

Peter Kraemer

# **Schadensdiagnoseverfahren für die Zustandsüberwachung von Offshore-Windenergieanlagen**

Schriftenreihe der Arbeitsgruppe  
für Technische Mechanik  
im Institut für Mechanik und Regelungs-  
technik - Mechatronik

Herausgeber: Claus-Peter Fritzen

Band 3

**Impressum**

Prof. Dr.-Ing. Claus Peter Fritzen  
Arbeitsgruppe für Technische Mechanik  
Institut für Mechanik und Regelungstechnik – Mechatronik  
Universität Siegen  
57068 Siegen  
ISSN 2191-5601  
URN urn:nbn:de:hbz:467-5323  
Zugl.: Siegen, Univ., Diss., 2011

# **Schadensdiagnoseverfahren für die Zustandsüberwachung von Offshore-Windenergieanlagen**

DISSERTATION

zur Erlangung des akademischen Grades

DOKTOR-INGENIEUR

vorgelegt von

Dipl.-Ing. PETER KRAEMER

aus Timișoara (Rumänien)

eingereicht der

Naturwissenschaftlich-Technischen Fakultät

der Universität Siegen

Referent: Prof. Dr.-Ing. CLAUS-PETER FRITZEN

Korreferent: Prof. Dr.-Ing. RAIMUND ROLFES

Tag der mündlichen Prüfung

15. Juli 2011



## Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Mechanik und Regelungstechnik – Mechatronik der Universität Siegen.

Mein ganz besonderer Dank gilt meinem Doktorvater Prof. Dr.-Ing. C.-P. FRITZEN, der mich für das Thema der vorliegenden Arbeit begeistert und während meiner Zeit als wissenschaftlicher Mitarbeiter mit seiner sehr hohen fachlichen Kompetenz betreut hat.

Bedanken möchte ich mich auch bei:

- Prof. Dr.-Ing. R. ROLFES (Leibniz Universität Hannover), der das Korreferat und die damit verbundenen Mühen übernommen hat, sowie bei Prof. Dr.-Ing. T. CAROLUS und Prof. Dr.-Ing. O. NELLES für die Beiträge zur Durchführung des Promotionsverfahrens.
- dem Bundesministerium für Wirtschaft und Technologie für die finanzielle Unterstützung meiner fachlichen Arbeit während des Projektes „Integrales Monitoring- und Bewertungssystem für Offshore-Windenergieanlagen“, sowie bei Prof. Dr.-Ing. W. RÜCKER, Dipl.-Ing. R. ROHRMANN (Bundesanstalt für Materialforschung und –prüfung in Berlin, BAM), Dipl.-Ing. M. OERTEL (Fa.  $\mu$ -Sen) und der Fa. AREVA-Wind für die Bereitstellung der für diese Arbeit notwendigen Messdaten.
- Dipl.-Ing. E. BRODOWSKI und meiner Tante Dipl.-Math. L. POPI, die mir den Weg für das Maschinenbaustudium ebneten.
- meinen Kollegen am Institut: Herr G. DIETRICH, Dipl.-Ing. W. RICHTER, Dr.-Ing. R. T. SCHULTE, Dipl.-Ing. P. KÖSTER, M.Sc. K. XING, M.Sc. C. YANG, M.Sc. Y. NIU, M.Sc. M. TORRES, Dipl.-Ing. E. ZENUNI, Dipl.-Ing. M. KÜBBELER, M.Sc. H. JUNG, Dr.-Ing. B. KÜNKLER, MSc D. LI, Prof. Dr.-Ing. G. MENGELKAMP und unserer Sekretärin Frau G. THOMAS für die jederzeit sehr gute Zusammenarbeit und das sehr angenehme Zusammensein an unseren Institut.
- meinen Diplomarbeitern, die durch Ihren Einsatz meine Arbeit bereichert und unterstützt haben: Dipl.-Ing. D. LAUTENSCHLAGER, Dipl.-Ing. Y. TIAN, Dipl.-Ing. T. GLIGOR, Dipl.-Ing. D. H. RICHTER und B.Sc. I. BÜTHE.
- meinen langjährigen „Zimmergenossen“ M.Sc. M. KLINKOV und Dr.-Ing. J. MOLL für die sehr gute Arbeitsatmosphäre und die gegenseitige Hilfsbereitschaft.

Einen wesentlichen Anteil am Gelingen dieser Arbeit hat meine Frau Carmen, die während der ganzen Promotionszeit und insbesondere während der Projektbearbeitungszeiten mich liebe- und verständnisvoll unterstützt hat. Iubita mea Carmen: Iți multumesc din toata inima!

Siegen, im April 2011

*Für Chaya Sophie und Carmen*

---

**INHALTSVERZEICHNIS**

<b>NOMENKLATUR</b>	<b>IV</b>
<b>KURZFASSUNG</b>	<b>IX</b>
<b>1 EINLEITUNG</b>	<b>1</b>
1.1 HISTORISCHE EINORDNUNG	1
1.2 ALLGEMEINES ZUR SCHADENSERKENNUNG	4
1.2.1 Strukturschadenserkennung	5
1.2.2 Schadenserkennung an Maschinenkomponenten: die Zustandsüberwachung	7
1.3 FOKUS, BEITRAG UND STRUKTUR DER ARBEIT	8
1.4 VORHANDENE METHODEN - LITERATURÜBERBLICK	10
<b>2 THEORETISCHE GRUNDLAGEN UND BASISWERKZEUGE</b>	<b>14</b>
2.1 BESCHREIBUNG DYNAMISCHER SYSTEME IM ZEITBEREICH	14
2.1.1 Zeitkontinuierliches Zustandsraummodell	16
2.1.2 Zustandsraummodell in Modalkoordinaten	17
2.1.3 Zeitdiskretes Zustandsraummodell	19
2.2 IDENTIFIKATION LINEARER SYSTEME IM ZEITBEREICH BEI STOCHASTISCHER ANREGUNG	21
2.2.1 Stochastic Subspace Identification - Methode	21
2.2.2 Systemidentifikation mit Hilfe von autoregressiven Modellen	24
2.2.3 Schätzung von Systemzuständen mit Kalman-Filtern	27
2.3 SENSITIVITÄTSANALYSE DYNAMISCHER SYSTEME	29
2.3.1 Eigenfrequenzsensitivität	29
2.3.2 Eigenvektorsensitivität	30
2.3.3 Kennzahlen zur Korrelation der Modaldaten	31
2.4 KONZEPTE ZUR DATENANALYSE	33
2.4.1 Klassifikationsverfahren	33
2.4.2 Die Hauptkomponentenanalyse	38
2.4.3 Grundlagen der Informationstheorie	43
2.5 GRUNDLAGEN DER SIGNALANALYSE IM FREQUENZBEREICH	45
2.5.1 Fourieranalyse und Frequenzspektrum	45
2.5.2 Das Hüllkurvenspektrum	47
2.5.3 Cepstrumanalyse	49

---

2.5.4	Die spektrale Kurtosis	51
<b>3</b>	<b>STRUKTURSCHADENSDIAGNOSE</b>	<b>53</b>
3.1	ANFORDERUNGEN AN SCHADENSERKENNUNGSMETHODEN FÜR OFFSHORE- WINDENERGIEANLAGEN	53
3.2	DAS ÜBERWACHUNGSKONZEPT	59
3.3	SCHADENSDETEKTION UNTER VERÄNDERLICHEN UMGEBUNGS- UND BETRIEBSZUSTÄNDEN	61
3.3.1	Beschreibung existierender Methoden und Einführung in die Problematik der EOC-Kompensation	61
3.3.2	Auswahl des Algorithmus und der schädigungssensitiven Merkmale	72
3.3.3	Anwendung von Klassifikationsverfahren zur Kompensation von Effekten veränderlicher Umgebungs- und Betriebszustände auf die schädigungssensitiven Merkmale	87
3.3.4	Datenvorauswahl für Schadenser kennungs algorithmen	95
3.4	MODELLGESTÜTZTE SCHADENSLOKALISATION MIT HILFE VON MODALDATEN	97
3.4.1	Modalanalyse mit Vektor-Autoregressiven Modellen	97
3.4.2	Schadenslokalisierung mit inversen Eigenwert- und Eigenvektorsensitivitäten	103
3.5	SENSORFEHLERIDENTIFIKATION	119
3.5.1	Beschreibung bisher existierender Methoden	120
3.5.2	Sensorfehlerdetektion und -isolation mit Hilfe des Mutual Information Konzepts	126
3.5.3	Rekonstruktion von Signalen fehlerhafter Sensoren	134
3.5.4	Vergleich unterschiedlicher Methoden zur Sensorfehlererkennung	140
<b>4</b>	<b>SCHADENSDIAGNOSE AN MASCHINENKOMPONENTEN</b>	<b>144</b>
4.1	ANWENDUNG DER ZYKLISCHEN KOHÄRENZ ZUR SCHADENSERKENNUNG	144
4.2	VERBESSERUNG DER ERGEBNISSE DER ZYKLISCHEN KOHÄRENZ MIT HILFE VON KURTOGRAMMEN	150
4.3	ERWEITERUNG DER ZYKLISCHEN KOHÄRENZ ZUR ANWENDUNG AN PITCHGESTEUERTEN ANLAGEN - ORDNUNGSANALYSE	153



---

<b>5</b>	<b>ANWENDUNGSBEISPIELE</b>	<b>155</b>
5.1	SCHADENS- UND SENSORFEHLERERKENNUNG AN STRUKTURKOMPONENTEN	155
5.1.1	Laborstruktur mit Tripodschaden	155
5.1.2	Langzeitüberwachung der OWEA M5000-2	162
5.1.3	Schadenslokalisierung am Beispiel einer <i>Steelquake</i> -Struktur	192
5.2	SCHADENSERKENNUNG AN MASCHINENKOMPONENTEN	196
5.2.1	Innenringschaden eines Lagers beim Generator einer Pitch-Anlage	197
5.2.2	Innenringschaden an einem Lager der Zwischenwelle einer Pitch-Anlage	201
5.2.3	Sonnenradschaden am Planetengetriebe	208
<b>6</b>	<b>ZUSAMMENFASSUNG UND AUSBLICK</b>	<b>214</b>
	<b>LITERATUR</b>	<b>220</b>
	<b>ANHANG</b>	<b>229</b>

## NOMENKLATUR

Die folgende Liste enthält die Erläuterung häufig benutzter Zeichen und Symbole. Alle hier nicht aufgeführten Zeichen werden im Text an der entsprechenden Stelle erklärt.

### Symbole

$A$	Systemmatrix, Matrix mit AR-Koeffizienten
$B$	Eingangsmatrix
$B_z$	Zustandsbeobachtbarkeitsmatrix
$c$	Anzahl aller Klassen
$C$	Dämpfungsmatrix
$C_y$	Messmatrix eines Zustandsraumsystems
$C_{yy}$	Cepstrum
$d$	Dimension, Distanz
$D$	Durchgangsmatrix
$E[.]$	Erwartungswert
$f_s$	Abtastrate
$G$	Zustand-Ausgangskovarianzmatrix
$H$	Matrix mit Hankelstruktur
$J$	Verlustfunktion, Zielfunktion
$K$	Steifigkeitsmatrix, Kalman-Verstärkungsfaktor, linker Kernelraum
$K$	Kurtosis
$K_y$	Spektrale Kurtosis
$LC_{yy}$	Leistungscepstrum
$m$	Gesamtsensoranzahl
$n$	Anzahl der Freiheitsgrade
$n_c$	Anzahl aller zu klassifizierenden Daten
$n_d$	Anzahl der Modalverschiebungen
$n_e$	Elementanzahl eines FE-Modells
$n_t$	Gesamtanzahl der Datenpunkte in einer Zeitreihe
$n_\lambda$	Anzahl aller berücksichtigten Eigenwerte
$N_{EOC}$	Anzahl aller EOC
$N_D$	Anzahl aller gemessenen Datensätze
$N_f$	Anzahl aller Merkmale (eng. <i>features</i> )

---

$N_w$	Anzahl der Fenster
$p$	Modellordnung
$P(\cdot)$	Auftretenswahrscheinlichkeit
$\mathbf{Q}_w$	Kovarianzmatrix des Prozessrauschens
$\mathbf{r}$	Residuumsvektor
$r_{yy}$	Autokorrelationsfunktion
$\mathbf{R}$	Ausgangskovarianzmatrix
$\mathbf{R}_v$	Kovarianzmatrix des Messrauschens
$s$	Sensor-/Messkanalnummer, Singulärwerte
$\mathbf{S}$	Sensitivitätsmatrix, Singulärwertmatrix, Residuumskovarianzmatrix
$S_{yy}$	Leistungsdichtespektrum
$\mathbf{S}_z$	Zustandssteuerbarkeitsmatrix
$t$	Zeit
$\mathbf{U}$	Hauptkomponentenmatrix
$\mathbf{v}$	Messrauschen
$\mathbf{w}$	Prozessrauschen
$w$	Fensterfunktion
$X$	Quelle für ein Signal (z.B. Sensor)
$\mathbf{y}$	Multi- oder univariate Zeitreihe
$\mathbf{Y}$	Fourier-Transformiertes Zeitsignal
$\mathbf{z}$	Zustandsvektor, Orthogonale Basis der Hauptkomponenten
$\alpha$	Konfidenzintervall, zyklische Frequenz
$\gamma$	Zyklisches Kohärenzspektrum
$\delta$	Zeitdiskrete Eigenwerte, Kronecker Delta, Regularisierungsfaktor
$\Delta t$	Zeitinkrement
$\Delta p$	Schadensparameter
$\varepsilon$	Residuum
$\zeta$	Ortsparameter einer GEV
$\theta$	Merkmal, Merkmalsmatrix
$\lambda$	Eigenwerte, Lagrangeoperator
$\mathbf{A}$	Eigenwertmatrix
$\boldsymbol{\mu}_c$	Vektor mit Zentren der Klassen

$\boldsymbol{\mu}$	Vektor mit Erwartungswerten einer multivariaten Zeitreihe
$\mu$	Formparameter einer GEV
$\xi$	Modale Dämpfung
$\sigma$	Skalierungsparameter einer GEV
$\boldsymbol{\Sigma}$	Kovarianzmatrix
$\boldsymbol{\Phi}$	Modalmatrix
$\omega$	Eigenkreisfrequenz
$\boldsymbol{\Omega}$	Diagonalmatrix mit Eigenkreisfrequenzen
$\Omega$	Rotordrehzahl

### Indizes

$a$	Index für eine Beschleunigung
$c$	Index für ein kontinuierliches Modell
$d$	Index für ein diskretes Modell
$i$	Laufindex für die Elemente einer Klasse/Index einer Schwingungsmode
$j$	Laufindex einer Klasse, Laufindex des Schadensparameters
$k$	Laufindex von diskreten Zeitpunkten
$m$	Index für ein Modalmodell
$n_f$	Laufender Merkmalsindex
$n_m$	Laufender Index einer Messung
$ref$	Index für Referenzgrößen
$v$	Index für eine Geschwindigkeit
$x$	Index für eine Verschiebung

### Zeichen

$\tau$	transponiert
$+$	Pseudoinverse
$-1$	Inverse
$*$	Konjugiert komplex
$\dot{x}$	Erste Ableitung von $x$ nach der Zeit
$\ddot{x}$	Zweite Ableitung von $x$ nach der Zeit
$\hat{x}$	Schätzwert einer Variablen $x$
$\bar{x}$	Mittelwertfreie Zeitreihe $x$

**Abkürzungen**

AANN	Autoassoziatives Neuronales Netz
ARMA	Autoregressives Modell mit gleitendem Mittelwert
ARV	Vektor-Autoregressives Modell
CDF	Kumulative Verteilungsdichtefunktion (eng. <i>Cumulative Distribution Function</i> )
DI	Schadensindikator (eng. <i>Damage Indicator</i> )
EOC	Umgebungs- und Betriebsbedingung (eng. <i>Environmental and Operational Condition</i> )
EM	<i>Expectation Maximization</i> Algorithmus
ERA	<b>E</b> igensystem- <b>R</b> ealisierung- <b>A</b> lgorithmus
FA	Faktorenanalyse
FT	Fouriertransformation
GEV	Generalisierte Extremwert-Verteilung
KL	Kullback-Leibler-Abstand
knn	<i>k-nearest-neighbour</i> Algorithmus
MA	Modalanalyse
MAC	<i>Modal Assurance Criterion</i>
MANOVA	<i>Multivariate Analysis of Variances</i>
MDA	<i>Missing Data Analysis</i>
MFA	<i>Mixture of Factor Analysis</i>
MI	<i>Mutual Information</i>
MSF	Modaler Skalierungsfaktor
NLFA	Nicht-lineare Faktorenanalyse
NLPCA	Nicht-lineare Hauptkomponentenanalyse
NSFD	<i>Nullspace-based Fault Detection</i>
OWEA	Offshore Windenergieanlage
PCA	Hauptkomponentenanalyse (eng. <i>Principal Component Analysis</i> )
PDF	Wahrscheinlichkeitsdichtefunktion (eng. <i>Probability Density Function</i> )
SFI	Sensorfehlerindikator
SSI	<i>Stochastic Subspace Identification</i>



## **KURZFASSUNG**

Die Schadensdiagnose auf der Basis von Schwingungsmessdaten ist ein vielversprechender Ansatz zur Überwachung unterschiedlicher Struktur- und Maschinenkomponenten von „vibrationsfreudigen“ Offshore-Windenergieanlagen während des laufenden Betriebs. Die kontinuierliche Überwachung soll die Anzahl der geplanten Instandhaltungsaktionen verringern, welche besonders im Offshore-Bereich sehr kostenintensiv sind. Gleichzeitig soll eine automatisierte Schadensdiagnose auch bei wetterbedingt schlechter Erreichbarkeit der Anlagen dem Anlagenbetreiber Informationen über den Zustand der Anlage liefern und gegebenenfalls einen entsprechend dem Anlagenzustand schonenden Betrieb einleiten.

