, FE 15.0510/2011/DRB. Essen: s. n., 2013
4. Internetseite Sensortec GmbH. [Online] 31. Juli 2013. <http://www.sensortec.de>
5. ZHAO, Y. et al.: All-fiber-optic sensor for relative humidity measurement. International Conference on Electronics and Optoelectronics (ICEOE), 2011
6. DONG, S.-G. et al.: Effective monitoring of corrosion in reinforcing steel in concrete constructions by a multifunctional sensor. Advances in Corrosion Science for Lifetime Prediction and Sustainability, Selection of Papers from the 8<sup>th</sup> ISE Spring Meeting 2010
7. KOBAYASHI, K., BANTHIA, N.: Corrosion detection in reinforced concrete using induction heating and infrared thermography. Journal of Civil Structural Health Monitoring, S. Bd. 1, Nr. 1-2, 25-35, 2011
8. COSTA, B., FIGUEIRAS, J.: Evaluation of a strain monitoring system for existing steel railway bridges. Journal of Constructional Steel Research, S. Bd. 72, 179-191, 2012
9. LÓPEZ-HIGUERA, J. M. et al.: Fiber Optic Sensors in Structural Health Monitoring. Journal of Lightwave Technology, S. Bd. 29, Nr. 4, 587-608, 2011
10. ANTUNES, P. F. C., VARUM, H., ANDRÉ, P. S.: Dynamic Monitorization of Structures with Optical Sensors. Proceedings of the 8<sup>th</sup> International Conference on Structural Dynamics (EURODYN), 2011
11. BROWNJOHN, J. et al.: Vibration-based monitoring of civil infrastructure: challenges and successes. Journal of Civil Structural Health Monitoring, S. Bd. 1, Nr. 3-4, 79-95, 2001
12. BASTANI, A. et al.: Identification of temperature variation and vibration disturbance in impedance-based structural health monitoring using piezoelectric sensor array method. S. Bd. 11, Nr. 3, 305-314, 2012
13. MATSUYA, I. et al.: Development of Lateral Displacement Sensor for Real-Time Detection of Structural Damage. IEEJ Transactions on Electrical and Electronic Engineering, S. Bd. 6, 266-272, 2011
14. LUBASCH, P.: Identifikation von Verkehrslasten unter Einsatz von Methoden des Soft Computing. Essen: Dissertation, 2009
15. ISERMANN, R.: Fault-Diagnosis Systems. s.l.: Springer-Verlag, 2006
16. LUNZE, J.: Regelungstechnik 1 – Systemtheoretische Grundlagen, Analyse und Entwurf einschleifiger Regelungen. Bochum: Springer-Verlag, 2008
17. SIMON, D.: Optimal State Estimation. New Jersey: John Wiley & Sons, Inc., 2006
18. ALSPACH, D. L., SORENSON, H. W.: Nonlinear Bayesian estimation using Gaussian sum approximations. IEEE Transactions on Automatic Control. 1972, Bd. 17, 4