Der Fokus dieser Arbeit liegt in der Methodenentwicklung für ein Überwachungssystem hinsichtlich der Schadensfrüherkennung an Offshore-Windenergieanlagen und insbesondere in der Zustandsüberwachung von Turm, Fundament und Maschinenkomponenten der Anlage. Die Methodenentwicklung baut auf der Erweiterung und Kombination unterschiedlicher Ansätze der Datenanalyse aus Strukturdynamik, Mustererkennung, Informationstheorie und Signalanalyse auf, damit diese den spezifischen Anforderungen für den Einsatz an Offshore-Windenergieanlagen gerecht werden.

Somit wird in dieser Arbeit ein Konzept zur Strukturüberwachung mit Hilfe von gemessenen Schwingungsdaten entwickelt und implementiert. Dieses besteht aus Algorithmen zur Strukturschadensdetektion unter Berücksichtigung veränderlicher Umgebungs- und Betriebszustände der Anlage, modellgestützter Schadenslokalisierung mit Hilfe von Modaldaten und einer Sensorfehleridentifikation. Zur Maschinenüberwachung werden weitere Ansätze zur Auswertung gemessener Signale im Triebstrang von Windenergieanlagen erweitert und implementiert. Diese bestehen aus der Kombination unterschiedlicher Signalanalysemethoden im Frequenzbereich und dienen dazu, Schäden in Lagern und langsam laufenden Planetengetrieben in einem früheren Stadium als mit den bislang angewendeten Ansätzen zu entdecken.

Die entwickelten und angewendeten Methoden zur Strukturüberwachung werden mit Hilfe von Simulationsmodellen, mit Messdaten unterschiedlicher Laborstrukturen sowie Messdaten aus einem Langzeitmonitoring einer 5MW-Offshore-Prototypanlage (Areva-Multibrid M5000-2) getestet. Die Methoden zur Maschinenüberwachung werden mit Hilfe von gemessenen Signalen an unterschiedlichen Windenergieanlagen validiert.






# 1 EINLEITUNG

## 1.1 HISTORISCHE EINORDNUNG

Die industrielle Revolution und das rasante Wachstum der Weltbevölkerung in den letzten Dekaden brachten die Menschen in eine große Abhängigkeit von elektrischer Energie. Diese Energieform und allgemein die Energieressourcen bestimmen gegenwärtig unseren Lebensstandard, die Machtverhältnisse auf der Welt und werden weiter die Entwicklung unserer Zivilisation entscheidend beeinflussen. Viele bisher zur Produktion von elektrischer Energie verwendeten Ressourcen, wie z.B. die fossilen Brennstoffe, sind aber nur noch beschränkt vorhanden. Gleichzeitig repräsentieren diese, aus Sicht des Phänomens der globalen Erwärmung, eine Gefahr für das Ökosystem des Planeten. Weitere Ressourcen, wie die Kernenergie, können langfristig nur bedingt zur Stromerzeugung eingesetzt werden, da diese gesellschaftlich nicht breit akzeptiert werden und die verbleibenden „nuklearen Residuen“ gesundheitsgefährdend und nicht abbaubar sind.

Aus diesen Gründen kamen in den letzten Jahren verstärkt regenerative Energieressourcen als alternative Quellen zur Stromerzeugung in den öffentlichen Fokus. Im Jahr 2009 wurden bereits 3% der gesamten Produktion der elektrischen Energie weltweit (*OECD*<sup>1</sup>-Länder, 9794 TWh) aus erneuerbaren Quellen erzeugt [IEA 2009]. Dabei war die Windenergie nicht unbedeutend beteiligt, wie in Abbildung 1.1, Mitte, zu sehen ist. In Abbildung 1.1, rechts, ist das Potential der Windenergie durch seine relative, jährliche Wachstumsrate in der Klasse der erneuerbaren Energien in den letzten Jahren verdeutlicht, siehe auch [OBSERVER 2009] und [WWEA 2010].



**Abbildung 1.1: Quellen für die Produktion der elektrischen Energie im Jahr 2009 (links), Anteil der erneuerbaren Energiequellen an der Stromerzeugung ohne Berücksichtigung der Hydroenergie (Mitte), Jährliche Wachstumsrate für die Nutzung der Energiequellen zwischen 1998 – 2008 (rechts)**

<sup>1</sup> *Organization for Economic Co-Operation and Development*

Besonders in den reichen Ländern der Welt, die sich die Entwicklung von erneuerbaren Energien leisten können, ist schon jetzt der Anteil der Windenergie an der Gesamtstromerzeugung höher als in Abbildung 1.1 (Mitte) gezeigt. Z.B. wurde in Deutschland im Jahr 2009 6,6% des gesamten Stromverbrauchs mit erneuerbarer Energie aus Wind gedeckt [BUNR 2010].

Aus technischer Sicht wird die Energie dem Wind mittels Windenergieanlagen entzogen und in elektrische Energie umgewandelt. Historische Beispiele für die Nutzung von Wind als Energieträger finden sich bereits im 10. Jahrhundert v. Chr. in Persien (Bewässerungsanlagen mit vertikaler Rotorachse). Im frühen Mittelalter verbreiteten sich Windmühlen (mit horizontaler Rotorachse) auch in Europa. Vor allem in England und in den Niederlanden wurden sie zum Mahlen von Getreide und als Wasserpumpen eingesetzt [HEIER 2005].

Die ersten Windenergieanlagen zur Erzeugung von elektrischem Strom sind in den 1890er Jahren in Dänemark entwickelt worden. POUL LA COUR baute dort mehrere Versuchsanlagen und führte erste Tests in einem selbstgebauten Windkanal durch. Anfang des 20. Jahrhunderts erfolgte bereits eine Serienfertigung kleiner Windenergieanlagen mit einer Leistung von 10-35 KW (Firma LYKKEGARD), die zur Stromversorgung isoliert liegender Ansiedlungen eingesetzt wurden. In Deutschland untersuchte ALFRED BETZ die Physik der Windenergienutzung nach aerodynamischen Gesichtspunkten und veröffentlichte in den 1920er Jahren die Ergebnisse seiner Arbeit. Auf dieser Grundlage wurden mehrere große Versuchsanlagen geplant, deren Realisierung durch den Ausbruch des Zweiten Weltkriegs verhindert wurde [HAU 1988]. Auch in den USA wurden kleine Windenergieanlagen in Serie hergestellt, um ländliche Gebiete mit Strom zu versorgen. Daraus entstand die Idee, größere Anlagen zu bauen. PALMER PUTNAM initiierte die Entwicklung einer Versuchsanlage mit einer Nennleistung von 1,25 MW, die 1941 gebaut wurde und als erste Großanlage der Welt gilt. Nach dem Zweiten Weltkrieg fielen die Preise für fossile Energieträger und die Windenergie wurde aus wirtschaftlicher Sicht unattraktiv. Erst die Energiekrise der 70er Jahre gab der Entwicklung von Windenergieanlagen neuen Auftrieb und führte zunächst zum Bau von Versuchsanlagen, deren Leistungsabgabe sich kontinuierlich von 50 KW bis in den MW-Bereich steigerte. Die leistungsfähigeren Windenergieanlagen und das Konzept der Windparks ebneten den Weg zu einer wirtschaftlichen Nutzung der Windenergie zur Stromerzeugung [HEIER 2005].

Den gegenwärtigen Entwicklungsstand stellen Windenergieanlagen mit einer Leistung von 3 bis 7 MW dar. Diese sind in der Regel Anlagen mit horizontaler Achse mit drei Rotorblättern

und luv-laufendem Rotor (Rotor vor dem Turm in Windrichtung), die mit einer Pitchsteuerung zur Drehung der Blätter um die eigene Achse ausgestattet sind. Weitere Bauformen für unterschiedliche Anlagengrößen sind in [GASCH und TWELE 2005] detailliert beschrieben. Die Erkenntnis, dass die Windgeschwindigkeit und der Durchmesser des Rotors eine entscheidende Rolle bei der Energiegewinnung aus Wind spielen, führte dazu, dass die ökonomische Bedeutsamkeit der Offshore- gegenüber der Onshore-Windenergieanlagen (WEA) zunahm. Daher wurden in die letzten Jahre mehrere Offshore-Windparks, besonders im Nordwesten Europas, eingerichtet. Die Prognosen des Bundesministeriums für Umwelt [BUNR 2002] zeigen, dass die Windenergienutzung auf See in Deutschland bis zum Jahr 2025 einen Anteil von 15% an der Stromerzeugung, bezogen auf den heutigen Stromverbrauch, erreichen wird. Der Anteil der Windenergienutzung an Land wird voraussichtlich mit 10% deutlich unter dem der Offshore-Nutzung liegen.

Die Kosten für Montage, Inspektion und Instandhaltung einer Offshore-WEA sind jedoch viel höher als für Onshore-Windenergieanlagen. Kostenmodelle in [ODE 2007] haben gezeigt, dass auf See die Kosten für den Bau und Installation des Fundaments drastisch steigen und weitere, für den Onshore-Bereich unbekannte Kosten, wie z.B. für Transporte auf dem Meer, entstehen. Außerdem ist die Erreichbarkeit der Anlagen oftmals nur bei gutem Wetter und niedrigem Wellengang gegeben. Je nach Standort ist somit die Anlage nur für einige wenige Monate im Jahr zugänglich.


Auch aus technischer Sicht stellen Offshore-Windenergieanlagen (OWEA) eine große Herausforderung in Bezug auf Gestaltung, Konstruktion und Betrieb dar. Infolge der dynamischen Wechselwirkungen zwischen den Anlagenkomponenten stellt sich ein komplexer Belastungszustand ein, der darüber hinaus vom Standort abhängig ist. Strukturelle Belastungen von Wind und Wasserwellen und die daraus resultierenden Materialbeanspruchungen sind noch nicht vollständig bekannt. Des Weiteren gibt es zurzeit immer noch viele offene Fragen, die die Gestaltung eines sicheren und wirtschaftlichen Fundaments für OWEAs betreffen [ROHRMANN und RUECKER 2005].

Ausfälle einer OWEA, bedingt durch Reparaturen und Wartungsarbeiten, welche durch nicht rechtzeitig entdeckte Schäden und deren Folgen verursacht wurden, führen zu erheblichen wirtschaftlichen Verlusten. Aus diesem Grund besteht die Notwendigkeit, Überwachungs- und Datenbewertungssysteme zu entwickeln, welche dem Betreiber notwendige und zuverlässige Informationen über den Zustand der Anlage liefern und gegebenenfalls eine Einleitung von Wartungsarbeiten ermöglichen. Ein Überwachungssystem soll dazu dienen,

den Wartungsaufwand sowie die Wartungskosten zu senken und gleichzeitig die Betriebssicherheit zu erhöhen.

## 1.2 ALLGEMEINES ZUR SCHADENSERKENNUNG

Strukturen von OWEAs sind für eine Lebensdauer von 20 Jahren ausgelegt. Innerhalb dieser Zeit wird mit ca.  $2 \times 10^8$  Lastwechseln gerechnet. Bei der heutigen Auslegung der Anlagen können aber nicht alle Belastungsfaktoren und besonders nicht deren Reihenfolge berücksichtigt werden. So können unerwartete Schäden an Strukturkomponenten, beispielweise aus Überlasten durch Wind und Extremwellen, Schiffsaufprall oder Korrosion z.B. an den Schweißnähten, entstehen. Weitere Gründe liegen in der Auskolkung/Ausspülung des Fundaments, Überlastung durch Eisansatz an den Rotorblättern oder das Lösen von Verbindungen zwischen unterschiedlichen Turmsegmenten. Weitere unerwünschte Beanspruchungen des Turms, die letztendlich zur Ermüdung und damit zu Turmschäden führen, entstehen aus der Anregung der ersten Resonanzfrequenzen des Turms durch die periodische Wechselwirkung zwischen Rotorblättern und Turm (sog. Turm-Blatt-Passage). Abbildung 1.2 (links und Mitte) zeigt beispielhaft mögliche Schäden am Turm und Turmfundament. Die Weiterentwicklung solcher Schäden kann zu einem Totalausfall, wie in Abbildung 1.2, rechts dargestellt, führen.



**Abbildung 1.2: Turmkorrosion (links), Riss im Betonfundament (Mitte), Totalausfall einer WEA (rechts)**

Auch der Triebstrang einer WEA ist durch die Kopplung an den Rotor einem komplexen Belastungszustand ausgesetzt. Dadurch wirken sich ruckartige Bewegungen des Rotors, verursacht durch plötzlichen Seitenwind oder Extremwindböen, auch auf den Triebstrang aus. Schäden des Getriebes und der Lager treten infolge von Überbelastungen, Blitz einschlag, Überhitzungen gefolgt von Schmierungsproblemen, Fertigungsfehlern in Getriebegehäusen oder langen Stillstandzeiten der Anlage auf (das Gewicht des Rotors mit den Blättern wirkt

dabei langfristig auf nur wenige Stellen des Getriebes und des Azimuth-/Windnachführungssystems). Mögliche Schäden im Triebstrang der Anlage sind in Abbildung 1.3 dargestellt.



**Abbildung 1.3: Beschädigtes Lager eines Windnachführungssystems (links); Verzahnungsschaden des Sonnenrades eines Planetengetriebes (rechts)**

Wie bereits erläutert, lässt sich in den meisten Fällen die Entstehung von Schäden nicht vollständig vermeiden. Um trotzdem Totalausfälle oder sehr kostenintensive Reparaturarbeiten zu umgehen, sollen Früherkennungssysteme eingesetzt werden. Sie sollen das rechtzeitige Austauschen defekter Komponenten oder einen komponentenschonenden Betrieb der Anlage einleiten. Einige Grundprinzipien zur Struktur- und Maschinenschadenserkennung werden im Folgenden erläutert.

### 1.2.1 Strukturschadenserkennung

Die zurzeit meist eingesetzten und bekanntesten Verfahren zur Schadenserkennung basieren auf zerstörungsfreien Prüfverfahren (NDT-Verfahren) wie z.B. der Ultraschallprüfung, der Röntgenprüfung, etc. [HELLIER 2001]. Diese Verfahren eignen sich sehr gut zur Schadenserkennung während der Fertigungsphase von WEA-Strukturkomponenten. Sobald die WEAs an den Einsatzorten aufgestellt sind, können solche klassischen Verfahren nicht mehr wirtschaftlich eingesetzt werden. Dies liegt an der schweren Erreichbarkeit der Anlagen und der schlechten Zugänglichkeit vieler Orte, an denen ein Schaden an der OWEA am wahrscheinlichsten entstehen kann, sog. *hot spots*. Des Weiteren sind solche Verfahren ausschließlich zur Prüfung der *hot spots* geeignet, während eine sinnvolle, globale Überwachung der Gesamtanlage, bedingt durch die Konstruktion und Größe einer OWEA, nicht möglich ist.

Eine weitere Klasse von Schadensdiagnoseverfahren basiert auf der Messung der Schwingungen der Anlage mit Hilfe unterschiedlicher Sensoren wie z.B. Dehnungsmessstreifen (DMS), Beschleunigungssensoren, Neigungssensoren etc.. Diese Sensoren werden auf der OWEA fest installiert. Damit wird die Schadenserkennung eine Frage der geeigneten Analyse der kontinuierlich gemessenen Zeitdaten mit Hilfe intelligenter

Algorithmen. Die Grundidee einer Analyse der Zeitdaten mit solchen Algorithmen ist die Erkennung der Änderung des Schwingungsverhaltens aus den Messdaten infolge eines Schadens. Dadurch wird die Schadenserkennung eine Mustererkennung bzgl. des Schwingungsverhaltens der Anlage.

Diese relativ neue Klasse von Verfahren lässt sich in das Gebiet des *Structural Health Monitoring* (SHM) einordnen. Nach [RYTTER 1993] lassen sich mehrere Stufen der Schadensidentifikation definieren:

Stufe 1: Schadensdetektion

Stufe 2: Schadenslokalisierung

Stufe 3: Bestimmung des Schadensausmaßes

Stufe 4: Prognose der Restlebensdauer

In der Stufe 1 meldet die Schadensidentifikationsmethode, ob ein Schaden überhaupt vorhanden ist. Die 2. Stufe gibt Auskunft über die Position des Schadens in der Struktur. Stufe 3 ermittelt zusätzlich das Ausmaß und die Art des Schadens. Wie lange die Struktur weiter betrieben werden kann, wird von den Algorithmen der 4. Stufe bestimmt.

SHM-Methoden können je nach Größe des überwachten Gebiets in Bezug zur Gesamtstrukturgröße in globale und lokale Überwachungsmethoden unterteilt werden. Lokale Methoden nutzen z.B. hochfrequente Ultraschallwellen, deren Wellenlänge in der gleichen Größenordnung wie die zu identifizierenden Schäden liegt [GIURGIUTIU 2008; MOLL *et al.* 2010]. Dadurch sind sie sehr empfindlich gegenüber kleinen Schäden, benötigen aber ein dichtes Sensornetzwerk und Kenntnisse über die *hot spots* der Struktur. Weiterhin ist für diese Methoden eine aktive Anregung der Struktur (mindestens ein Aktor) notwendig.

Globale Methoden nutzen die tiefen Eigenschwingungsmoden der Struktur als dynamische Signatur. Diese können mit einem weit weniger dichten Sensornetzwerk arbeiten, wobei die Sensoren über die ganze Struktur verteilt sind. Es ist daher nicht notwendig, dass mögliche Schädigungsorte *a priori* bekannt sind. Auch bei diesen Methoden sind Kenntnisse über die Strukturanregung vorteilhaft, aber in vielen Fällen (auch bei OWEA) sind genaue Kenntnisse über Anregungsniveau und -ort nicht vorhanden. Dadurch basieren viele globale Methoden ausschließlich auf gemessenen Systemausgangs-Zeitdaten (hierbei wird oft angenommen, dass der Anregungsprozess z.B. ein weißes Rauschen ist). Diese globalen *Output-Only*-Methoden, die sich zur kontinuierlichen Überwachung der massiven Struktur von WEA eignen, können nach der Komplexität der Messdatenverarbeitung weiter in rein messdatenbasierte Methoden (z.B. zur Schadensdetektion mit statistischen Verfahren

[BASSEVILLE *et al.* 2000; FUGATE *et al.* 2001; SOHN *et al.* 2000; SOHN und FARRAR 2001]), oder modellbasierte Verfahren (z.B. zur Lokalisation von Schäden mit Hilfe von FE-Modellen und Modaldaten [BOHLE 2005; FRISWELL und MOTTERSHEAD 1995; FRITZEN und BOHLE 2001; NATKE 1992; NATKE und CEMPEL 1997]) unterteilt werden. Eine detaillierte Übersicht und eine klare Einteilung dieser Methoden nach unterschiedlichen Kriterien befinden sich z.B. in [BALAGEAS *et al.* 2006]. Die Anforderungen an Methoden zur Schadenserkenkung für OWEA und eine geeignete Auswahl werden in Abschnitt 3.1 beschrieben und begründet.

### **1.2.2 Schadenserkenkung an Maschinenkomponenten: die Zustandsüberwachung**

Der Betrieb von Maschinen ist i.d.R. mit der Entstehung von Schwingungen und der Schallabstrahlung verbunden. Beides sind unerwünschte Effekte, die größtenteils aus Imperfektionen resultieren [KOLERUS 2000]. Daraus lässt sich schließen, dass das Schwingungsbild in irgendeiner Weise charakteristisch für den Laufzustand einer Maschine ist und sich daher viele Fehler bereits im Frühstadium hierin widerspiegeln müssen.

Die Schwingungen breiten sich wellenartig in Form von Körperschall in der Maschine aus und werden als Luftschall an die Umgebung abgegeben. Sie setzen sich aus einer Vielzahl einzelner Schwingungskomponenten zusammen, die sich teilweise charakteristischen Frequenzen unterschiedlicher Maschinenkomponenten zuordnen lassen. Durch die Messung des Geräuschverhaltens einer Maschine können also Rückschlüsse auf eventuell auftretende Schäden an Maschinenkomponenten gezogen werden. Genauer noch: Mit der Schwingungsmessung will man Rückschlüsse auf die inneren Kräfte am Entstehungsort der Schwingungen, beispielsweise im Lager, ziehen.

Die Schwingungen können im Zeitbereich, im Frequenzbereich und im Zeit-Frequenz-Bereich [NGUYEN 2002] analysiert werden. Im Zeitbereich wird dargestellt, *wann* ein Peak auftritt, im Frequenzbereich dagegen *wie oft* ein solcher Peak vorkommt. Beide Darstellungsformen besitzen denselben Informationsgehalt. Jedoch sind Einzeleinflüsse, wie beispielsweise der Beitrag bestimmter Getriebekomponenten zum Gesamtschwingungsbild, oft im Frequenzbereich wesentlich einfacher, schneller und deutlicher zu identifizieren als im Zeitbereich. Durch den Vergleich der Peaks mit den charakteristischen Schadensfrequenzen einzelner Komponenten einer Maschine, wie z.B. den Zahneingriffswiederholffrequenzen oder den Überrollfrequenzen (siehe Anhang A1.2 und A1.3), kann eine Aussage über einen möglichen Schaden getroffen werden. Aus diesem Grund ist die Frequenzanalyse für die Zustandsüberwachung (eng. *Condition Monitoring*, CM) sehr wichtig.

### 1.3 FOKUS, BEITRAG UND STRUKTUR DER ARBEIT

Das zentrale Ziel der Arbeit ist die Methodenentwicklung für ein integriertes Überwachungssystem hinsichtlich einer Schadensfrüherkennung inklusive der Sensorselbstdiagnose von Offshore-Windenergieanlagen. Der Schwerpunkt der Entwicklung soll besonders den Turm, das Fundament und die Maschinenkomponenten in der Anlage (Lager, Getriebe) berücksichtigen. Die entwickelten Verfahren bauen auf der Erweiterung und Kombination unterschiedlicher Methoden der Datenanalyse aus der Strukturmechanik, der Informationstheorie und der Zustandsüberwachung auf, sodass diese den spezifischen Anforderungen für den Einsatz an OWEAs gerecht werden.

Zunächst werden in Kapitel 2 die erforderlichen Grundlagen erläutert. Hierbei handelt es sich um eine kurze Beschreibung linearer, zeitinvarianter Systeme im Zeit-, Zustandsraum- und Modalbereich sowie deren Identifikation bei unbekannter stochastischer Anregung. In einem nächsten Schritt werden die für die Arbeit benötigten Konzepte zur Datenanalyse in Form der Sensitivitätsanalyse, der Klassifikationsverfahren, der Hauptkomponentenanalyse und der Informationstheorie erläutert. Das Kapitel 2 endet mit der Erläuterung einiger für diese Arbeit notwendigen Methoden zur Zeitreihenanalyse im Frequenzbereich (Frequenz- und Hüllkurvenspektrumanalyse sowie Cepstrumanalyse), die als Grundlage zur Schadenserkennung an Maschinenkomponenten dienen sollen.

Den eigentlichen Beitrag und Kern der Arbeit liefert Kapitel 3. Dieses präsentiert zuerst wichtige Informationen über die Anregung und das dynamische Verhalten von OWEAs, sowie Anforderungen an Schadenserkennungsmethoden für die Anwendung an Windenergieanlagen. In einem nächsten Schritt wird das Gesamtkonzept zur Schadenserkennung an Tragstrukturen vorgestellt. Die wesentlichen Komponenten sind dabei: die Datenvorauswahl für die Schadenserkennung, die Schadensdetektion unter Berücksichtigung von veränderlichen Umgebungs- und Betriebseinflüssen (eng. *Environmental and Operational Conditions*, EOC), die modellgestützte Lokalisation mit Hilfe von Modaldaten und die Sensorfehlererkennung bzw. Signalrekonstruktion.

Für die Detektion werden geeignete Methoden für Turm und Tripod aus der Literatur und zwei weiter- bzw. neu entwickelten Methoden basierend auf Residuen von identifizierten linearen zeitinvarianten *Output-Only*-Systemen im Zeitbereich präsentiert. Diese Algorithmen berechnen kontinuierlich Schädigungsindikatoren, die den Zustand der Struktur für einen gewissen Zeitraum beschreiben und im Fall eines Strukturschadens eine voreingestellte zulässige Grenze überschreiten. Ein wichtiger Aspekt dieser Arbeit ist die Kompensation von



Einflüssen der EOCs auf die Schädigungsindikatoren. Diese wird unter Anwendung unterschiedlichen Methoden der Mustererkennung, wie z.B. Klassifikationsverfahren erreicht. Die Schadenslokalisationsmethode besteht hauptsächlich aus der Weiterentwicklung einer sensitivitäts- und modellbasierten Methode [BOHLE 2005]. Die Neuerung besteht einerseits aus der Erweiterung der Schadensparametervorselektionsverfahren um den Rückwärtsschritt bei der schrittweisen Selektion und aus der Anwendung eines Optimierungsverfahrens zur Korrektur des Linearisierungsfehlers bei der Schätzung des Schadensausmaßes. Andererseits enthält die Weiterentwicklung eine Anbindung der Algorithmen an die Berechnungsplattform FEMTools, die die Verwendung von Finite-Elemente-Modellen mit einer sehr hohen Anzahl an Freiheitsgraden und komplizierten Geometrien ermöglicht. Die Extraktion der Modaldaten, notwendig zur Charakterisierung des Schwingungsverhaltens und zur Schadenslokalisierung, basiert auf Vektor-Autoregressiven Modelle (ARV). Diese Modalanalysemethode wird für eine automatische Extraktion von Eigenfrequenzen, Dämpfungsverhältnissen und Eigenschwingungsformen der Struktur bei stochastischer Strukturanregung genutzt.

Ein weiterer Kern der Arbeit und des Kapitels 3 ist die Entwicklung neuer Ansätze, z.B. basierend auf der Informationstheorie, und die Anwendung geeigneter Methoden aus der Literatur zur Sensorfehlererkennung, sowie die Implementierung dieser in einem Gesamtüberwachungskonzept. Dieser Schritt wird als sehr wichtig eingestuft, da Sensoren, eingesetzt zur Überwachung von OWEAs, besonders rauen Bedingungen ausgesetzt sind und ihre Lebensdauer in den meisten Fällen unter der Lebenserwartung der Anlage liegt. Durch die Anwendung geeigneter Methoden zur Sensorfehlererkennung soll die Zuverlässigkeit von Langzeitüberwachungssystemen, die bei rauen Seebedingungen eingesetzt werden, deutlich erhöht werden.

Die in Kapitel 4 entwickelten und erweiterten Methoden zur Maschinenkomponentenüberwachung eignen sich besonders für langsam rotierende Komponenten von OWEAs (z.B. Planetengetriebe), für schlechte Signalübertragungswege und die dadurch ungünstigen Signal-zu-Rauschen-Verhältnisse. Hierbei handelt sich um Methoden, die bei der Überwachung von WEA bisher nicht eingesetzt worden sind. Besonders die Zyklkohärenz-Methode in Kombination mit Signalvorverarbeitungsmethoden hat sich sensitiver gegenüber Schäden in einem früheren Stadium gezeigt als die klassischen Maschinenzustandsüberwachungs-Algorithmen.


Kapitel 5 stellt zuerst Ergebnisse der Schadensdetektion unter veränderlichen EOCs und der Sensorfehlererkennung an einer Laborstruktur vor. Anschließend wird das implementierte

Gesamtüberwachungskonzept für das Monitoring des OWEA-Prototyps M5000-2 der Fa. AREVA-Multibrid, begleitet von unterschiedlichen Beispielen für die Schadensdetektion, -lokalisierung und Sensorfehlererkennung, dargestellt.

Im zweiten Teil des 5. Kapitels werden die Ergebnisse der Schadensdiagnose mit Hilfe von tatsächlichen Schäden an Planetengetrieben und unterschiedlichen Lagerschäden in Maschinenkomponenten von WEA erläutert, bevor in Kapitel 6 eine Zusammenfassung und eine Diskussion der Ergebnisse erfolgt.

#### 1.4 VORHANDENE METHODEN - LITERATURÜBERBLICK

In diesem Abschnitt werden in der Literatur beschriebene Gesamtkonzepte zur Überwachung der Struktur- und Maschinenkomponenten von OWEA vorgestellt. Die wesentlichen Komponenten einer OWEA sind dazu in Abbildung 1.4 dargestellt.



**Abbildung 1.4: Komponenten einer Offshore-Windenergieanlage am Beispiel des Prototyps M5000-2 der Fa. AREVA-Multibrid in Bremerhaven**


Weitere Methoden, die sich einzeln für bestimmte Überwachungszwecke eignen, werden separat in den entsprechenden Arbeitsabschnitten beschrieben. So wird ein Literaturüberblick

zur Schadensidentifikation an Strukturkomponenten unter veränderlichen EOCs in 3.3.1 und zur Sensorfehlererkennung in 3.5.1 gegeben.

Die Maschinenkomponenten und die Rotorblätter sind heutzutage aus der Sicht der Schadenserkennung die meist überwachten Komponenten der Anlagen. Bei den Rotorblättern handelt es sich im Wesentlichen um die Überwachung der Blatteigenfrequenzen [VOLKMER *et al.* 2006], der akustischen Emissionen [LADING *et al.* 2002], der elektromechanischen Impedanz [PITCHFORD 2007] und der Überwachung mit Hilfe von Ultraschallwellen [LADING *et al.* 2002]. Eine umfangreiche Übersicht über die erforschten Methoden zur Rotorblattüberwachung gibt [CIANG *et al.* 2008].

Getriebe und Planetengetriebe, Lager unterschiedlicher Wellen, usw. werden online und automatisch mit CM-Systemen (CMS) überwacht. In den meisten Fällen werden diese Systeme von Lager- oder Getriebeherstellern und von einigen wenigen spezialisierten Firmen für das CM für Windenergieanlagen betrieben. Die eingesetzten Methoden basieren auf der Trendbeobachtung von Crestfaktoren und Kurtosiswerten zur Schadensdetektion und auf der Beobachtung von Lager- oder Zahnradschadensüberrollfrequenzen im Frequenzbereich. Hierzu werden vor allem die Frequenz-, die Hüllkurvenspektrum- und die Cepstrumanalyse zur Schadenstypidentifikation verwendet, vgl. [KLEIN 2003], [SHAN *et al.* 1999] und [KOLERUS 2000]. Diese Methoden und ihr Automatisierungsgrad sind bisher durch die Anlagenzertifizierer, wie z.B. in [GLWIND 2007], vorgeschrieben. Sie werden von weiteren Vorschriften zur Messung von Öltemperatur und Schmiermittelzustand im Getriebe, Messungen der Windgeschwindigkeiten, etc. begleitet. Mit einer modellbasierten Überwachung des Triebstrangs beschäftigen sich z.B. [PEETERS *et al.* 2006; SCHLECHT und GUTT 2002]. Die modellgestützten Ansätze dienen jedoch vor allem zur genaueren Untersuchung der Schwingungsinteraktion zwischen Triebstrang, Rotor und Turm.

SHM von Strukturkomponenten scheint, mit Ausnahme der Rotorblätter, heutzutage den Herstellern der WEAs weniger wichtig zu sein. Dadurch wurden bislang nur wenige Systeme zur Überwachung von Turm und Fundament entwickelt. Der Grund liegt darin, dass sich bislang Rotorblätter und Maschinenkomponenten anfälliger gegenüber Schäden erwiesen haben als der Turm. Auch in [GLWIND 2007] werden nur wenige Vorschläge zum Monitoring der Strukturkomponenten gemacht, die im Wesentlichen auf der Überwachung der ersten Turmeigenfrequenz basieren. Abbildung 1.5 zeigt die Schadenshäufigkeit und die damit verbundenen Ausfallzeiten für Onshore-Windenergieanlagen zwischen 1989-2006, siehe auch [FAULSTICH *et al.* 2008].



**Abbildung 1.5: Schadenshäufigkeit und Ausfallzeit für verschiedene Komponenten von Onshore-Windenergieanlagen, nach [FAULSTICH *et al.* 2008]**

Es gibt bislang keine validierte Prognose über den Einfluss von Korrosion, Auskolkung, möglichem Schiffsaufprall und extremen Lasten von Wind und Wellen auf den Schädigungszustand von OWEA-Strukturen im Bereich des Turms und des Fundaments. Strukturschäden sollten allerdings in einem Frühstadium erkannt werden, da diese zum Totalausfall der Anlage führen können, siehe auch Abbildung 1.2.

Schadenserkennungskonzepte zum Einsatz an Offshore-Ölplattformen eignen sich nicht in allen Anforderungspunkten, siehe Abschnitt 3.1, zum Einsatz an OWEAs, da diese die veränderlichen Betriebszustände der Anlagen nicht berücksichtigen. Außerdem sind die meisten Systeme nur anhand von Simulationsmodellen getestet worden, siehe z.B. [KIM und STUBBS 1995; NICHOLS 2003]. Einige Ansätze, verwendet im Bauwesen [SCHAUMANN *et al.* 2005; THÖNS *et al.* 2008], nutzen z.B. eine probabilistische Abschätzung der Lebensdauer von WEAs mit Hilfe von sog. Schädigungsmatrizen/Schädigungsäquivalenten, die unterschiedliche, auf die Struktur einwirkende Lasten in Abhängigkeit des Strukturzustands klassifiziert. Dadurch können also die Anteile der einzelnen Lasten an der Gesamt-Schädigung bestimmt werden. Die Methode gibt jedoch keine Auskunft über Schäden, die unvorhergesehen auftreten können.

Ein Gesamtsystem zur Überwachung der Strukturkomponenten einer Windenergieanlage wurde in [ROLFES *et al.* 2006], [ROLFES *et al.* 2007], [ZERBST *et al.* 2007] und [SWARTZ *et al.* 2010] vorgeschlagen. Die Arbeitsgruppe um ROLFES nutzt zur Schadensdetektion einen Proportionalitätsfaktor zwischen der Dehnung und der Schwinggeschwindigkeit an bestimmten Stellen des Turms. Die Lokalisation von Schäden erfolgt modellgestützt „durch

Parameteridentifikation unter Einsatz eines inversen Identifikationsverfahrens“ [ZERBST *et al.* 2007].

[LANGE 2008] hat ein System zur Schadenserkennung und Lebensdauervorhersage entwickelt, welches an zwei Anlagen der Fa. Siemens bzw. Nordex eingesetzt wird. Es basiert im Wesentlichen auf der Verschiebung der aktuellen gemessenen Struktureigenfrequenzen gegenüber Referenzeigenfrequenzen. Die Restlebensdauer einer Anlage wird hier aus den gemessenen Biege- und Torsionsmomenten am Turm berechnet. Diese soll auch auf weiteren Anlagen im Park extrapoliert werden.