19. CRASSIDIS, J. L., JUNKINS, J. L.: Optimal Estimation of Dynamic Systems, Second Edition. s.l.: CRC Press, 2011
20. JULIER, S. J., UHLMANN, J. K.: New extension of the Kalman-Filter to nonlinear systems. Proc. SPIE 3068, Signal Processing, Sensor Fusion, and Target Recognition VI. 28. Juli 1997
21. SAWO, F.: Nonlinear State and Parameter Estimation of Spatially Distributed Systems. Karlsruhe: Universitätsverlag Karlsruhe, 2009
22. CURBACH, M.: Ermittlung der Spannungen aus Abfluß der Hydratationswärme am Beispiel der Brücke Rudolphstein. 5. Dresdner Brückenbausymposium, 1995
23. LEHNER, St.: Kontinuierlich eingegossene Schiene – Temperaturverteilung – Verbundwirkung – Brücken. Technische Universität München: s. n., 2006
24. WEBER, F., DISTL, H.: Echtzeitgeregelte Masendämpfer für Wolgograd-Brücke. Heft 6, Beton- und Stahlbetonbau 108, S. 362-372, 2013
25. ZILCH, K. et al.: Bericht zum Forschungsprojekt FE 88.002/2009: Entwicklung von Verfahren einer zuverlässigkeitsbasierten Bauwerksprüfung. Bergisch Gladbach: Wirtschaftsverlag NW, 2011
26. HOHBERG, R.: Zum Ermüdungsverhalten von Beton. Berlin: Dissertation, 2004
27. FEHLMANN, P.: Zur Ermüdung von Stahlbetonbrücken. Zürich: Dissertation, 2012
28. BLOM, H. A. P., BAR-SHALOM, Y.: The interacting multiple model algorithm for systems with Markovian switching coefficients. IEEE Transactions on Automatic Control. August 1988, S. 780-783
29. BAR-SHALOM, Y., LI, X. RONG and KIRUBARAJAN, Th.: Estimation with Applications to Tracking and Navigation. s.l.: John Wiley & Sons, Inc., 2001
30. NIELSEN, J. K. et al.: Bayesian Interpolation and Parameter Estimation in a Dynamic Sinusoidal Model. IEEE Transactions on Audio, Speech, and Language Processing. September 2011, S. 1986-1998
31. ALVES, D., COELHO, R.: A Real-Time Algorithm for the Harmonic Estimation and Frequency Tracking of Dominant Components in Fusion Plasma Magnetic Diagnostics. Review of Scientific Instruments
32. GRAßE, W.: Lasten und Einwirkungen auf Brücken einschließlich Kombinationsregeln (DIN-Fachbericht 101)
33. BIEWER, B.: Fuzzy-Methoden. Praxisrelevante Rechenmodelle und Fuzzy-Programmiersprachen. Berlin: Springer, 1997
34. RASMUSSEN, C. E., WILLIAMS, C.: Gaussian Processes for Machine Learning. s.l.: the MIT Press, 2006
35. GRAUPE, D.: Principles of Artificial Neural Networks. s.l.: World Scientific, 2007
36. LJUNG, L.: Perspectives on system identification. Annual Reviews in Control, S. 1-12, 2010
37. BISHOP, C. M.: Neural networks for pattern recognition. UK: Oxford University Press, 1998
38. BISHOP, C. M.: Pattern Recognition and Machine Learning. UK: Springer Verlag, 2006
39. ABE, S.: Support Vector Machines for Pattern Classification. s.l.: Springer Verlag, 2005
40. SCHÖLKOPF, B., SMOLA, A. J.: Learning with Kernels. s.l.: The MIT Press, 2002
41. STEIN, M. L.: Interpolation of Spatial Data – Some Theory for Kriging. s.l.: Springer-Verlag, 1999
42. BRUNN, D., SAWO, F.: Modellbasierte Vermessung verteilter Phänomene und Generierung optimaler Messequenzen. tm – Technisches Messen, S. 75-90, 2007
43. HEARN, G., TESTA, R.: Modal Analysis for Damage Detection in Structures. Journal of Structural Engineering. 1991, Bd. 117, 10, S. 3042-3063
44. PAPOULIS, A., PILLAI, S. Unnikrishna: Probability, Random Variables and Stochastic Processes, Fourth Edition. s.l.: McGraw-Hill, 2002

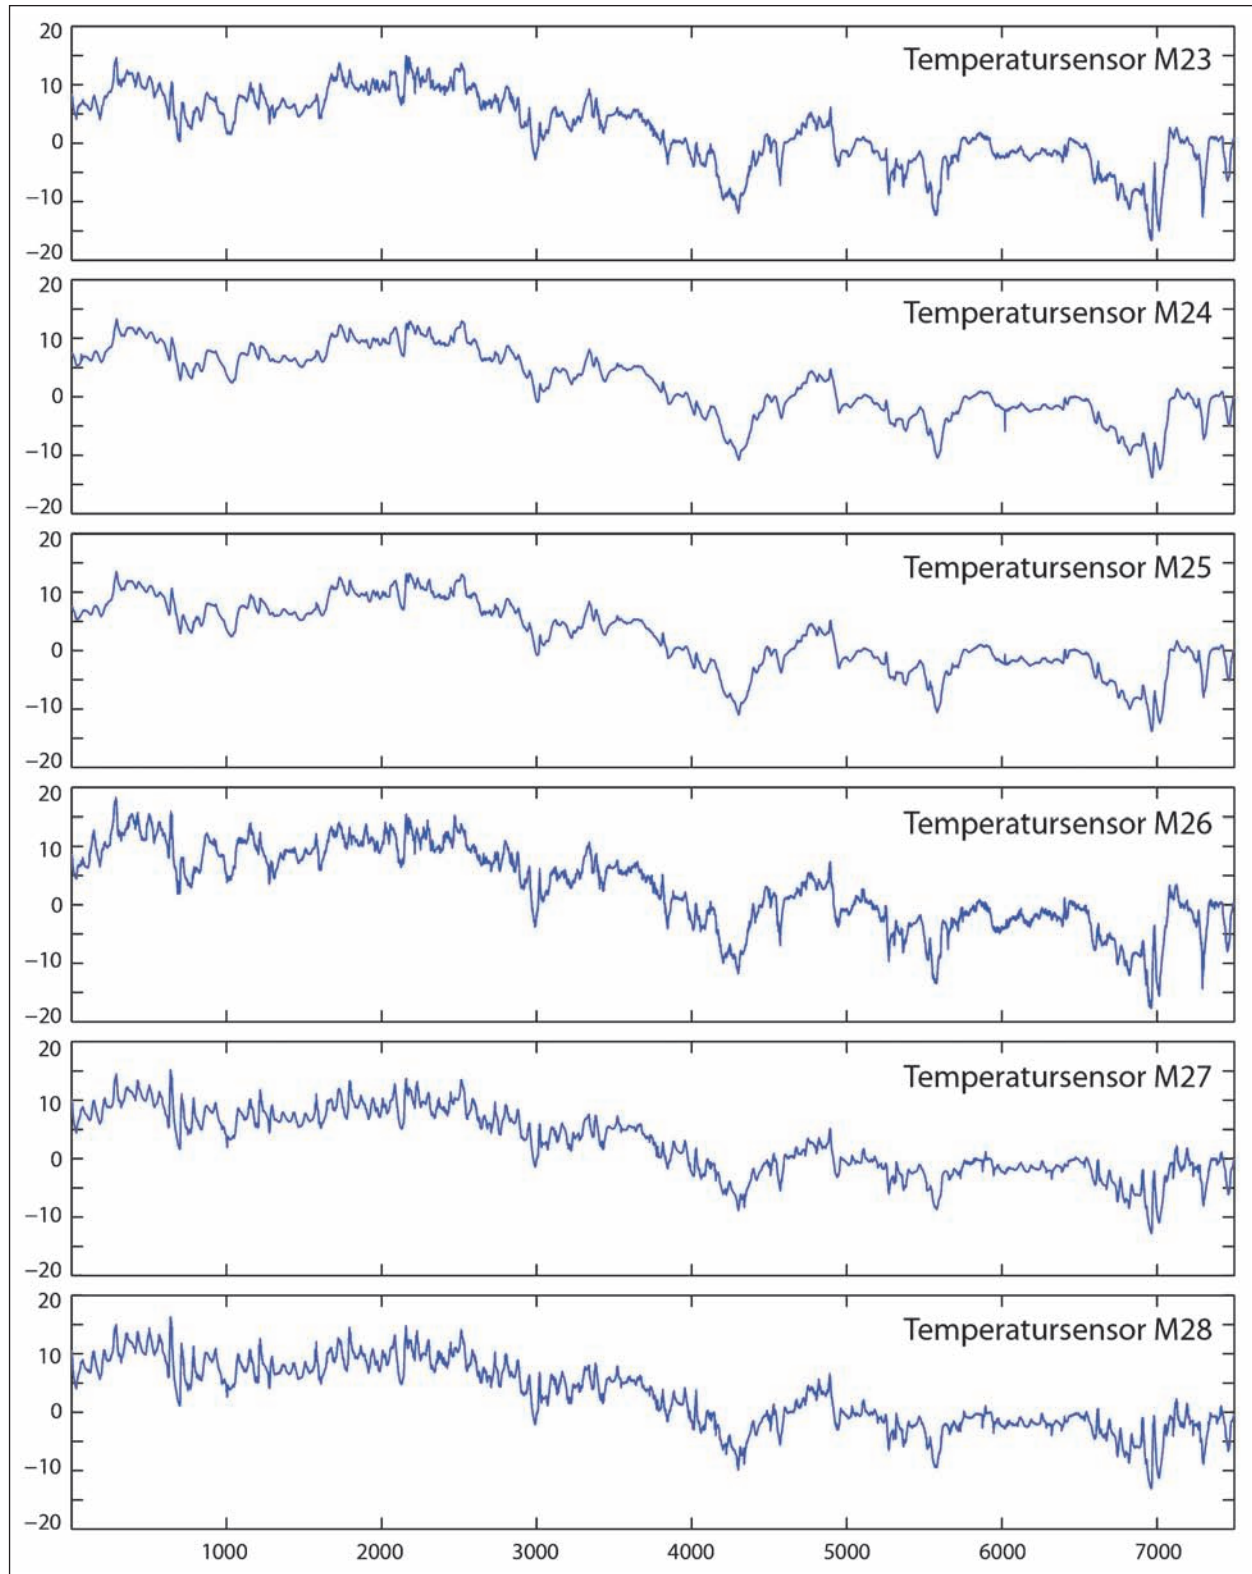
45. MAIERHOFER, Chr. et al.: Bewertung von Radar- und Ultraschalldaten mit Hilfe der Datenfusion. DGZfP-Jahrestagung, 2007
46. CANDY, J. V.: Model-Based Signal Processing. Hoboken, New Jersey, USA: John Wiley & Sons, Inc., 2006
47. MEHRA, R. K., PESCHON, J.: An innovations approach to fault detection and diagnosis in dynamic systems. Automatica. September 1971, S. 637-640
48. WELCH, G., BISHOP, G.: An Introduction to the Kalman-Filter. Department of Computer Science, University of North Carolina at Chapel Hill: s. n., 1995
49. KLUMPP, V. et al.: The Sliced Gaussian Mixture Filter with Adaptive State Decomposition Depending on Linearization Error. Proceedings of the 13<sup>th</sup> Conference on Information Fusion (FUSION). 2010, S. 1-8
50. SCHÖN, T., GUSTAFSSON, F., NORDLUND, P.-J.: Marginalized particle filters for mixed linear/nonlinear state-space models. 7, 2005, IEEE Transactions on Signal Processing, Bd. 53, S. 2279-2289
51. HAYKIN, S.: Kalman-Filtering and Neural Networks. s.l.: John Wiley & Sons, Inc., 2001
52. RAUCH, H. E., TUNG, F., STRIEBEL, C. T.: Maximum likelihood estimates of linear dynamics systems. August 1965, AIAA Journal, Bd. 3, S. 1445-1450
53. SÄRKKÄ, S.: Unscented Rauch-Tung-Striebel Smoother. IEEE Transactions on Automatic Control. April 2008, S. 845-849
54. AGAMENNONI, G., NIETO, J. I., Nebot, E. M.: An Outlier-Robust Kalman-Filter. Shanghai, China: IEEE, 2011. 2011 IEEE International Conference on Robotics and Automation. S. 1551-1558
55. FALK, M., HÜSLER, J., REISS, R.-D.: Laws of Small Numbers: Extremes and Rare Events. Basel: Birkhäuser Verlag, 2011
56. SAMMUT, C., WEBB, G. I.: Encyclopedia of Machine Learning. New York: Springer, 2011