In [KRAEMER und FRITZEN 2007a], [KRAEMER und FRITZEN 2008a], [FRITZEN *et al.* 2008], [KRAEMER und FRITZEN 2008c], [FRITZEN *et al.* 2010a] und [FRITZEN *et al.* 2010b] wird ein integrales Überwachungssystem bestehend aus drei Hauptmodulen vorgestellt:

- automatische Schadensdetektion unter Berücksichtigung von EOC-Einflüssen,
- Sensorfehlererkennung,
- modellgestützte Schadenslokalisierung mit Hilfe einer inversen Sensitivitätsmethode und Modaldaten.

Die theoretischen Grundlagen, die zum Verständnis dieses Überwachungssystems benötigt werden, sind im nachfolgenden Kapitel ausführlich dargestellt.

## 2 THEORETISCHE GRUNDLAGEN UND BASISWERKZEUGE

In diesem Kapitel werden die für diese Arbeit erforderlichen Grundlagen vorgestellt. Die Abschnitte 2.1 und 2.2 beschreiben lineare, zeitinvariante Systeme im Zeit-, Zustandsraum- und Modalbereich sowie deren Identifikation bei unbekannter, stochastischer Anregung. Diese Grundlagen werden im Verlauf der Arbeit bei der Modalanalyse und zum Aufbau von Schadensdetektionsalgorithmen und Simulationsmodellen benötigt. Der Abschnitt 2.3 beschreibt die Sensitivitätsanalyse von Modaldaten und stellt eine Grundlage zur Schadenslokalisierung aus Abschnitt 3.4.2 vor. In Abschnitt 2.4 werden Werkzeuge zur Datenanalyse bereitgestellt, die im Wesentlichen im 3. Kapitel zur Kompensation der Umgebungseinflüsse auf die Schädigungsindikatoren und zur Sensorfehleridentifikation benötigt werden.

Schließlich beschreibt Abschnitt 2.5 die heutzutage bekanntesten Werkzeuge zur Schadenserkennung an Maschinenkomponenten. Diese werden zur Erläuterung der Zyklkohärenz-Methode aus Kapitel 4 und zur Gegenüberstellung der Ergebnisse unterschiedlicher CM-Methoden anhand von Anwendungsbeispielen im Abschnitt 5.2 benötigt.

### 2.1 BESCHREIBUNG DYNAMISCHER SYSTEME IM ZEITBEREICH

Die Dynamik eines nicht-linearen, zeitvariant angeregten Systems, kann mit Hilfe folgender Bewegungs- und Schadensevolutionsgleichungen (siehe [FRITZEN 2006] in Kapitel 2 von [BALAGEAS *et al.* 2006]) beschrieben werden:

$$\mathbf{M}(\boldsymbol{\theta}_d, \boldsymbol{\theta}_e, \mathbf{x}, t) \ddot{\mathbf{x}} + \mathbf{g}(\boldsymbol{\theta}_d, \boldsymbol{\theta}_e, \mathbf{x}, \dot{\mathbf{x}}, t) = \mathbf{f}(\boldsymbol{\theta}_d, \boldsymbol{\theta}_e, t), \quad (2.1)$$

$$\dot{\boldsymbol{\theta}}_d = \boldsymbol{\Gamma}(\boldsymbol{\theta}_d, \boldsymbol{\theta}_e, \mathbf{x}, \dot{\mathbf{x}}, t), \quad (2.2)$$

$$\mathbf{y}(t) = \mathbf{h}(\boldsymbol{\theta}_d, \boldsymbol{\theta}_e, \mathbf{x}, \dot{\mathbf{x}}, t). \quad (2.3)$$

Hierbei sind  $\mathbf{M}$  die Massenmatrix,  $\mathbf{g}$  der Vektor der elastischen Kräfte, der Dämpfungskräfte, etc. und  $\mathbf{f}$  der Vektor der äußeren Kräfte.  $\ddot{\mathbf{x}}$ ,  $\dot{\mathbf{x}}$ ,  $\mathbf{x}$  sind die Beschleunigungs-, Geschwindigkeits- und Verschiebungsvektoren.  $\boldsymbol{\theta}_d$  ist ein von der Zeit  $t$  abhängiger Schädigungsparameter und  $\boldsymbol{\theta}_e$  sind die zeitlich veränderlichen Umgebungseinflüsse, wie Temperaturänderungen, ambienten Anregungen, veränderliche Randbedingungen, etc.. Die i. A. nicht-lineare Funktion  $\boldsymbol{\Gamma}$  beschreibt die Entwicklung des Schädigungsparameters  $\boldsymbol{\theta}_d$ , z.B. eine Rissausbreitung, ein Verlust in der Steifigkeit oder Masse, etc.. Die Messgleichung (2.3)

repräsentiert die gemessene Strukturantwort  $\mathbf{y}$ , welche in einem nicht-linearen und zeitvarianten Zusammenhang  $\mathbf{h}$  zu  $\boldsymbol{\theta}_d, \boldsymbol{\theta}_e, \mathbf{x}, \dot{\mathbf{x}}$  und  $t$  steht, vgl. [BALAGEAS *et al.* 2006].

Wenn die Messdatenaufnahme innerhalb eines kurzen Zeitraumes erfolgt, können die Parameter  $\boldsymbol{\theta}_d$  und  $\boldsymbol{\theta}_e$  während der Datenaufnahme als konstant angenommen werden. Unter diesen Annahmen kann die Schädigungsentwicklungsgleichung (2.2) vernachlässigt werden. Ist das dynamische Verhalten des Systems zusätzlich linear, kann es durch die lineare Bewegungsgleichung beschrieben werden:

$$\mathbf{M}\ddot{\mathbf{x}} + \mathbf{C}\dot{\mathbf{x}} + \mathbf{K}\mathbf{x} = \mathbf{f}(t). \quad (2.4)$$

$\mathbf{C}$  und  $\mathbf{K}$  sind die Dämpfungs- und die Steifigkeitsmatrix des linearen Systems. Sie haben die Dimension  $n \times n$ , wobei  $n$  die Anzahl der Systemfreiheitsgrade ist. Oft wird zur Vereinfachung die Dämpfungsmatrix in Abhängigkeit der Massen- und Steifigkeitsmatrix mit Hilfe der skalaren Größen  $\alpha$  und  $\beta$  beschrieben (proportionale Dämpfung):

$$\mathbf{C} = \alpha \mathbf{M} + \beta \mathbf{K}. \quad (2.5)$$

Wenn das System nur schwach gedämpft ist, wie z.B. bei Stahlkonstruktionen, dann werden die dynamischen Eigenschaften des Systems durch die Eigenkreisfrequenzen  $\omega_i$  und die Eigenformen  $\boldsymbol{\varphi}_i$  mit Hilfe des konservativen Eigenwertproblems ausreichend charakterisiert:

$$[\mathbf{K} - \omega_i^2 \mathbf{M}] \boldsymbol{\varphi}_i = 0. \quad (2.6)$$

Die Orthogonalitätsbeziehungen der Eigenvektoren aus Gl. (2.6) können zur Normierung der Massen- und Steifigkeitsmatrizen auf die generalisierten Massen  $M_i$  und die generalisierten Steifigkeiten  $K_i$  verwendet werden:

$$\begin{aligned} \boldsymbol{\varphi}_j^T \mathbf{M} \boldsymbol{\varphi}_i &= 0, & \forall i \neq j \\ \boldsymbol{\varphi}_i^T \mathbf{M} \boldsymbol{\varphi}_i &= M_i = 1 \end{aligned} \quad (2.7)$$

und

$$\begin{aligned} \boldsymbol{\varphi}_j^T \mathbf{K} \boldsymbol{\varphi}_i &= 0, & \forall i \neq j \\ \boldsymbol{\varphi}_i^T \mathbf{K} \boldsymbol{\varphi}_i &= K_i = \omega_i^2. \end{aligned} \quad (2.8)$$

Die Änderung der Systemeigenschaften bei linearen dynamischen Systemen lässt sich daher auf die Änderung der Steifigkeits- oder Massenmatrix zurückführen. Dadurch kann das

Schadensidentifikationsproblem (z.B. Änderung der Steifigkeit infolge eines Schadens) im Zeitbereich in ein Problem der Systemidentifikation überführt werden. Hierfür eignet sich die Umschreibung der Bewegungsgleichungen in die Zustandsraumdarstellung [JUANG 1994].

### 2.1.1 Zeitkontinuierliches Zustandsraummodell

Der Zustand  $z$  eines mechanischen Systems kann durch seinen Verschiebungs- und Geschwindigkeitsvektor eindeutig beschrieben werden:

$$z = \begin{pmatrix} \mathbf{x} \\ \dot{\mathbf{x}} \end{pmatrix}. \quad (2.9)$$

Die Multiplikation der Gl. (2.4) mit der Inversen der Massenmatrix ergibt:

$$\ddot{\mathbf{x}} = -\mathbf{M}^{-1}\mathbf{C}\dot{\mathbf{x}} - \mathbf{M}^{-1}\mathbf{K}\mathbf{x} + \mathbf{M}^{-1}\mathbf{B}_u\mathbf{u}, \quad (2.10)$$

wobei der Kraftvektor  $\mathbf{f}$  durch folgendes Produkt ersetzt wurde:

$$\mathbf{f}(t) = \mathbf{B}_u\mathbf{u}(t). \quad (2.11)$$

Hierbei ist  $\mathbf{B}_u$  eine Matrix der Dimension  $n \times n_u$  welche diejenigen Freiheitsgrade  $n_u$  beinhaltet, an denen die Systemeingangsgrößen  $\mathbf{u}$  (Anregungssignale) angreifen. Das Einfügen von Gl. (2.10) in (2.9) ergibt die Systemgleichungen in der Zustandsraumdarstellung:

$$\dot{z} = \underbrace{\begin{bmatrix} \mathbf{0} & \mathbf{I} \\ -\mathbf{M}^{-1}\mathbf{K} & -\mathbf{M}^{-1}\mathbf{C} \end{bmatrix}}_{\mathbf{A}_c} z + \underbrace{\begin{bmatrix} \mathbf{0} \\ \mathbf{M}^{-1}\mathbf{B}_u \end{bmatrix}}_{\mathbf{B}_c} \mathbf{u}(t). \quad (2.12)$$

Die  $2n \times 2n$  Matrix  $\mathbf{A}_c$  ist die Systemmatrix und die  $2n \times n_u$  Matrix  $\mathbf{B}_c$  die Eingangsmatrix. Der Index  $c$  gibt an, dass Gl. (2.12) für den kontinuierlichen Zeitbereich formuliert ist.

Wenn die Antwort des Systems an  $m$  Stellen gemessen wird, kann die Messgleichung wie folgt geschrieben werden:

$$\mathbf{y} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{C}_a \end{bmatrix} \ddot{\mathbf{x}} + \begin{bmatrix} \mathbf{0} \\ \mathbf{C}_v \\ \mathbf{0} \end{bmatrix} \dot{\mathbf{x}} + \begin{bmatrix} \mathbf{C}_x \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix} \mathbf{x}, \quad (2.13)$$

wobei  $\mathbf{y}$  den Systemausgang repräsentiert und  $\mathbf{C}_x$ ,  $\mathbf{C}_v$ ,  $\mathbf{C}_a$  die Auswahlmatrizen (beinhalten die Messfreiheitsgrade des Systems) für die entsprechenden Komponenten des Verschiebungs-,



Geschwindigkeits- und Beschleunigungsvektors sind. Mit Gl. (2.10) folgt aus (2.13) die Messgleichung in der Zustandsraumdarstellung:

$$\begin{aligned}
 \mathbf{y} &= \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{C}_a \end{bmatrix} \mathbf{M}^{-1} [\mathbf{B}_u \mathbf{u} - \mathbf{C} \dot{\mathbf{x}} - \mathbf{K} \mathbf{x}] + \begin{bmatrix} \mathbf{0} \\ \mathbf{C}_v \\ \mathbf{0} \end{bmatrix} \dot{\mathbf{x}} + \begin{bmatrix} \mathbf{C}_x \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix} \mathbf{x}, \\
 \mathbf{y} &= \underbrace{\begin{bmatrix} \mathbf{C}_x & \mathbf{0} \\ \mathbf{0} & \mathbf{C}_v \\ -\mathbf{C}_a \mathbf{M}^{-1} \mathbf{K} & -\mathbf{C}_a \mathbf{M}^{-1} \mathbf{C} \end{bmatrix}}_{\mathbf{C}_y} \underbrace{\begin{bmatrix} \mathbf{x} \\ \dot{\mathbf{x}} \end{bmatrix}}_{\mathbf{z}} + \underbrace{\begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{C}_a \mathbf{M}^{-1} \mathbf{B}_u \end{bmatrix}}_{\mathbf{D}} \mathbf{u} = \mathbf{C}_y \mathbf{z} + \mathbf{D} \mathbf{u}.
 \end{aligned} \tag{2.14}$$

Hier ist  $\mathbf{C}_y$  die Ausgangsmatrix mit der Dimension  $m \times 2n$  und  $\mathbf{D}$  die Durchgangsmatrix mit der Dimension  $m \times n_u$ .

### 2.1.2 Zustandsraummodell in Modalkoordinaten

Die Lösung des dynamischen Problems in der nodalen Darstellung eines Zustandsraummodells nach Gl. (2.12) und (2.14) ist nur dann sinnvoll, wenn das Modell relativ wenige Freiheitsgrade besitzt, da z.B. der Zustandsraum eines FE-Modells mit  $n$  Freiheitsgraden die Lösung von  $2n$  Differenzialgleichungen beansprucht. Ein alternativer Ansatz, der oft bei der Darstellung komplexer, dynamischer Strukturen angewendet wird, ist die Transformation des Modells in Modalkoordinaten [GAWRONSKI 2004]. Dadurch wird eine starke Reduktion der Systemordnung erreicht und die Anzahl der Differenzialgleichungen ist von der Anzahl der betrachteten Moden des Systems abhängig.

Die Moden und Eigenfrequenzen eines dynamischen Modells werden aus dem Eigenwertproblem der Gleichung (2.6) berechnet. Die Eigenkreisfrequenzen werden in einer Diagonalmatrix  $\mathbf{\Omega}$

$$\mathbf{\Omega} = \begin{bmatrix} \omega_1 & 0 & \cdots & 0 \\ 0 & \omega_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \omega_n \end{bmatrix} \tag{2.15}$$

und die Eigenvektoren des Systems in einer Modalmatrix  $\mathbf{\Phi}$

$$\Phi = [\varphi_1 \quad \varphi_2 \quad \cdots \quad \varphi_n] = \begin{bmatrix} \varphi_{11} & \varphi_{21} & \cdots & \varphi_{1n} \\ \varphi_{21} & \varphi_{22} & \cdots & \varphi_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \varphi_{n_d1} & \varphi_{n_d2} & \cdots & \varphi_{n_dn} \end{bmatrix}, \quad (2.16)$$

zusammengefasst, wobei  $n_d$  die Anzahl der ausgewählten Modalverschiebungen in einer Schwingungsform repräsentiert.