57. WORDEN, K. et al.: The Fundamental Axioms of Structural Health Monitoring. Proceedings of the Royal Society, S. 1639-1664, 2007
58. WORDEN, K., MANSON, G.: The Application of Machine Learning to Structural Health Monitoring. Philosophical Transactions of the Royal Society, S. 515-537, 2006
59. WORDEN, K., DULIEU-BARTON, J. M.: An Overview of Intelligent Fault Detection in Systems and Structures. Structural Health Monitoring, S. 85-98, 2004
60. SOHN, H. et al.: Structural Health Monitoring Using Statistical Pattern Recognition Techniques. ASME Journal of Dynamics Systems, Measurement and Control: Special Issue on Identification of Mechanical Systems, 2001
61. KERSCHEN, G. et al.: Sensor Validation using Principal Component Analysis. Smart Materials and Structures, S. 36-42, 2005
62. WORDEN, K., MANSON, G.: Visualisation and Dimension Reduction of High-Dimensional Data for Damage Detection. IMAC – Proceedings of the 17<sup>th</sup> International Modal Analysis Conference. S. 1576-1585, 1999
63. KOHONEN, T.: Self-Organizing Maps. s.l.: Springer Verlag, 2001
64. RITTER, H., MARTINETZ, T., SCHULTEN, K.: Neuronale Netze – Eine Einführung in die Neuroinformatik selbstorganisierender Netzwerke. Bonn: Addison-Wesley, 1991
65. MACKERT, K.-U.: Expertengespräch Stahlbrückenbau – Kanalbrücke Berkenthin mit temperierter Fahrbahn. Bergisch Gladbach: s. n., 2011
66. DUBROVA, E.: Fault-Tolerant Design. s.l.: Springer-Verlag, 2013
67. SCHÖNFELD, D.: Informations- und Kodierungstheorie. s.l.: Springer-Verlag, 2012
68. KLASSEN, F., OESTREICH, V., VOLZ, M.: Industrielle Kommunikation mit Feldbus und Ethernet. s.l.: VDE-Verlag, 2010
69. CAN in Automation (CiA): Controller Area Network. <http://www.can-cia.org/>. [Online] [Zitat vom: 13. 05 2014.]
70. LAWRENZ, W.: CAN Controller Area Network - Grundlagen und Praxis

71. ZIMMERMANN, W., SCHMIDGALL, R.: Bus-systeme in der Fahrzeugtechnik – Protokolle, Standards und Softwarearchitektur. s. l.: Vieweg+Teubner, 2010
72. LOY, D.: LON-Technologie. Verteilte Systeme in der Anwendung. Heidelberg: s. n., 1998
73. PROFIBUS. <http://www.profibus.com/technology/profibus>. [Online] [Zitat vom: 13. 05 2014]
74. POPP, M.: Profibus-Dp/DPV1 Grundlagen, Tipps und Tricks für Anwender. s.l.: Hüthig
75. ANSI/TIA/EIA-485-A-98: Electrical Characteristics of Generators and Receivers for Use in Balanced Digital Multipoint Systems. 1998
76. JAPSERNEITE, J., NEUMANN, P.: How to Guarantee Realtime Behavior using Ethernet. Salvador-Bahia, Brazil. In: 11<sup>th</sup> IFAC Symposium on Information Control Problems in Manufacturing (INCOM'2004), 2004
77. DECOTIGNIE, J.-D.: Ethernet-Based Real-Time and Industrial Communications. In: Proceedings of the IEEE 93 (2005)
78. PÖHLSSEN, St.: Entwicklung einer Service-orientierten Architektur zur vernetzten Kommunikation zwischen medizinischen Geräten, Systemen und Applikationen. Lübeck: s. n., 2010
79. COYLE, F. P.: XML, Web Services, and the Data Revolution. s.l.: Addison Wesley, 2002
80. W3C Recommendation: SOAP Version 1.2 Part 1: Messaging Framework. <http://www.w3.org/TR/2007/REC-soap12-part1-20070427/>. [Online] [Zitat vom: 13. 05 2014]
81. LIU, T. et al.: Multi-source information fusion applied to structural damage diagnosis. Structure and Infrastructure Engineering: Maintenance, Management, Life-Cycle Design and Performance, Bd. 7, S. 353-367, 5, 2011
82. XIE, Z., FENG, J.: Real-time nonlinear structural system identification via iterated unscented Kalman-Filter. Mechanical Systems and Signal Processing, Bd. 28, S. 309-322, 2012
83. KLASSEN, F., OESTREICH, V., VOLZ, M.: Industrielle Kommunikation mit Feldbus und Ethernet. s.l.: VDE-Verlag, 2010