Mit Hilfe der Modalmatrix und unter der Annahme eines proportionalen Dämpfungsansatzes, vgl. Gl. (2.5), können nun die Massen-, Steifigkeits- und Dämpfungsmatrizen diagonalisiert

$$M_m = \Phi^T M \Phi, \quad K_m = \Phi^T K \Phi, \quad C_m = \Phi^T C \Phi \quad (2.17)$$

und die Bewegungsgleichungen für  $\mathbf{x} = \Phi \mathbf{x}_m$  in Modalkoordinaten (Index  $m$ ) umgestellt werden:

$$\underbrace{\Phi^T M \Phi}_{M_m} \ddot{\mathbf{x}}_m + \underbrace{\Phi^T C \Phi}_{C_m} \dot{\mathbf{x}}_m + \underbrace{\Phi^T K \Phi}_{K_m} \mathbf{x}_m = \Phi^T \mathbf{B}_u \mathbf{u}$$

$$\mathbf{y} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{C}_a \end{bmatrix} \Phi \ddot{\mathbf{x}}_m + \begin{bmatrix} \mathbf{0} \\ \mathbf{C}_v \\ \mathbf{0} \end{bmatrix} \Phi \dot{\mathbf{x}}_m + \begin{bmatrix} \mathbf{C}_x \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix} \Phi \mathbf{x}_m. \quad (2.18)$$

Durch die Multiplikation der ersten Gl. (2.18) von links mit  $M_m^{-1}$  unter Berücksichtigung von

$$\Omega^2 = M_m^{-1} K_m \quad \text{und} \quad \mathbf{Z} = \frac{1}{2} M_m^{-1} C_m \Omega^{-1}, \quad (2.19)$$

wobei

$$\mathbf{Z} = \begin{bmatrix} \xi_1 & 0 & \cdots & 0 \\ 0 & \xi_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \xi_n \end{bmatrix} \quad (2.20)$$

die modale Dämpfungsmatrix ist, kann die Gl. (2.18) wie folgt umgeschrieben werden:

$$\ddot{\mathbf{x}}_m + 2\mathbf{Z}\Omega \dot{\mathbf{x}}_m + \Omega^2 \mathbf{x}_m = M_m^{-1} \Phi^T \mathbf{B}_u \mathbf{u}. \quad (2.21)$$

Somit können die Bewegungsgleichungen in Modalkoordinaten nur mit Hilfe der Modalmassen und identifizierter Systemeigenschaften, in Form von Eigenfrequenzen, Eigenformen und modalen Dämpfungen  $\xi$ , aufgestellt werden. Die Beschreibung der Gleichungen im

Zustandsraum erfolgt mit Hilfe des schon für Gl. (2.9) und (2.10) beschriebenen Formalismus. Die Systemmatrizen des Modalmodells sind in Gl. (2.22)-(2.25) dargestellt:

$$\mathbf{A}_m = \begin{bmatrix} \mathbf{0} & \mathbf{I} \\ -\mathbf{M}_m^{-1}\mathbf{K}_m & -\mathbf{M}_m^{-1}\mathbf{C}_m \end{bmatrix} = \begin{bmatrix} \mathbf{0} & \mathbf{I} \\ -\boldsymbol{\Omega}^2 & -2\mathbf{Z}\boldsymbol{\Omega} \end{bmatrix} \quad (2.22)$$

$$\mathbf{B}_m = \begin{bmatrix} \mathbf{0} \\ \mathbf{M}_m^{-1}\boldsymbol{\Phi}^T \mathbf{B}_u \end{bmatrix} \quad (2.23)$$

$$\mathbf{C}_{ym} = \begin{bmatrix} \mathbf{C}_x\boldsymbol{\Phi} & \mathbf{0} \\ \mathbf{0} & \mathbf{C}_v\boldsymbol{\Phi} \\ -\mathbf{C}_a\boldsymbol{\Phi}\mathbf{M}_m^{-1}\mathbf{K}_m & -\mathbf{C}_a\boldsymbol{\Phi}\mathbf{M}_m^{-1}\mathbf{C}_m \end{bmatrix} = \begin{bmatrix} \mathbf{C}_x\boldsymbol{\Phi} & \mathbf{0} \\ \mathbf{0} & \mathbf{C}_v\boldsymbol{\Phi} \\ -\mathbf{C}_a\boldsymbol{\Phi}\boldsymbol{\Omega}^2 & -\mathbf{C}_a\boldsymbol{\Phi}2\mathbf{Z}\boldsymbol{\Omega} \end{bmatrix} \quad (2.24)$$

$$\mathbf{D}_m = [\mathbf{0} \quad \mathbf{0} \quad \mathbf{C}_a\boldsymbol{\Phi}\mathbf{M}_m^{-1}\boldsymbol{\Phi}^T \mathbf{B}_u]^T. \quad (2.25)$$

### 2.1.3 Zeitdiskretes Zustandsraummodell

Bei Messungen an realen Strukturen werden die Zeitreihen in äquidistanten Zeitabständen  $\Delta t$  mit Hilfe eines AD-Wandlers digital erfasst. Dadurch ist die Zeitachse nicht mehr kontinuierlich und die Daten sind nur an den diskreten Zeitpunkten  $t_k$ ,  $k=0\dots n_t$  mit  $t_k = k\Delta t$  vorhanden. Die Abtastrate einer Messung wird mit  $f_s = 1/\Delta t$  bezeichnet.

Wenn der Anfangszustandsraumvektor  $\mathbf{z}_0$  bekannt ist, dann kann Gleichung (2.12) für eine diskrete Zeit  $t$  wie folgt gelöst werden:

$$\mathbf{z}(t) = e^{\mathbf{A}_c(t-t_0)}\mathbf{z}_0 + \int_{t_0}^t e^{\mathbf{A}_c(t-\tau)}\mathbf{B}_c\mathbf{u}(\tau)d\tau. \quad (2.26)$$

Gl. (2.26) beschreibt die Evolution des Zustandsvektors  $\mathbf{z}(t)$ , angefangen von  $\mathbf{z}_0$  unter der Einwirkung des Eingangssignals  $\mathbf{u}(t)$ . Der Zustand des Systems zum Zeitpunkt  $t_{k+1} = (k+1)\Delta t$  mit  $\Delta t = t_{k+1} - t_k$  lautet:

$$\mathbf{z}(t_{k+1}) = e^{\mathbf{A}_c\Delta t}\mathbf{z}_k + \int_{t_k}^{t_{k+1}} e^{\mathbf{A}_c(t-\tau)}\mathbf{B}_c\mathbf{u}(\tau)d\tau. \quad (2.27)$$

Die Integration der Gleichungen (2.26) und (2.27) benötigt das kontinuierliche Eingangssignal  $\mathbf{u}$ . Unter der Annahme, dass  $\mathbf{u}(\tau)$  konstant zwischen den Zeitintervallen ist, kann

$\mathbf{u}(\tau) = \mathbf{u}(k\Delta t)$  für  $k\Delta t \leq \tau < (k+1)\Delta t$  gesetzt werden. Bei Berücksichtigung der Substitution  $\tau' = (k+1)\Delta t - \tau$  ergibt sich für Gleichung (2.27) folgender Ausdruck:

$$\mathbf{z}(t_{k+1}) = \underbrace{e^{A_c \Delta t}}_{\mathbf{A}_d} \mathbf{z}_k + \underbrace{\int_{t_k}^{t_{k+1}} e^{A_c \Delta t} \mathbf{B}_c d\tau'}_{\mathbf{B}_d} \mathbf{u}(t_k). \quad (2.28)$$

Mit  $\mathbf{z}(t_k) = \mathbf{z}(k\Delta t) = \mathbf{z}_k$  und  $\mathbf{u}(t_k) = \mathbf{u}(k\Delta t) = \mathbf{u}_k$  können die Gleichungen des zeitdiskreten Zustandsraummodells in einer kompakten Form geschrieben werden:

$$\begin{aligned} \mathbf{z}_{k+1} &= \mathbf{A}_d \mathbf{z}_k + \mathbf{B}_d \mathbf{u}_k \\ \mathbf{y}_k &= \mathbf{C}_y \mathbf{z}_k + \mathbf{D} \mathbf{u}_k. \end{aligned} \quad (2.29)$$

Der Index  $d$  in Gleichung (2.29) kennzeichnet den diskreten Zeitbereich.

### 2.1.3.1 Modale Darstellung von zeitdiskreten dynamischen Systemen

Die modalen Eigenschaften des Systems können mit Hilfe der zeitdiskreten Systemmatrix  $\mathbf{A}_d$  bestimmt werden. Das Lösen des Eigenwertproblems [EWINS 2000; HEYLEN *et al.* 1998]

$$(\mathbf{A}_d - \delta_i \mathbf{I}) \boldsymbol{\psi}_i = \mathbf{0} \quad (2.30)$$

liefert die komplexen Eigenwerte  $\boldsymbol{\Delta} = \text{diag}\{\delta_1, \delta_2, \dots\}$  und die komplexen Eigenvektoren, die in der Matrix  $\boldsymbol{\Psi} = [\boldsymbol{\psi}_1, \boldsymbol{\psi}_2, \dots]$  spaltenweise angeordnet sind. Die Matrix

$$\boldsymbol{\Phi} = \mathbf{C}_y \boldsymbol{\Psi} \quad (2.31)$$

gibt Auskunft über die Eigenformen des Systems an den Messstellen. Die Eigenkreisfrequenzen  $\omega_i$  und Dämpfungsverhältnisse  $\xi_i$  des Systems erhält man durch Transformation der Eigenwerte aus dem diskreten in den kontinuierlichen Zeitbereich:

$$\lambda_i = \frac{\ln(\delta_i)}{\Delta t} = -\xi_i \omega_i \pm j \sqrt{1 - \xi_i^2} \omega_i, \quad (2.32)$$

### 2.1.3.2 Zeitdiskrete Modelle mit stochastischer Anregung und Rauschen

Wenn ein System nicht deterministisch, sondern stochastisch angeregt wird und die Eingangsgrößen des Systems nicht bekannt sind, dann gelten für die Zustandsraumdarstellung eines solchen Prozesses die folgenden Gleichungen:

$$\begin{aligned} \mathbf{z}_{k+1} &= \mathbf{A}_d \mathbf{z}_k + \mathbf{w}_k \\ \mathbf{y}_k &= \mathbf{C}_y \mathbf{z}_k + \mathbf{v}_k \end{aligned} \quad (2.33)$$

Hierbei ist  $\mathbf{w}_k$  das stochastische Anregungssignal, welches auch als Prozessrauschen bezeichnet wird. Diese Anregung kann durch Wind-, Wellenlasten, etc. entstehen.  $\mathbf{v}_k$  repräsentiert das Messrauschen. Beide Rauschprozesse sind nicht messbar und es wird angenommen, dass es sich um stationäres, mittelwertfreies und unkorreliertes weißes Rauschen mit den Erwartungswerten

$$E\left[\begin{pmatrix} \mathbf{w}_k \\ \mathbf{v}_k \end{pmatrix}\right] = 0 \text{ und } E\left[\begin{pmatrix} \mathbf{w}_k \\ \mathbf{v}_k \end{pmatrix} \begin{pmatrix} \mathbf{w}_{k+q}^T & \mathbf{v}_{k+q}^T \end{pmatrix}\right] = \begin{pmatrix} \mathbf{Q} & \mathbf{N} \\ \mathbf{N}^T & \mathbf{R} \end{pmatrix} \delta_{k,k+q} \quad (2.34)$$

handelt. In Gl. (2.34) repräsentiert  $\delta_{k,k+q}$  das Kronecker-Delta. Weitere Eigenschaften aus der Annahme einer stochastischen Anregung lassen sich wie folgt ableiten:

$$E[\mathbf{z}_k \mathbf{w}_k^T] = 0, \quad E[\mathbf{z}_k \mathbf{v}_k^T] = 0, \quad E[\mathbf{v}_{k+1} \mathbf{y}_k^T] = 0, \quad E[\mathbf{w}_{k+1} \mathbf{y}_k^T] = 0. \quad (2.35)$$

Solche Systeme, bei denen die Eingangsgrößen nicht (deterministisch) bekannt bzw. erfassbar sind, werden in der Literatur [PEETERS und DE ROECK 1999], [PEETERS und DE ROECK 2001] als *Output-Only*-Systeme bezeichnet.

## 2.2 IDENTIFIKATION LINEARER SYSTEME IM ZEITBEREICH BEI STOCHASTISCHER ANREGUNG

### 2.2.1 Stochastic Subspace Identification - Methode

Die *Stochastic Subspace Identification* (SSI) - Methode [PEETERS und DE ROECK 1999], [PEETERS 2000], [PEETERS und DE ROECK 2001] ist eine *Output-Only*-Systemidentifikationsmethode, die aus dem Eigensystem-Realisierungs-Algorithmus (ERA) zur Identifikation linearer Systeme unter Impulsanregung hergeleitet wurde [JUANG 1994]. SSI basiert auf den Annahmen aus Gl. (2.33) und (2.34), sowie auf der Definition der Ausgangskovarianzmatrizen für den aktuell betrachteten Zeitversatz  $i$

$$\mathbf{R}_i = E[\mathbf{y}_{k+i} \mathbf{y}_k^T] \quad (2.36)$$

und der Zustands-Ausgangs-Kovarianzmatrix

$$\mathbf{G} = E[\mathbf{z}_{k+1} \mathbf{y}_k^T]. \quad (2.37)$$

Die Multiplikation der Messgleichung aus Gl. (2.33) von rechts mit  $\mathbf{y}_k^T$  unter Berücksichtigung der Annahmen in Gl. (2.35) führt zur Kopplung der Kovarianzmatrizen aus der Gl. (2.36) und (2.37) über die System- und Messmatrix:

$$\mathbf{R}_i = \mathbf{C}_y \mathbf{A}_d^{i-1} \mathbf{G}. \quad (2.38)$$

Diese Beziehung kann zur Identifikation der zeitdiskreten System- und Messmatrix verwendet werden. Dabei wird Gebrauch von der Zustandsbeobachtbarkeitsmatrix  $\mathbf{B}_z$

$$(\mathbf{B}_z)_{\tilde{\alpha}} = \begin{bmatrix} \mathbf{C}_y \\ \mathbf{C}_y \mathbf{A}_d \\ \mathbf{C}_y \mathbf{A}_d^2 \\ \vdots \\ \mathbf{C}_y \mathbf{A}_d^{\tilde{\alpha}-1} \end{bmatrix} \quad (2.39)$$

und der Zustandssteuerbarkeitsmatrix  $\mathbf{S}_z$

$$(\mathbf{S}_z)_{\tilde{\beta}} = [\mathbf{G} \quad \mathbf{A}_d \mathbf{G} \quad \mathbf{A}_d^2 \mathbf{G} \quad \dots \quad \mathbf{A}_d^{\tilde{\beta}-1} \mathbf{G}] \quad (2.40)$$

gemacht.  $\tilde{\alpha}$  und  $\tilde{\beta}$  bezeichnen die Anzahl der Zeitverschiebungen in der Beobachtbarkeits- bzw. Steuerbarkeitsmatrix [MENGELKAMP 2006]. Die Multiplikation der Zustandsbeobachtbarkeits- mit der Zustandssteuerbarkeitsmatrix ergibt die Matrix  $\mathbf{H}$  mit einer HANKEL-Struktur, die aus Ausgangskovarianzmatrizen aufgebaut ist.

$$\begin{aligned} (\mathbf{B}_z)_{\tilde{\alpha}} (\mathbf{S}_z)_{\tilde{\beta}} &= (\mathbf{H}_{\tilde{\alpha}, \tilde{\beta}})_0 = \begin{bmatrix} \mathbf{C}_y \mathbf{G} & \mathbf{C}_y \mathbf{A}_d \mathbf{G} & \dots & \mathbf{C}_y \mathbf{A}_d^{\tilde{\beta}-1} \mathbf{G} \\ \mathbf{C}_y \mathbf{A}_d \mathbf{G} & \mathbf{C}_y \mathbf{A}_d^2 \mathbf{G} & \dots & \mathbf{C}_y \mathbf{A}_d^{\tilde{\beta}} \mathbf{G} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{C}_y \mathbf{A}_d^{\tilde{\alpha}-1} \mathbf{G} & \mathbf{C}_y \mathbf{A}_d^{\tilde{\alpha}} \mathbf{G} & \dots & \mathbf{C}_y \mathbf{A}_d^{\tilde{\alpha}+\tilde{\beta}-2} \mathbf{G} \end{bmatrix} \\ &= \begin{bmatrix} \hat{\mathbf{R}}_1 & \hat{\mathbf{R}}_2 & \dots & \hat{\mathbf{R}}_{\tilde{\beta}} \\ \hat{\mathbf{R}}_2 & \hat{\mathbf{R}}_3 & \dots & \hat{\mathbf{R}}_{1+\tilde{\beta}} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\mathbf{R}}_{\tilde{\alpha}} & \hat{\mathbf{R}}_{1+\tilde{\alpha}} & \dots & \hat{\mathbf{R}}_{\tilde{\alpha}+\tilde{\beta}-1} \end{bmatrix}. \end{aligned} \quad (2.41)$$

Aus Gl. (2.41) lässt sich die allgemeine Schreibweise für die Hankelmatrix<sup>1</sup> herleiten:

---

<sup>1</sup> Aus Übersichtlichkeitsgründen werden bei weiteren Darstellungen der Hankelmatrix die Indizes  $\tilde{\alpha}$ ,  $\tilde{\beta}$  nicht mehr aufgeführt.

$$(\mathbf{H}_{\tilde{\alpha}, \tilde{\beta}})_{i-1} = \begin{bmatrix} \hat{\mathbf{R}}_i & \hat{\mathbf{R}}_{i+1} & \cdots & \hat{\mathbf{R}}_{i+\tilde{\beta}-1} \\ \hat{\mathbf{R}}_{i+1} & \hat{\mathbf{R}}_{i+2} & \cdots & \hat{\mathbf{R}}_{i+\tilde{\beta}} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\mathbf{R}}_{i+\tilde{\alpha}-1} & \cdots & \cdots & \hat{\mathbf{R}}_{i+\tilde{\alpha}+\tilde{\beta}-2} \end{bmatrix}. \quad (2.42)$$

Die Schätzung der Ausgangskovarianzmatrizen  $\hat{\mathbf{R}}$  aus gemessenen Zeitdaten erfolgt unter der Annahme ergodischer Verhältnisse:

$$\hat{\mathbf{R}}_i = \frac{1}{n_t - i - 1} \sum_{k=1}^{n_t - i} \mathbf{y}_{k+i} \mathbf{y}_k^T. \quad (2.43)$$

Hierbei ist  $n_t$  die Anzahl der Zeitpunkte, die von einem Sensor innerhalb einer Messperiode aufgenommen werden.