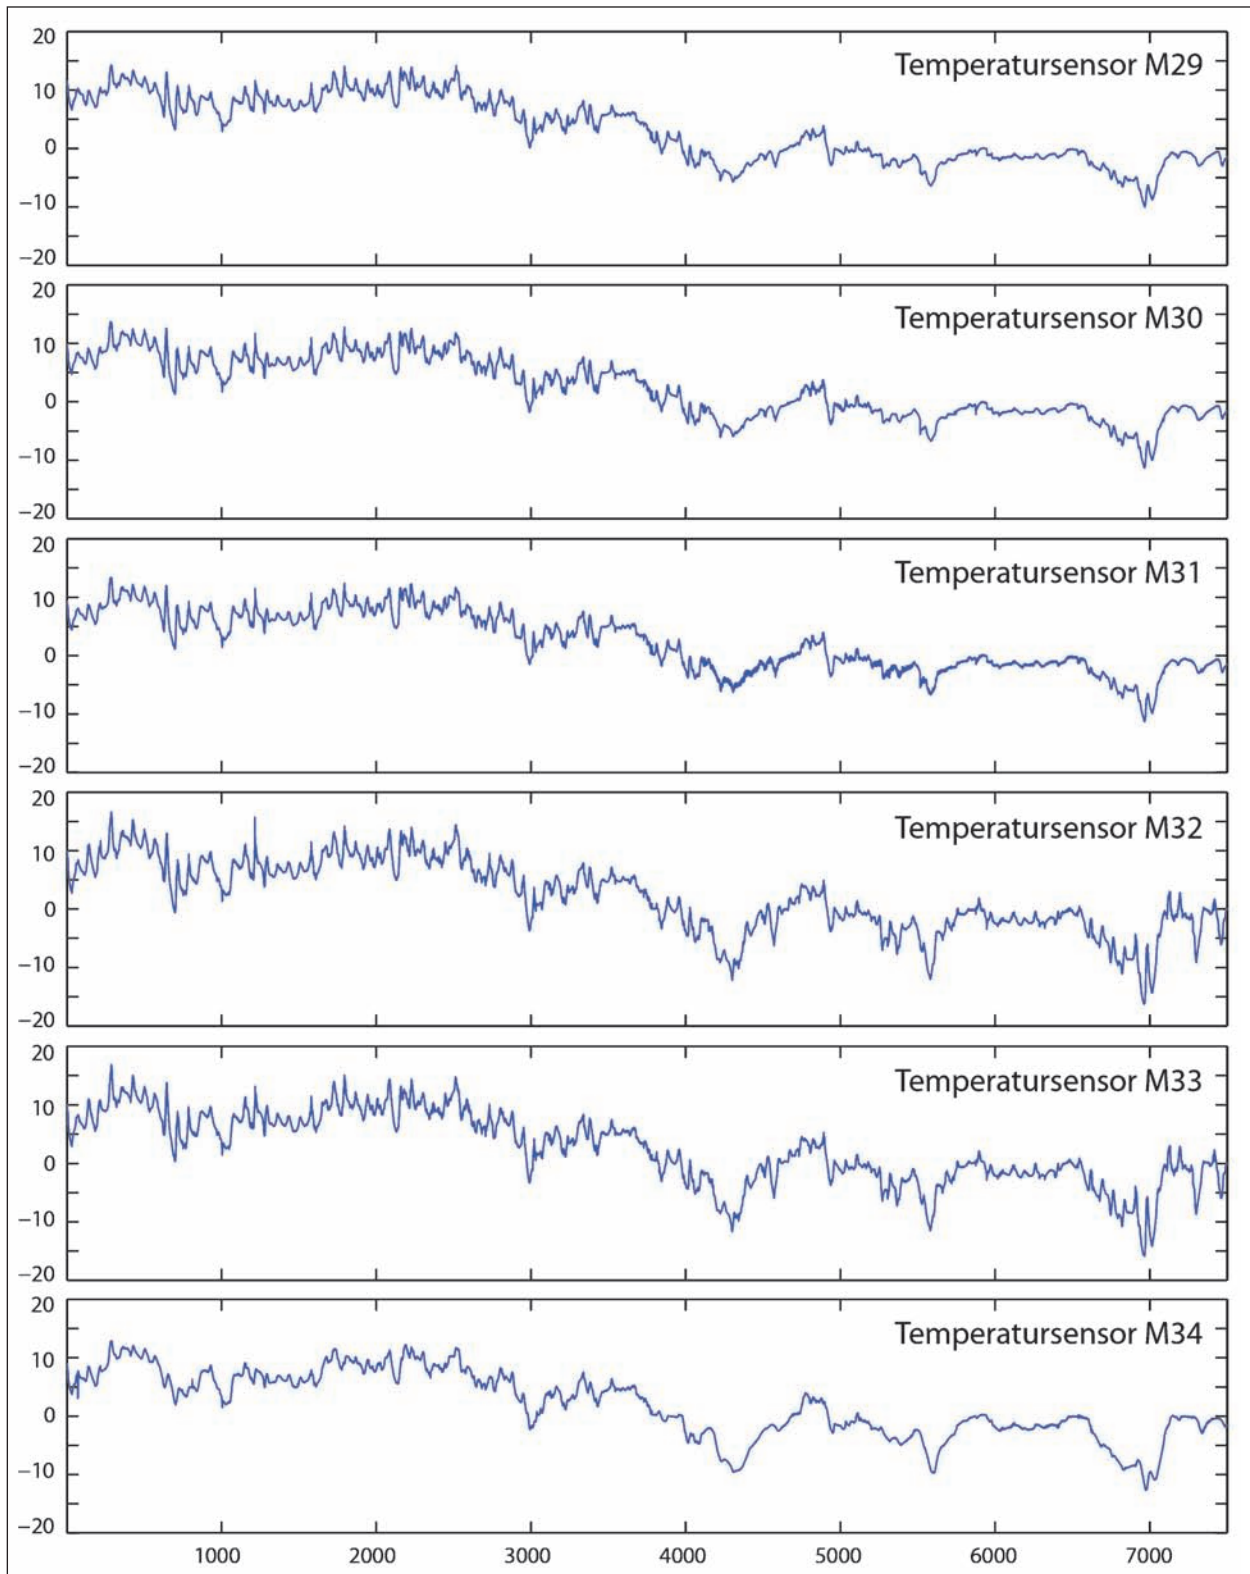


## 9 Anhang – Anwendungsszenario Kanalbrücke Berkenthin

### 9.1 Darstellung des Trainingsdatensatzes



**Bild 56:** Darstellung des für das Lernen des künstlichen neuronalen Netzes benutzten Trainingsdatensatzes (Temperatursensor Messkanal M23 – Messkanal M28)



**Bild 57:** Darstellung des für das Lernen des künstlichen neuronalen Netzes benutzten Trainingsdatensatzes (Temperatursensor Messkanal M29 – Messkanal M34)

## Schriftenreihe

### Berichte der Bundesanstalt für Straßenwesen

#### Unterreihe „Brücken- und Ingenieurbau“

## 2008

- B 59: Bandverzinkte Schutzplankenholme  
Schröder € 12,50
- B 60: Instandhaltung des Korrosionsschutzes durch Teilerneuerung – Bewährung  
Schröder € 13,50
- B 61: Untersuchung von Korrosion an Fußplatten von Schutzplankenpfosten  
Schröder, Staeck € 13,00
- B 62: Bewährungsnachweis von Fugenfüllungen ohne Unterfüllstoff  
Eilers € 12,00
- B 63: Selbstverdichtender Beton (SVB) im Straßentunnelbau  
Heunisch, Hoepfner, Pierson (†), Dehn, Orgass, Sint  
Dieser Bericht liegt nur in digitaler Form vor und kann kostenpflichtig unter [www.nw-verlag.de](http://www.nw-verlag.de) heruntergeladen werden. € 17,50
- B 64: Tiefenabhängige Feuchte- und Temperaturmessung an einer Brückenkappe der Expositionsklasse XF4  
Brameshuber, Spörel, Warkus € 12,50

## 2009

- B 65: Zerstörungsfreie Untersuchungen am Brückenbauwerk A1 Hagen/Schwerte  
Friese, Taffe, Wöstmann, Zoega  
Dieser Bericht liegt nur in digitaler Form vor und kann kostenpflichtig unter [www.nw-verlag.de](http://www.nw-verlag.de) heruntergeladen werden. € 14,50
- B 66: Bewertung der Sicherheit von Straßentunneln  
Zulauf, Locher, Steinauer, Mayer, Zimmermann, Baltzer, Riepe, Kündig € 14,00
- B 67: Brandkurven für den baulichen Brandschutz von Straßentunneln  
Blosfeld € 17,50
- B 68: Auswirkungen des Schwerlastverkehrs auf die Brücken der Bundesfernstraßen – Teile 1-4  
Kaschner, Buschmeyer, Schnellenbach-Held, Lubasch, Grünberg, Hansen, Liebig, Geißler  
Dieser Bericht liegt nur in digitaler Form vor und kann kostenpflichtig unter [www.nw-verlag.de](http://www.nw-verlag.de) heruntergeladen werden. € 29,50
- B 69: Berücksichtigung der Belange behinderter Personen bei Ausstattung und Betrieb von Straßentunneln  
Wagener, Grossmann, Hintzke, Sieger € 18,50
- B 70: Frost-Tausalz-Widerstand von Beton in Brücken und Ingenieurbauwerken an Bundesfernstraßen  
Tauscher € 14,50

## 2010

- B 71: Empfehlungen für geschweißte KK-Knoten im Straßenbrückenbau  
Kuhlmann, Euler € 22,50
- B 72: Untersuchungen zur Dauerhaftigkeit von permanenten Anti-Graffiti-Systemen  
Weschpennig, Kropf, von Witzhausen € 13,50

B 73: Brand- und Abplatzverhalten von Faserbeton in Straßentunneln

Dehn, Nause, Juknat, Orgass, König  
Dieser Bericht liegt nur in digitaler Form vor und kann kostenpflichtig unter [www.nw-verlag.de](http://www.nw-verlag.de) heruntergeladen werden. € 21,00

B 74: Verwendung von Anti-Graffiti-Systemen auf Mauerwerk  
Müller € 14,00

B 75: Sachstand Verstärkungsverfahren – Verstärken von Betonbrücken im Bestand  
Schnellenbach-Held, Peeters, Scherbaum € 13,50

## 2011

B 76: Instandsetzung und Verstärkung von Stahlbrücken unter Berücksichtigung des Belagssystems  
Sedlacek, Paschen, Feldmann, Geßler, Möller, Steinauer, Scharnigg € 17,00

B 77: Anpassung von DIN-Fachberichten „Brücken“ an Eurocodes  
Teil 1: DIN-FB 101 „Einwirkung auf Brücken“  
Teil 2: DIN-FB 102 „Betonbrücken“  
Teil 3: DIN-FB 103 „Stahlbrücken“  
Teil 4: DIN-FB 104 „Verbundbrücken“  
Freundt, Böning, Maurer, Arnold, Gedwien, Müller, Schrick, Tappe, Kuhlmann, Rasche, Froschmeier, Euler, Hanswille, Brauer, Bergmann  
Dieser Bericht liegt nur in digitaler Form vor und kann kostenpflichtig unter [www.nw-verlag.de](http://www.nw-verlag.de) heruntergeladen werden. € 29,50

B 78: Bemessung von Wellstahlbauwerken – Vergleich nach den bisherigen und den neuen Richtlinien  
Kuhlmann, Günther, Krauss  
Dieser Bericht liegt nur in digitaler Form vor und kann kostenpflichtig unter [www.nw-verlag.de](http://www.nw-verlag.de) heruntergeladen werden. € 18,50

B 79: Untersuchungen zur Querkraftbemessung von Spannbetonbalken mit girlandenförmiger Spanngliedführung  
Maurer, Kiziltan, Zilch, Dunkelberg, Fitik  
Dieser Bericht liegt nur in digitaler Form vor und kann kostenpflichtig unter [www.nw-verlag.de](http://www.nw-verlag.de) heruntergeladen werden. € 15,50

B 80: Lautsprecheranlagen und akustische Signalisierung in Straßentunneln  
Mayer, Reimann, Löwer, Brettschneider, Los € 16,00

B 81: Quantifizierung der Lebensdauer von Betonbrücken mit den Methoden der Systemanalyse  
Müller, Vogel, Neumann € 14,50

B 82: Verkehrslastmodelle für die Nachrechnung von Straßenbrücken im Bestand  
Freundt, Böning € 16,00

B 83: Konzeption zur Nachrechnung bestehender Straßenbrücken  
Maurer, Kolodziejczyk, Zilch, Dunkelberg € 16,00

B 84: Prüfung des Frost-Tausalz-Widerstandes von Beton mit dem modifizierten CDF-Verfahren (XF2)  
Gehlen, Lowke, Milachowski € 15,00

B 85: Entwicklung von Verfahren einer zuverlässigkeitsbasierten Bauwerksprüfung  
Zilch, Straub, Dier, Fischer € 19,50

B 86: Untersuchungen an Bauwerken aus hochfesten Beton  
Nguyen, Freitag € 13,50

## 2012

B 87: Vermeidung von Glättebildung auf Brücken durch die Nutzung von Geothermie  
Feldmann, Döring, Hellberg, Kuhnhenne, Pak, Mangerig, Beucher, Hess, Steinauer, Kemper, Scharnigg € 17,00

B 88: Anpralllasten an Schutzeinrichtungen auf Brücken – Anpassung der DIN-Fachberichte „Stahlbrücken“ und „Verbundbrücken“ an endgültige Eurocodes und nationale Anhänge einschließlich Vergleichsrechnungen  
Kuhlmann, Zizza, Günther € 15,50

B 89: Nachrechnung von Betonbrücken zur Bewertung der Tragfähigkeit bestehender Bauwerke  
Maurer, Heeke, Kiziltan, Kolodziejczyk, Zilch, Dunkelberg, Fitik € 19,50

B 90: Fugenbewegung an der Ruhrtalbrücke Mintard  
Eilers, Quaas, Staeck € 14,00

## 2013

B 91: Priorisierung und Nachrechnung von Brücken im Bereich der Bundesfernstraßen – Einfluss der Einwirkungen aus Verkehr unter besonderer Berücksichtigung von Restnutzungsdauer und Verkehrsentwicklung  
Freundt, Böning € 15,00