Die Information aus Gl. (2.41) lässt sich jetzt für die Bestimmung der Matrizen  $\mathbf{B}_z$  und  $\mathbf{S}_z$  nutzen. Beide Matrizen werden mit Hilfe einer Singulärwertzerlegung der Matrix

$$\mathbf{H}_0 = \mathbf{U} \mathbf{S} \mathbf{V}^T \quad \text{mit} \quad \mathbf{S} = \begin{bmatrix} s_1 & 0 & 0 \\ 0 & s_2 & 0 \\ 0 & 0 & \ddots \end{bmatrix} \quad (2.44)$$

berechnet, wobei  $\mathbf{U}$  und  $\mathbf{V}$  orthonormale Matrizen sind, d.h.  $\mathbf{U}^T \mathbf{U} = \mathbf{V}^T \mathbf{V} = \mathbf{I}$ . Die Singulärwertmatrix  $\mathbf{S}$  ist eine quadratische Matrix mit den Singulärwerten  $s_1 \geq s_2 \geq \dots \geq s_p \geq 0$  auf der Diagonalen. Die Zahl  $p$  gibt die Anzahl der signifikanten Singulärwerte an und ist gleich der Systemordnung. Bezeichnet man mit  $\mathbf{U}_p$  und  $\mathbf{V}_p$  die Matrizen mit den ersten  $p$  Spalten der Matrizen  $\mathbf{U}$  und  $\mathbf{V}$ , so lässt sich die Matrix  $\mathbf{H}_0$  für das reduzierte System wie folgt schreiben:

$$\mathbf{H}_0 \approx \mathbf{U}_p \mathbf{S}_p \mathbf{V}_p^T. \quad (2.45)$$

Nun können die für die Systemidentifikation benötigten Matrizen aus der Gl. (2.39)-(2.40) wie folgt formuliert werden:

$$(\mathbf{B}_z)_{\tilde{\alpha}} = \mathbf{U}_p \mathbf{S}_p^{1/2} \quad \text{und} \quad (\mathbf{S}_z)_{\tilde{\beta}} = \mathbf{S}_p^{1/2} \mathbf{V}_p^T. \quad (2.46)$$

Um eine geschätzte Matrix  $\hat{\mathbf{A}}_d$  für ein reduziertes System der Ordnung  $p$  zu erhalten, wird die Hankelmatrix aus Gl. (2.42) für  $i = 2$  berechnet:

$$\mathbf{H}_1 = (\mathbf{B}_z)_{\tilde{\alpha}} \hat{\mathbf{A}}_d (\mathbf{S}_z)_{\tilde{\beta}}. \quad (2.47)$$

Die Umstellung nach  $\hat{\mathbf{A}}_d$  liefert eine Schätzung der Zustandsmatrix des diskreten Systems:

$$\hat{\mathbf{A}}_d = \mathbf{S}_p^{-1/2} \mathbf{U}_p^T \mathbf{H}_1 \mathbf{V}_p \mathbf{S}_p^{-1/2}. \quad (2.48)$$

Die geschätzte Messmatrix des Systems kann direkt aus der Beobachtbarkeitsmatrix für die  $m$ -Systemausgänge hergeleitet werden

$$\hat{\mathbf{C}}_y = \mathbf{E}^T \mathbf{U}_p \mathbf{S}_p^{1/2}, \quad (2.49)$$

wobei  $\mathbf{E}^T = [\mathbf{I} \ \mathbf{0} \ \dots \ \mathbf{0}]$  aus einer Einheitsmatrix und weiteren Nullmatrizen der Größe  $m \times m$  besteht. Mit Hilfe der Zustands- und Messmatrix kann somit das Schwingungsverhalten des Systems nach den Gleichungen (2.30)-(2.32) berechnet werden.

### 2.2.2 Systemidentifikation mit Hilfe von autoregressiven Modellen

Eine weitere in dieser Arbeit verwendete Systemidentifikationsmethode basiert auf der Modellierung von  $m$ -variater Zeitreihen und somit auch des Zustandsraums des Systems mit einem autoregressiven Modell.

Ein  $m$ -variater AR( $p$ )-Modell, das auch als Vektor-Autoregressives ARV( $p$ )-Modell für stationäre Zeitreihen bekannt ist, wird wie folgt formuliert:

$$\mathbf{y}_k = \mathbf{w} + \sum_{l=1}^p \mathbf{A}_l \mathbf{y}_{k-l} + \boldsymbol{\varepsilon}_k. \quad (2.50)$$

Der Modellfehler  $\boldsymbol{\varepsilon}$  besteht aus  $m$  mittelwertfreien Vektoren mit gaussverteilten Daten. Die Kovarianzmatrix des Modellfehlers wird mit  $\hat{\mathbf{C}}_{AR} = E[\boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^T]$  bezeichnet. Die Matrizen  $\mathbf{A}_1, \dots, \mathbf{A}_p$  mit der Dimension  $m \times m$  sind die Koeffizientenmatrizen des ARV-Modells der Ordnung  $p$ . Der Vektor  $\mathbf{w}$  mit der Dimension  $m \times 1$  ermöglicht die Berücksichtigung der von Null abweichenden Mittelwerte der Zeitreihen. Soll das Rauschen mit einem zusätzlichen gleitenden Mittelwert berücksichtigt werden, dann wird das Modell aus Gl. (2.50) um den MA-Term (eng. *Moving Average*) erweitert, dadurch entsteht ein ARMAV-Modell

$$\mathbf{y}_k = \mathbf{w} + \sum_{l=1}^p \mathbf{A}_l \mathbf{y}_{k-l} + \sum_{l=1}^q \mathbf{B}_l \boldsymbol{\varepsilon}_{k-l} + \boldsymbol{\varepsilon}_k, \quad (2.51)$$



wobei  $\mathbf{B}$  die Koeffizientenmatrix des MA-Modells mit der Ordnung  $q$  ist. Derartige Modelle wurden zur Identifikation dynamischer Systeme z.B. in [ANDERSEN 1997; ANDERSEN und KIRKEGAARD 1998; BODEUX und GOLINVAL 2001] verwendet. Die Identifikation mit ARMAV-Modellen wird hier nicht weiter verfolgt, da die gleichzeitige Berechnung der Autoregressiven- und Moving-Average-Matrizen sehr rechenzeitintensiv ist und mit einem ARV-Modell höherer Ordnung gleichwertige Ergebnisse erzielt werden [PEETERS und DE ROECK 1999].

Die Berechnung der AR-Koeffizientenmatrizen erfolgt durch die Minimierung des Modellfehlers mit Hilfe eines kleinsten Fehlerquadrate-Ansatzes begleitet von Regularisierungstechniken. Die Vorgehensweise bei der Berechnung der AR-Koeffizientenmatrizen befinden sich im Anhang A1.1 und in [LÜTKEPOHL 1993; NEUMAIER und SCHNEIDER 2001]. Eine geeignete Auswahl der Systemordnung kann mit Hilfe des *Schwarz-Bayes* (SBC) oder des *Final Prediction Error* (FPE) Kriteriums getroffen werden:

$$SBC(p) = \frac{l_p}{m} - \left(1 - \frac{n_p}{n_t}\right) \log(n_t) \quad \text{mit} \quad l_p = \log|\hat{\mathbf{C}}_{AR}| \quad \text{und} \quad n_p = mp + 1, \quad (2.52)$$

$$FPE(p) = \frac{l_p}{m} - \log \frac{n_t(n_t - n_p)}{n_t + n_p}. \quad (2.53)$$

Die Zustandsraumbeschreibung des ARV( $p$ )-Modells kann mit Hilfe der Gl. (2.33) und (2.50) erfolgen. Hierbei ist der Systemzustand an den Zeitinkrementen  $k$  bzw.  $k-1$

$$\begin{aligned} \mathbf{z}_k &= [\mathbf{y}_k^T \quad \mathbf{y}_{k-1}^T \quad \cdots \quad \mathbf{y}_{k-p+1}^T]^T \\ \mathbf{z}_{k-1} &= [\mathbf{y}_{k-1}^T \quad \mathbf{y}_{k-2}^T \quad \cdots \quad \mathbf{y}_{k-p}^T]^T \end{aligned} \quad (2.54)$$

und die Rauschmatrix:

$$\mathbf{w}_k = [\boldsymbol{\varepsilon}_{k+1}^T \quad \mathbf{0}^T \quad \cdots \quad \mathbf{0}^T]^T. \quad (2.55)$$

Aus den Gl. (2.33), (2.50), (2.54) und (2.55) lässt sich nun erkennen, dass die System- und Messmatrix eines ARV( $p$ )-Modells wie folgt definiert werden können:

$$\hat{\mathbf{A}}_d = \begin{bmatrix} \mathbf{A}_1 & \mathbf{A}_2 & \cdots & \mathbf{A}_{p-1} & \mathbf{A}_p \\ \mathbf{I} & \mathbf{0} & \cdots & \mathbf{0} & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{I} & \mathbf{0} \end{bmatrix}, \quad (2.56)$$

$$\hat{\mathbf{C}}_y = [\mathbf{I} \quad \mathbf{0} \quad \cdots \quad \mathbf{0} \quad \mathbf{0}]. \quad (2.57)$$

Die Dimensionen der Matrizen  $\mathbf{A}_d$  und  $\mathbf{C}_y$  sind  $mp \times mp$  bzw.  $m \times mp$ . Diese Realisierung der Zustandsmatrizen ist als Beobachter-kanonische Form bekannt, vgl. [ANDERSEN 1997]. Diese Bezeichnung ist mit der Beziehung zwischen den Zustandsraumgleichungen und den Gleichungen eines ARV- oder ARMAV-Modells über die Zustandsbeobachtbarkeitsmatrix verbunden. Dieser Zusammenhang ist ersichtlich, wenn man die Zustandsgleichung ohne Prozessrauschen in die Messgleichung (2.33) für  $k+p$  Zeitinkremente einfügt

$$\mathbf{y}_{k+p} = \mathbf{C}_y \mathbf{A}_d^p \mathbf{z}_k \quad (2.58)$$

und diese anschließend zum Umschreiben der Zeitreihenmodellierung aus Gl. (2.50) nutzt:

$$(\mathbf{C}_y \mathbf{A}_d^p - \mathbf{A}_1 \mathbf{C}_y \mathbf{A}_d^{p-1} - \cdots - \mathbf{A}_{p-1} \mathbf{C}_y \mathbf{A}_d - \mathbf{A}_p \mathbf{C}_y) \mathbf{z}_k = \boldsymbol{\varepsilon}_{k+p}. \quad (2.59)$$

Damit kann diese Gleichung, für  $\boldsymbol{\varepsilon}_{k+p} = 0$ , in Abhängigkeit der Beobachtbarkeitsmatrix geschrieben werden:

$$\begin{bmatrix} \mathbf{A}_p & \mathbf{A}_{p-1} & \cdots & \mathbf{A}_2 & \mathbf{A}_1 \end{bmatrix} \begin{bmatrix} \mathbf{C}_y \\ \mathbf{C}_y \mathbf{A}_d \\ \vdots \\ \mathbf{C}_y \mathbf{A}_d^{p-2} \\ \mathbf{C}_y \mathbf{A}_d^{p-1} \end{bmatrix} = \mathbf{C}_y \mathbf{A}_d^p \quad (2.60)$$

oder

$$\begin{bmatrix} \mathbf{A}_p & \mathbf{A}_{p-1} & \cdots & \mathbf{A}_2 & \mathbf{A}_1 \end{bmatrix} = \mathbf{C}_y \mathbf{A}_d^p (\mathbf{B}_z)_p^{-1}. \quad (2.61)$$

In [ANDERSEN 1997] wurde nachgewiesen, dass die kanonische Form der Zustandsmatrizen in Gl. (2.56) und (2.57) mit Hilfe der Impulsantwort und der Übertragungsfunktion eines ARMAV-Modells hergeleitet werden können.

Wie bei der *Stochastic Subspace Identification*-Methode können auch die Zustandsmatrizen aus Gl. (2.56) und (2.57) zur Untersuchung des Schwingungsverhaltens einer Struktur nach den Gleichungen (2.30)-(2.32) verwendet werden. Die Anzahl der Schwingungsmoden eines  $m$ -variaten ARV( $p$ )-Modells ist  $mp$ . Die Trennung zwischen physikalischen und mathematischen Moden wird für beide Methoden mit Hilfe von Stabilitätsplots im Abschnitt 3.4.1 durchgeführt.

### 2.2.3 Schätzung von Systemzuständen mit Kalman-Filtern

Die identifizierten Systemmatrizen können nun zur Schätzung weiterer Systemzustände genutzt werden. Dies erfolgt, indem der Systemzustand zu jedem diskreten Zeitinkrement  $k$  aus den vorherigen Zuständen berechnet wird. Eine entsprechende Schätzung bietet das Kalman-Filter, welches die Bewegungsgleichungen eines zeitdiskreten, zeitinvarianten Systems aus Gl. (2.33) in einer erweiterten Form nutzt:

$$\begin{aligned} \mathbf{z}_k &= \mathbf{A}_d \mathbf{z}_{k-1} + \mathbf{B}_d \mathbf{u}_{k-1} + \mathbf{G} \mathbf{w}_{k-1} \\ \mathbf{y}_k &= \mathbf{C}_y \mathbf{z}_k + \mathbf{D} \mathbf{u}_k + \mathbf{H} \mathbf{w}_k + \mathbf{v}_k \end{aligned} \quad (2.62)$$

Das Prozessrauschen  $\mathbf{w}$  und das Messrauschen  $\mathbf{v}$  sind schon in Gl. (2.34) definiert worden. Sie sind unabhängige, mittelwertfreie, normalverteilte Größen  $p(\mathbf{w}) \sim N(0, \mathbf{Q}_w)$ ,  $p(\mathbf{v}) \sim N(0, \mathbf{R}_v)$  mit den Erwartungswerten (Kovarianzmatrizen):

$$\mathbf{Q}_w = E[\mathbf{w}_k \mathbf{w}_k^T], \quad \mathbf{R}_v = E[\mathbf{v}_k \mathbf{v}_k^T] \quad \text{und} \quad \mathbf{N}_{wv} = E[\mathbf{w}_k \mathbf{v}_k^T] \quad (2.63)$$

Die Matrizen  $\mathbf{G}$  und  $\mathbf{H}$  indizieren, auf welche Systemfreiheitsgrade das Prozessrauschen einen Einfluss hat.

Das Kalman-Filter ist ein rekursiver Algorithmus und besteht aus einer Schleife, die für jeden Zeitpunkt  $k$  durchlaufen wird. Die Schätzung der Systemzustände zum Zeitpunkt  $k$  ergibt sich aus einer gewichteten Mittelung des aktuellen Messwertes vom Zeitpunkt  $k$  und der Prädiktion der Systemzustände für den Zeitpunkt  $k$ . Die Gewichtungsfaktoren bei dieser Mittelung werden aus den im jeweiligen Schleifendurchlauf geschätzten Unsicherheiten gebildet, die jeweils mit dem prädierten Systemzustand bzw. dem neuen Messwert verbunden sind. Je geringer die Unsicherheit ist, desto höher ist der relative Gewichtungsfaktor.

Die folgende allgemeine Beschreibung des Algorithmus basiert auf [KÖHLER 2005] und [WELCH und BISHOP 2001]. Zuerst wird der *a priori* Zustand  $\hat{\mathbf{z}}_k^-$  für den Zustandsvektor  $\mathbf{z}_k$  des Systems im Prädiktionsschritt, Gl (2.64), geschätzt.

*Prädiktionsschritt:*

$$\hat{\mathbf{z}}_k^- = \mathbf{A}_d \hat{\mathbf{z}}_{k-1} + \mathbf{B}_d \mathbf{u}_{k-1} \quad (2.64)$$

$$\mathbf{P}_k = \mathbf{A}_d \mathbf{Z}_{k-1} \mathbf{A}_d^T + \mathbf{Q}_w \quad (2.65)$$

Nach Eintreffen des Messwertes  $\mathbf{y}_k$  lässt sich im Korrekturschritt der *a posteriori* Schätzwert  $\hat{\mathbf{z}}_k$  berechnen, siehe Gl. (2.66). Für die *a posteriori* Schätzung wird die Differenz zwischen den gemessenen und den geschätzten Signalen mit dem Kalman-Faktor  $\mathbf{K}_k$  gewichtet, siehe Gl. (2.66) und (2.67).

*Korrekturschritt:*

$$\hat{\mathbf{z}}_k = \hat{\mathbf{z}}_k^- + \mathbf{K}_k (\mathbf{y}_k - \mathbf{C}_y \hat{\mathbf{z}}_k^- - \mathbf{D} \mathbf{u}_k) = \hat{\mathbf{z}}_k^- + \mathbf{K}_k (\mathbf{y}_k - \hat{\mathbf{y}}_k) \quad \text{mit} \quad (2.66)$$

$$\mathbf{K}_k = \mathbf{P}_k \mathbf{C}_y^T (\mathbf{C}_y \mathbf{P}_k \mathbf{C}_y^T + \mathbf{R}_v)^{-1} \quad (2.67)$$

$$\mathbf{Z}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{C}_y) \mathbf{P}_k. \quad (2.68)$$

Die *a priori* geschätzte Fehlerkovarianz  $\mathbf{P}_k$  aus dem Prädiktionsschritt wird für das *update* des Kalman-Faktors in Gl. (2.67) verwendet. Die Fehlerkovarianz  $\mathbf{P}_k$  berechnet sich aus der *a posteriori* geschätzten Fehlerkovarianz  $\mathbf{Z}_k$ , siehe Gl. (2.65) und (2.68). Die Fehlerkovarianzmatrizen aus Gl. (2.65) und (2.68) lassen sich mit Hilfe der *a priori* und *a posteriori* Schätzfehler  $\mathbf{e}_k^-$  bzw.  $\mathbf{e}_k$  aufstellen:

$$\mathbf{P}_k = E[\mathbf{e}_k^- \cdot \mathbf{e}_k^{-T}] \quad \text{und} \quad \mathbf{Z}_k = E[\mathbf{e}_k \cdot \mathbf{e}_k^T] \quad \text{mit} \quad (2.69)$$

$$\mathbf{e}_k^- = \mathbf{z}_k - \hat{\mathbf{z}}_k^- \quad \text{und} \quad \mathbf{e}_k = \mathbf{z}_k - \hat{\mathbf{z}}_k. \quad (2.70)$$

Eine Kalman-Verstärkermatrix kann mit Hilfe der Fehlerkovarianzmatrix im stationären Zustand  $\mathbf{P}_\infty = \mathbf{P}_{k-1} = \mathbf{P}_k$ , welche die Lösung der Riccati Gleichung für  $\mathbf{H} = 0$  repräsentiert, berechnet werden [GREWAL und ANDREWS 2001]:

$$\mathbf{P}_\infty = \mathbf{A}_d [\mathbf{P}_\infty - \mathbf{P}_\infty \mathbf{C}_y^T (\mathbf{C}_y \mathbf{P}_\infty \mathbf{C}_y^T + \mathbf{R}_v)^{-1} \mathbf{C}_y \mathbf{P}_\infty] \mathbf{A}_d^T + \mathbf{G} \mathbf{Q}_w \mathbf{G}^T. \quad (2.71)$$

Einsetzen der Gleichung (2.71) in Gl. (2.67) und schließlich in Gl. (2.65) führt zur Identifikation der Zustände eines linearen zeitinvarianten Systems. Wenn es sich um ein *Output-Only*-System handelt, dann folgt daraus, dass für  $\mathbf{u} = 0$  das System nur durch weißes Rauschen  $\mathbf{w}$  angeregt wird. In diesem Kontext beschreibt die Matrix  $\mathbf{G}$  die Anregungsstellen, siehe auch Gl. (3.133) in Abschnitt 3.5.3.1.

### 2.3 SENSITIVITÄTSANALYSE DYNAMISCHER SYSTEME

Dieser Abschnitt gibt eine Einführung in die modellgestützte Schadensdiagnose und basiert auf [BALAGEAS *et al.* 2006] und [BOHLE 2005]. Hierbei werden Veränderungen der dynamischen Eigenschaften einer schwach proportional gedämpften Struktur durch lokal begrenzte Schäden identifiziert. Ein Schaden wird sich dabei in der Regel in einer Änderung der lokalen Systemsteifigkeit niederschlagen. Der Vollständigkeit halber wird der Fall einer Massenänderung bei den folgenden Erläuterungen mit betrachtet:

$$\mathbf{M}_g \ddot{\mathbf{x}} + \mathbf{K}_g \mathbf{x} = (\mathbf{M}_{ref} + \Delta\mathbf{M}) \ddot{\mathbf{x}} + (\mathbf{K}_{ref} + \Delta\mathbf{K}) \mathbf{x} = \mathbf{f} . \quad (2.72)$$

Dabei bedeutet der Index  $g$ , dass es sich um die Steifigkeits- und Massematrix des geschädigten Systems handelt, der Index  $ref$  bezieht sich auf die Referenzmatrizen des ungeschädigten Systems.  $\Delta\mathbf{K}$  bzw.  $\Delta\mathbf{M}$  repräsentieren die Abweichungen in der Steifigkeit und der Masse bzgl. des Referenzsystems und werden für jede Subregion, bspw. für jedes Finite Element, durch  $n_e$  dimensionslose Parameter  $\Delta p_j$  bzw.  $\Delta q_j$  linearisiert:

$$\Delta\mathbf{K} \approx \sum_{j=1}^{n_e} \frac{\partial\mathbf{K}}{\partial p_j} \Delta p_j = \sum_{j=1}^{n_e} \mathbf{K}_j \Delta p_j , \quad \Delta\mathbf{M} \approx \sum_{j=1}^{n_e} \frac{\partial\mathbf{M}}{\partial q_j} \Delta q_j = \sum_{j=1}^{n_e} \mathbf{M}_j \Delta q_j \quad (2.73)$$

Für den Fall, dass die Parametrisierung für jedes Element vorgenommen wird, entsprechen die Submatrizen  $\mathbf{K}_j$  und  $\mathbf{M}_j$  den globalen Elementmatrizen  $\mathbf{K}_{el,j}$  und  $\mathbf{M}_{el,j}$  des Referenzsystems. Diese Form der dimensionslosen Parametrisierung lässt sich auf alle Parameter anwenden, die im Vorhinein in die Elementmatrizen eingehen, z.B. der E-Modul bei isotropem Materialverhalten. Die Linearisierung führt zu Näherungslösungen, welche bei großen Veränderungen in den Parametern häufig zu Linearisierungsfehlern führen. Ein Beispiel dafür ist in Abschnitt 3.4.2.3 und Abbildung 3.35, rechts, gegeben.

#### 2.3.1 Eigenfrequenzsensitivität

Die Sensitivität bezüglich der Eigenfrequenzen lässt sich von der üblichen Eigenwert-sensitivität im Bezug auf  $\lambda_i = \omega_i^2 = 4\pi^2 f_i^2$  überführen. Die gesuchten partiellen Ableitungen der Eigenfrequenzen  $\partial f_i / \partial p_j$  nach den Parametern können durch Differenzieren von Gl. (2.6) nach den Parametern  $p_j$  hergeleitet werden:

$$\frac{\partial}{\partial p_j} \left[ (\mathbf{K} - 4\pi^2 f_i^2 \mathbf{M}) \boldsymbol{\varphi}_i \right] = \mathbf{0}. \quad (2.74)$$

$$\Rightarrow \left[ \frac{\partial \mathbf{K}}{\partial p_j} - 4\pi^2 f_i^2 \frac{\partial \mathbf{M}}{\partial p_j} - 8\pi^2 f_i \frac{\partial f_i}{\partial p_j} \mathbf{M} \right] \boldsymbol{\varphi}_i + (\mathbf{K} - 4\pi^2 f_i^2 \mathbf{M}) \frac{\partial \boldsymbol{\varphi}_i}{\partial p_j} = \mathbf{0}. \quad (2.75)$$

Vormultiplizieren mit  $\boldsymbol{\varphi}_i^T$  liefert bei symmetrischer Massen- und Steifigkeitsmatrix

$$\begin{aligned} & \boldsymbol{\varphi}_i^T \frac{\partial \mathbf{K}}{\partial p_j} \boldsymbol{\varphi}_i - 4\pi^2 f_i^2 \boldsymbol{\varphi}_i^T \frac{\partial \mathbf{M}}{\partial p_j} \boldsymbol{\varphi}_i - 8\pi^2 f_i \frac{\partial f_i}{\partial p_j} \boldsymbol{\varphi}_i^T \mathbf{M} \boldsymbol{\varphi}_i + \dots \\ & \dots + \left[ \underbrace{(\mathbf{K} - 4\pi^2 f_i^2 \mathbf{M})}_{=\mathbf{0}} \boldsymbol{\varphi}_i \right]^T \frac{\partial \boldsymbol{\varphi}_i}{\partial p_j} = 0 \end{aligned} \quad (2.76)$$

Sind die Eigenvektoren nach Gl. (2.7) massennormiert, erhält man unter Verwendung von Gl. (2.76) die Eigenfrequenzableitungen:

$$\frac{\partial f_i}{\partial p_j} = \frac{1}{8\pi^2 f_i} (\boldsymbol{\varphi}_i^T \mathbf{K}_j \boldsymbol{\varphi}_i - 4\pi^2 f_i^2 \boldsymbol{\varphi}_i^T \mathbf{M}_j \boldsymbol{\varphi}_i). \quad (2.77)$$

### 2.3.2 Eigenvektorsensitivität

Die Eigenvektorableitungen werden mit einem Näherungsverfahren von [FOX und KAPOOR 1968] beschrieben. Leitet man Gl. (2.6) nach den Korrekturparameter  $p_j$  ab, so erhält man

$$[\mathbf{K} - \lambda_i \mathbf{M}] \frac{\partial \boldsymbol{\varphi}_i}{\partial p_j} = - \left( \frac{\partial}{\partial p_j} [\mathbf{K} - \lambda_i \mathbf{M}] \right) \boldsymbol{\varphi}_i. \quad (2.78)$$

Zur Lösung von Gl. (2.78) wird der folgende Summenansatz

$$\frac{\partial \boldsymbol{\varphi}_i}{\partial p_j} = \sum_{k=1}^n a_{ijk} \boldsymbol{\varphi}_k \quad (2.79)$$

aus den Eigenvektoren für die Eigenvektorableitungen eingeführt. Für die Bestimmung der Koeffizienten  $a_{ijk}$  wird der Summenansatz in Gl. (2.78) eingesetzt und diese Gleichung

zusätzlich von links mit dem Eigenvektor  $\boldsymbol{\varphi}_l^T$  multipliziert:

$$\sum_{k=1}^n a_{ijk} \boldsymbol{\varphi}_l^T [\mathbf{K} - \lambda_i \mathbf{M}] \boldsymbol{\varphi}_k = - \boldsymbol{\varphi}_l^T \left( \frac{\partial}{\partial p_j} [\mathbf{K} - \lambda_i \mathbf{M}] \right) \boldsymbol{\varphi}_i. \quad (2.80)$$

Nach Ausnutzung der Orthogonalitätsbeziehungen aus Gl. (2.7)-(2.8) erhält man für  $i \neq l$

$$a_{ijl} = \frac{1}{\lambda_i - \lambda_l} \left[ \boldsymbol{\varphi}_l^T \frac{\partial}{\partial p_j} [\mathbf{K} - \lambda_i \mathbf{M}] \boldsymbol{\varphi}_i \right]. \quad (2.81)$$

Die Koeffizienten für  $i = l$  werden mit Hilfe der Massenormierung der Eigenvektoren nach Einführung des Summenansatzes aus Gl. (2.79) berechnet

$$2 \boldsymbol{\varphi}_i^T \mathbf{M} \sum_{k=1}^n a_{ijk} \boldsymbol{\varphi}_k = -\boldsymbol{\varphi}_i^T \frac{\partial \mathbf{M}}{\partial p_j} \boldsymbol{\varphi}_i \quad \text{mit} \quad a_{iji} = -\frac{1}{2} \boldsymbol{\varphi}_i^T \frac{\partial \mathbf{M}}{\partial p_j} \boldsymbol{\varphi}_i. \quad (2.82)$$

Falls Systemschäden ausschließlich durch Steifigkeitsveränderungen beschrieben werden sollen, dann vereinfachen sich die Gl. (2.77) und (2.81) zu:

$$\frac{\partial f_i}{\partial p_j} = \frac{1}{8\pi^2 f_i} \boldsymbol{\varphi}_i^T \mathbf{K}_j \boldsymbol{\varphi}_i \quad (2.83)$$

bzw.

$$a_{ijl} = \frac{1}{\lambda_i - \lambda_l} \left[ \boldsymbol{\varphi}_l^T \mathbf{K}_j \boldsymbol{\varphi}_i \right] \quad \text{und} \quad a_{iji} = 0 \quad (\text{für } i = l). \quad (2.84)$$

### 2.3.3 Kennzahlen zur Korrelation der Modaldaten

Da Korrelationen und Vergleiche zwischen Modaldaten sowohl im Kontext einer Schadenslokalisierung (z.B. Vergleich zwischen gemessenen und simulierten Moden) als auch für eine automatisierte Modalanalyse (Vergleich zwischen gemessenen Moden aus zwei unterschiedlichen Datensätzen) genutzt werden, sind im Folgenden zwei der wichtigsten Kriterien zur modalen Korrelation und Skalierung beschrieben: Das *Modal Assurance*-Kriterium und der Modale Skalierungsfaktor.

*Modal Assurance-Kriterium* (MAC)

Das MAC-Kriterium ist eine der wichtigsten Kennzahlen für den Vergleich zweier Modalmatrizen  $\boldsymbol{\Phi}_A$  und  $\boldsymbol{\Phi}_B$ . Die Ähnlichkeit zweier Vektoren  $\boldsymbol{\varphi}_{A,i}$  und  $\boldsymbol{\varphi}_{B,j}$  lässt sich durch den von beiden Vektoren eingeschlossenen Winkel  $\alpha_{AB,ij}$  interpretieren:

$$\alpha_{AB,ij} = \arccos \left( \frac{\boldsymbol{\varphi}_{A,i}^T \boldsymbol{\varphi}_{B,j}}{|\boldsymbol{\varphi}_{A,i}| |\boldsymbol{\varphi}_{B,j}|} \right). \quad (2.85)$$

Das MAC-Kriterium berechnet das Quadrat des Kosinus des Winkels und kann demnach Werte zwischen Null und Eins annehmen. Für alle verfügbaren Eigenvektoren bilden die MAC-Werte eine sog. MAC-Matrix

$$\text{MAC}_{AB,ij} = \cos^2(\alpha_{AB,ij}) = \frac{(\boldsymbol{\varphi}_{A,i}^T \boldsymbol{\varphi}_{B,j})^2}{(\boldsymbol{\varphi}_{A,i}^T \boldsymbol{\varphi}_{A,i})(\boldsymbol{\varphi}_{B,j}^T \boldsymbol{\varphi}_{B,j})}. \quad (2.86)$$

Parallele Eigenvektoren ( $\alpha_{AB,ij} = 0^\circ$ ) führen zu einem MAC-Wert von Eins, orthogonale Eigenvektoren ( $\alpha_{AB,ij} = 90^\circ$ ) liefern den Wert Null. Anhand der MAC-Matrix können die Eigenvektorpaare mit der höchsten Korrelation ermittelt werden, so dass eine Zuordnung der einander entsprechenden Eigenvektoren und eine gleichzeitige Bewertung ihrer Übereinstimmung möglich ist. Über das MAC-Kriterium kann außerdem die Zuweisung der einander entsprechenden, zugehörigen Eigenfrequenzen vorgenommen werden (vgl. bspw. Abschnitt 3.4.1).

#### *Modaler Skalierungsfaktor (MSF)*

Die Bildung von Residuen aus Eigenvektordifferenzen gestaltet sich als problematisch, wenn die zugrundeliegenden Eigenvektoren unterschiedlich normiert sind. Im Extremfall, wenn zwei parallele, über das MAC-Kriterium zugeordnete Eigenschwingungsformen  $\boldsymbol{\varphi}_A$  und  $\boldsymbol{\varphi}_B$  so normiert sind, dass  $\boldsymbol{\varphi}_A = -\boldsymbol{\varphi}_B$  ist und das Residuum  $\boldsymbol{\varphi}_A - \boldsymbol{\varphi}_B$  gebildet werden soll, erhält man statt des erwarteten Nullvektors gerade die Summe der beiden Eigenvektoren  $2\boldsymbol{\varphi}_A$ . Um dies zu vermeiden, wird der MSF für jedes mit Hilfe des MAC-Kriteriums gebildete Eigenvektorpaar bestimmt und mit diesem Skalierungsfaktor die Normierung angepasst:

$$\text{MSF}_{AB,ij} = \frac{\boldsymbol{\varphi}_{A,i}^T \boldsymbol{\varphi}_{B,j}}{\boldsymbol{\varphi}_{B,j}^T \boldsymbol{\varphi}_{B,j}}. \quad (2.87)$$

Verwendet man wieder die Beträge der Eigenvektoren und den von den Vektoren  $\boldsymbol{\varphi}_A$  und  $\boldsymbol{\varphi}_B$  eingeschlossenen Winkel, so erhält man für den MSF den Ausdruck

$$\text{MSF}_{AB,ij} = \frac{|\boldsymbol{\varphi}_{A,i}|}{|\boldsymbol{\varphi}_{B,j}|} \cos(\alpha_{AB,ij}). \quad (2.88)$$

Die vergleichbar normierten Eigenvektoren erhält man durch Multiplikation der Vektoren  $\boldsymbol{\varphi}_j$  mit dem Modalen Skalierungsfaktor  $\text{MSF}_{AB,ij}$ :



$$\boldsymbol{\varphi}_{B,j}^* = \text{MSF}_{AB,ij} \cdot \boldsymbol{\varphi}_{B,j} = |\boldsymbol{\varphi}_{A,i}| \cdot \cos(\alpha_{AB,ij}) \cdot \boldsymbol{e}_{\varphi_{A,j}}. \quad (2.89)$$

## 2.4 KONZEPTE ZUR DATENANALYSE

Dieser Abschnitt dient zum Einen dem Zusammenstellen der Grundlagen zur Datenanalyse bzgl. der Kompensation des Einflusses der EOC auf die Merkmale eines identifizierten Systems und zum Anderen zur Erläuterung der Grundlagen zur Sensorfehleridentifikation.

Bei der Beschreibung der Klassifikation werden die Systemmerkmale  $\boldsymbol{\theta}$  als Eingangsparameter definiert. Die Vorstellung der Hauptkomponentenanalyse (eng. *principal component analysis*, PCA) erfolgt anhand der Messdaten  $\boldsymbol{y}$  als Eingangsparameter für die Achsentransformation, da die PCA sowohl für die Sensorfehlererkennung (die Methoden nutzen direkt die Messdaten) als auch für die Kompensation der Umgebungseinflüsse auf die Systemmerkmale verwendet werden.

### 2.4.1 Klassifikationsverfahren

Die in dieser Arbeit angewendeten Klassifikationsverfahren gehören zu der Klasse der unüberwachten Lernverfahren. Bei der Beschreibung wird gezielt auf die *k-medoid* und *fuzzy-k-means*-Algorithmen eingegangen.

#### *Gitterverfahren*

Das einfachste Klassifikationsverfahren basiert auf der Zerlegung der Bereiche für jeden Eingangsparameter in äquidistante Intervalle [BISHOP 1995]. Das größte Problem dieses Verfahrens ist der exponentielle Anstieg der Klassenanzahl mit der Dimensionalität  $d$  der Eingangsparameter (eng. *curse of dimensionality*).

#### *knn-Verfahren*

Um das oben genannte Dimensionalitätsproblem des Gitterverfahrens zu umgehen, können eine gewisse Anzahl  $c$  von Klassen sowie deren Zentren  $\boldsymbol{\mu}_c$  vordefiniert werden. Der *knn*-Algorithmus (eng. *nearest-neighbour algorithm*) errechnet den euklidischen Abstand zwischen den vordefinierten Zentren und den Eingangsparametern der zu klassifizierenden Daten  $\boldsymbol{\theta}$ :

$$\|\boldsymbol{\theta} - \boldsymbol{\mu}_c\|^2 = \|\boldsymbol{\theta}\|^2 - 2\boldsymbol{\theta}^T \boldsymbol{\mu}_c + \|\boldsymbol{\mu}_c\|^2. \quad (2.90)$$

Der minimale Abstand zwischen den Daten und den Zentren entscheidet über die Zugehörigkeit der Daten zur jeweiligen Klassen. Der Nachteil dieses Algorithmus ist, dass die Positionen der Zentren vorgegeben werden müssen. Dadurch eignet sich dieser Algorithmus nur für Klassifikationsvorgänge, in denen schon im Voraus festgelegt wurde, dass die Klassenzentren repräsentativ für die Klassen sind.