B 92: Kriterien für die Anwendung von unbewehrten Innenschalen für Straßentunnel  
Kaundinya € 14,00

B 93: Querkrafttragfähigkeit von Fahrbahnplatten – Anpassung des DIN-Fachberichtes „Betonbrücken“ an die endgültige Eurocodes und nationale Anhänge einschließlich Vergleichsrechnungen  
Hegger, Reiß € 17,50

B 94: Baulicher Brandschutz für Tunnel in offener Bauweise – Rechnerischer Nachweis  
Peter, Knief, Schreyer, Piazzola  
Dieser Bericht liegt nur in digitaler Form vor und kann unter <http://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 95: Erfahrungen mit selbstverdichtendem und hochfestem Beton im Brücken- und Ingenieurbau an Bundesfernstraßen  
Tauscher € 17,00

B 96: Geothermischen Anlagen bei Grund- und Tunnelbauwerken  
Adam € 17,00

B 97: Einfluss der veränderten Verkehrsführung bei Ertüchtigungsmaßnahmen auf die Bauwerksbeanspruchungen  
Freundt, Böning € 15,00

## 2014

B 98: Brückenseile – Gegenüberstellung von vollverschlossenen Seilen und Litzenbündelseilen  
Friedrich  
Dieser Bericht liegt nur in digitaler Form vor und kann unter <http://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 99: Intelligente Brücke – Zuverlässigkeitsbasierte Bewertung von Brückenbauwerken unter Berücksichtigung von Inspektions- und Überwachungsergebnissen  
Fischer, Schneider, Thöns, Rücker, Straub  
Dieser Bericht liegt nur in digitaler Form vor und kann unter <http://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 100: Roadtraffic Management System (RTMS)  
Freundt, Vogt, Böning, Pierson, Ehrle € 15,00

B 101: Adaptive Spannbetonstruktur mit lernfähigem Fuzzy-Regelungssystem  
Schnellenbach-Held, Fakhouri, Steiner, Kühn € 18,50

B 102: Adaptive „Tube-in-Tube“-Brücken  
Empelmann, Busse, Hamm, Zedler, Girmscheid € 18,00

B 103: Umsetzung des Eurocode 7 bei der Bemessung von Grund- und Tunnelbauwerken  
Briebrecher, Städing € 14,00

B 104: Intelligente Brücke – Konzeption eines modular aufgebauten Brückenmodells und Systemanalyse  
Borrmann, Fischer, Dori, Wild  
Dieser Bericht liegt nur in digitaler Form vor und kann unter <http://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 105: Intelligente Brücke – Machbarkeitsstudie für ein System zur Informationsbereitstellung und ganzheitlichen Bewertung in Echtzeit für Brückenbauwerke  
Schnellenbach-Held, Karczewski, Kühn  
Dieser Bericht liegt nur in digitaler Form vor und kann unter <http://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 106: Einsatz von Monitoringsystemen zur Bewertung des Schädigungszustands von Brückenbauwerken  
Freundt, Vogt, Böning, Michael, Könke, Beinersdorf € 17,00

B 107: Materialeigenschaften von Kunststoffdichtungsbahnen bestehender Straßentunnel  
Robertson, Bronstein, Brummermann € 16,00

B 108: Fahrzeug-Rückhaltesysteme auf Brücken  
Neumann, Rauer € 18,50

B 109: Querkrafttragfähigkeit bestehender Spannbetonbrücken  
Hegger, Herbrand € 17,00

B 110: Intelligente Brücke – Schädigungsrelevante Einwirkungen und Schädigungspotenziale von Brückenbauwerken aus Beton  
Schnellenbach-Held, Peeters, Miedzinski  
Dieser Bericht liegt nur in digitaler Form vor und kann unter <http://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 111: Erarbeitung von Modellen zur Bestimmung der Schadensumfangsentwicklung an Brücken  
Müller € 15,00

## 2015

B 112: Nachhaltigkeitsberechnung von feuerverzinkten Stahlbrücken  
Kuhlmann, Maier, Ummenhofer, Zinke, Fischer, Schneider € 14,00

B 113: Versagen eines Einzelelementes bei Stützkonstruktionen aus Gabionen  
Placzek, Pohl  
Dieser Bericht liegt nur in digitaler Form vor und kann unter <http://bast.opus.hbz-nrw.de/> heruntergeladen werden.

B 114: Intelligente Bauwerke – Anforderungen an die Aufbereitung von Messgrößen und ihrer Darstellungsform  
Sawo, Klumpp, Beutler  
Dieser Bericht liegt nur in digitaler Form vor und kann unter <http://bast.opus.hbz-nrw.de/> heruntergeladen werden.

---

Alle Berichte sind zu beziehen im:

Carl Schünemann Verlag GmbH  
Zweite Schlachtpforte 7  
28195 Bremen  
Tel. (0421) 3 69 03-53  
Fax (0421) 3 69 03-48  
[www.schuenemann-verlag.de](http://www.schuenemann-verlag.de)

Dort ist auch ein Kompletverzeichnis erhältlich.