### *k-means-Algorithmus*

Eine gute Auswahl für die Position der Zentren, wobei die Kenntnis über die Anzahl der Zentren wie beim *knn*-Verfahren *a-priori* vorausgesetzt wird, kann mit Hilfe des *k-means*-Algorithmus getroffen werden [BISHOP 1995; DUDA *et al.* 2001; NELLES 2001]. Dieser Algorithmus besteht aus einem iterativen Prozess und minimiert die folgende Verlustfunktion:

$$J = \sum_{j=1}^c \sum_{i \in S_j} \left\| \theta_i - \mu_{c_j} \right\|^2 . \quad (2.91)$$

Die Menge  $S_j$  beschreibt diejenigen Elemente  $i$ , die während einer Iteration zum Zentrum  $\mu_{c_j}$  gehören.  $c$  ist die Anzahl aller Zentren, bzw. Klassen, und  $\mu_{c_j}$  ist die Position der Zentren. Im Verlauf dieses Optimierungsproblems variieren die Positionen der Zentren  $\mu_{c_j}$  für jede Iteration. Der Algorithmus arbeitet in folgenden Schritten:

Schritt 1: Normieren der Daten auf das Intervall 0 bis 1.

Schritt 2: Zufällige Auswahl von Zentrenpositionen innerhalb der Menge der Datenpunkte.

Schritt 3: Zuweisung aller Datenpunkte zu dem am nächsten zu ihnen liegenden Zentrum.

Schritt 4: Berechnung des „Schwerpunktes“ einer Klasse  $S_j$  und Zuweisen dieses Wertes zu einem Zentrum:

$$\mu_{c_j} = \frac{1}{N_j} \sum_{i \in S_j} \theta_i . \quad (2.92)$$

$N_j$  bezeichnet hier die Anzahl der zu klassifizierenden Daten innerhalb einer Klasse.

Schritt 5: Einsetzen des Ergebnisses der Gl. (2.92) in (2.91) und Berechnung des Minimums der Verlustfunktion bis eines der beiden Kriterien erfüllt ist: die Änderung der Verlustfunktion ist kleiner als ein voreingestellter Wert (Konvergenz) bzw. eine voreingestellte maximale Iterationszahl wird erreicht.

In Abbildung 2.1 ist der Ablauf einer Klassifikation mit dem *k-means*-Algorithmus dargestellt. Die Anfangszentren, dargestellt durch ein + in Abbildung 2.1, links, werden in

drei Schritten mit Hilfe von Gl. (2.91)- (2.92) in Richtung der tatsächlichen Klassenzentren „verschoben“. Als Ergebnis des Algorithmus entsteht die sog. *hard partition* der Daten. Dadurch kann ein Datum/Datenpunkt nur zu einer einzigen Klasse gehören.

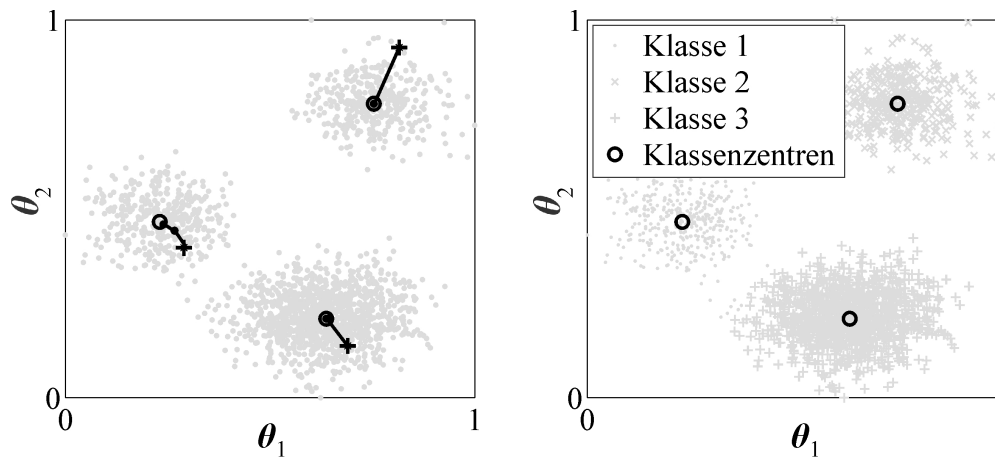


Abbildung 2.1: Klassifikation mit *k-means*-Algorithmus

### *k-medoid-Algorithmus*

Dieser Algorithmus ist eine einfache Erweiterung des *k-means*-Algorithmus, durch eine weitere Verschiebung der Klassenzentren zum nächstliegenden Datenpunkt [DUDA *et al.* 2001]. Diese Vorgehensweise stellt sich als sehr nützlich heraus, falls ein Datum als Referenz oder Erwartungswert für eine Klasse benötigt wird [MOLL *et al.* 2008].

### *Kriterien zur Klassenvalidierung*

Der *k-means*-Algorithmus liefert unterschiedliche Klassifikationsergebnisse in Abhängigkeit der gewählten Anfangszentren, der Anzahl der Zentren und sehr selten von der Anzahl der durchgeführten Iterationen.

Um lokale Optima für die Klassenzentren zu vermeiden, können die Anfangszentren zufällig mehrmals initialisiert und unterschiedliche Kriterien zur Validierung von Klassifikationsergebnissen genutzt werden [DUDA *et al.* 2001]. Das bekannteste Kriterium dafür ist die Minimierung der Summe der Fehlerquadrate, die in der Clusteranalyse oft auch als Minimierung der Partitionsvarianz bezeichnet wird:

$$J_e = \sum_{j=1}^c \sum_{i \in S_j} \|\theta_i - \mu_{c_j}\|^2. \quad (2.93)$$

Weitere bekannte Kriterien aus der multivariaten Diskriminanzanalyse, die aber in dieser Arbeit nicht verwendet und daher nicht mehr weiter erläutert werden, sind das Determinanten-

Kriterium (minimiert das Produkt der Klassenvarianzen in deren Hauptachsenrichtung) und das Invarianten-Kriterium (gestaltet die Klassenpartition unabhängig von linearen Transformationen der Daten).

Während die Auswahl optimaler Klassenzentren mit Hilfe unterschiedlicher Kriterien lösbar ist, gibt es aus statistischer Sicht bislang keine abgesicherten Ansätze für die optimale Anzahl an Klassen. Im Kontext der Schadensidentifikation, so wie sie in dieser Arbeit vorkommt, stellt aber die zuletzt angesprochene Problematik kein Hindernis bezüglich der Schadenserkennung dar, da die Klassenanzahl von der geforderten Sensitivität der Schadenserkennungsmethode bestimmt wird, siehe Abschnitt 3.3.3.

### *Fuzzy-k-means-Algorithmus*

Die bisherigen Klassifikationsansätze gehören zu den Klassen der *hard partition*-Algorithmen. Die *fuzzy partition* basiert auf der Theorie der unscharfen Mengen und unterscheidet sich von bisherigen Verfahren, indem alle  $n_c$  Eingangsdaten allen  $c$  Klassen mit einem gewissen Zugehörigkeitsgrad zugewiesen werden.

Die *Fuzzy-k-means* Klassifikation basiert auf der Minimierung des sog. *c-means* Operators, siehe [BEZDEK 1973; DUNN 1974]:

$$J = \sum_{j=1}^c \sum_{i=1}^{n_c} (w_{ji})^{\tilde{m}} d_{ji}^2 \quad (2.94)$$

mit z.B.  $d_{ji}^2 = \|\theta_i - \mu_{c_j}\|^2$  oder einer anderen quadratischen Norm.  $w_{ji}$  repräsentiert den Zugehörigkeitsgrad des Eingangsdatenvektors  $\theta_i$  zu der Klasse  $j$  und  $\tilde{m}$  den *Fuzzyness*-Faktor. Die Eigenschaften der Zugehörigkeitsgradfunktion für die *Fuzzy*-Klassifikation sind

$$w_{ji} \in [0, 1], \quad 1 \leq i \leq n_c, \quad 1 \leq j \leq c, \quad (2.95)$$

$$\sum_{j=1}^c w_{ji} = 1, \quad 1 \leq i \leq n_c, \quad (2.96)$$

$$0 < \sum_{i=1}^{n_c} w_{ji} < n_c, \quad 1 \leq j \leq c. \quad (2.97)$$

Gl. (2.95) zeigt, dass der Zugehörigkeitsgrad  $w_{ji}$  einer Eingangsgröße  $\theta_i$  zu einer Klasse  $j$  nicht kleiner als Null und nicht größer als Eins sein kann. Die zweite Bedingung, Gl. (2.96),

erklärt, dass für jede Eingangsgröße  $\theta_i$  die Summe der Zugehörigkeiten zu allen Clustern gleich Eins ist. Die dritte Eigenschaft aus Gl. (2.97) besagt, dass keine leeren Klassen entstehen können.

Die Lösung des Minimierungsproblems wird durch die Kopplung der zweiten Bedingung aus Gl. (2.96) an die Zielfunktion  $J$  mit Hilfe von Lagrange-Multiplikatoren  $\tilde{\lambda}$  erreicht:

$$\bar{J} = \sum_{j=1}^c \sum_{i=1}^{n_c} (w_{ji})^{\tilde{m}} d_{ji}^2 + \sum_{i=1}^{n_c} \left[ \tilde{\lambda}_i \left( \sum_{j=1}^c w_{ji} - 1 \right) \right]. \quad (2.98)$$

Das Minimum von Gl. (2.98) wird durch die iterative Berechnung der Gewichtungen und Zentren der Klassifikationseingangsdaten unter Erfüllung der Bedingungen aus Gl. (2.95)-(2.97) und für  $\tilde{m} > 1$  (siehe auch [JIAN *et al.* 2004]) und  $d_{ji}^2 > 0$  erreicht<sup>1</sup>. In einem ersten Schritt werden die Gewichtungen aus den normierten Abständen der Daten zu den Zentren berechnet:

$$w_{ji} = \frac{1}{\sum_{k=1}^c (d_{ji}^2 / d_{ki}^2)^{\frac{1}{\tilde{m}-1}}} \quad \text{mit} \quad 1 \leq j \leq c, \quad 1 \leq i \leq n_c. \quad (2.99)$$

Im zweiten Schritt werden die gewichteten Mittelwerte der Daten für jede Klasse  $j$  festgelegt:

$$\mu_{c_j} = \frac{\sum_{i=1}^{n_c} (w_{ji})^{\tilde{m}} \theta_i}{\sum_{i=1}^{n_c} (w_{ji})^{\tilde{m}}} \quad \text{mit} \quad 1 \leq j \leq c. \quad (2.100)$$

Die Iteration wird nach einer voreingestellten Anzahl an Iterationsschritten  $I$ , oder wenn

$$J_I - J_{I-1} < \varepsilon \quad (2.101)$$

erfüllt ist, beendet.  $\varepsilon$  aus Gl. (2.101) ist eine empirische Abbruchzahl.

Ein Beispiel für diesen Algorithmus ist in Abbildung 2.2 dargestellt. Die Klassenzentren wurden zuerst zufällig generiert und der Klassifikationsvorgang nach Gl. (2.98) in neun

---

<sup>1</sup>In dieser Arbeit wird nach dem Vorschlag von [DUNN 1974]  $\tilde{m} = 2$  verwendet. Für  $\tilde{m} \rightarrow 1$  ergeben sich sehr scharfe *clustering*-Ergebnisse, d.h. die Zugehörigkeiten liegen näher bei 0 oder bei 1. Für  $\tilde{m} \rightarrow \infty$  ergibt sich  $w_{ji} \rightarrow 1/c$  d.h. die Zugehörigkeit der Daten ist zu allen Clustern gleich groß.

Iterationsschritten durchgeführt. Die Interpretation der Zugehörigkeit eines Datumpaares zu den Zentren wird beispielhaft in Abbildung 2.2 erläutert. Hier gehört der mit (x) markierte Datum mit 47% zur Klasse 1, mit 46% zur Klasse 2 und nur mit 7% zur Klasse 3.

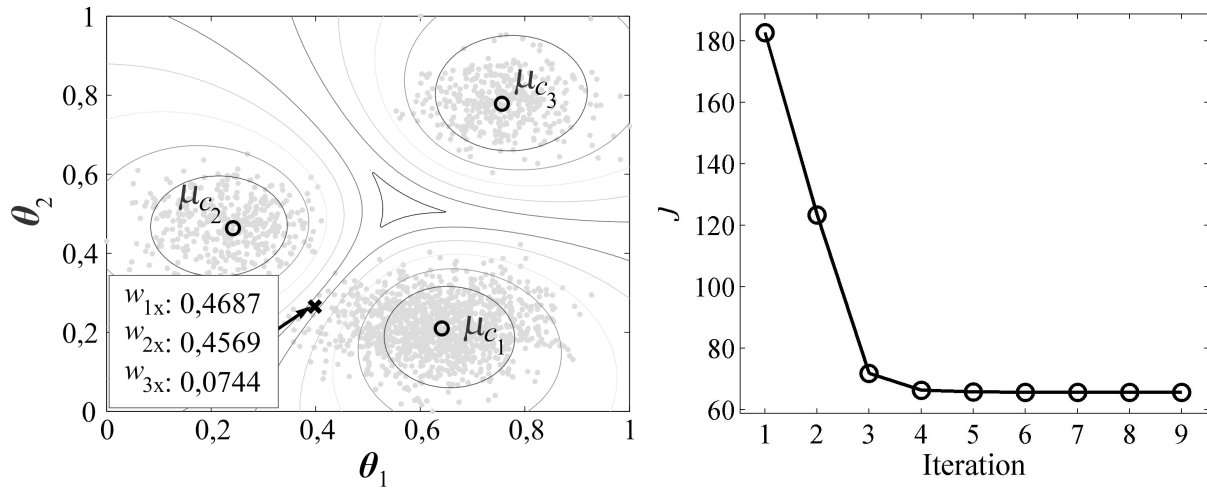


Abbildung 2.2: Klassifikation mit dem *fuzzy-k-means*-Algorithmus

Die Anwendung der Euklidischen Distanz  $d_{ji}^2 = (\theta_i - \mu_{c_j})^T \mathbf{I}(\theta_i - \mu_{c_j})$  bei der *Fuzzy*-Klassifikation führt zu Klassen mit hypersphärischer Form. Die Form dieser Klassen kann jedoch auch bezüglich der Varianzen von  $\theta$  in unterschiedlichen Richtungen gestaltet werden. Hierbei wird die Einheitsmatrix  $\mathbf{I}$  mit den Diagonalelementen einer invertierten Kovarianzmatrix  $\Sigma$  der Eingangsdaten ersetzt:

$$d_{ji}^2 = (\theta_i - \mu_{c_j})^T \Sigma^{-1} (\theta_i - \mu_{c_j}). \quad (2.102)$$

Die Mahalanobis-Norm aus Gl. (2.102) dient als Grundlage für erweiterte Formen der Klassifikation, wie z.B. mit Hilfe des Gustafson-Kessel-Algorithmus [GUSTAFSON und KESSEL 1979], die aber nicht mehr Gegenstand dieser Arbeit sind.

Unterschiedliche Validierungstechniken für die *Fuzzy*-Klassifikation, welche Informationen über den Überlappungsgrad zwischen den Klassen liefern, befinden sich in [BALASKO *et al.* 2005]. Wie bei der Anwendung der *k-means*-Methode wird aber auch hier die Anzahl der Klassen in Abhängigkeit von der geforderten Sensitivität der Schadenserkenngsmethode über systematische Berechnungen mit einer unterschiedlichen Anzahl an Klassen vorgegeben.

## 2.4.2 Die Hauptkomponentenanalyse

Die Hauptkomponentenanalyse (PCA) ist weit verbreitet in der multivariaten Datenanalyse, Mustererkennung und Datenkompression [KÖHLER 2005]. Bei der PCA geht es um die

Darstellung der  $m$ -variaten Daten auf der Grundlage eines neuen  $d$ -dimensionalen Koordinatensystems ( $d < m$ ) mit einem minimalen Verlust an Information

$$\mathbf{z} = \mathbf{U}^T \mathbf{y}, \quad (2.103)$$

wobei  $\mathbf{y}$  (Dimension  $m \times n_t$ ) die zu transformierenden Signalvektoren/Datensätze,  $\mathbf{U}$  (Dimension:  $m \times d$ ) die Transformationsmatrix (Hauptkomponenten) und  $\mathbf{z}$  (Dimension:  $d \times n_t$ ) die transformierten Signalvektoren bezeichnet. Die Hauptkomponenten  $\mathbf{U}$  können aus der Kovarianz  $\Sigma$  der multivariaten Zeitreihe  $\mathbf{y}$  mit Hilfe eines Eigenwertproblems wie folgt berechnet werden:

$$(\Sigma - \lambda_s \mathbf{I}) \mathbf{U}_s = 0 \text{ mit } \Sigma = E[(\mathbf{y} - \bar{\mathbf{y}})(\mathbf{y} - \bar{\mathbf{y}})^T] \text{ und } s = 1 \dots m. \quad (2.104)$$

Die Diagonalelemente von  $\Lambda$  beinhalten daher  $m$  Eigenwerte der Kovarianzmatrix.  $\bar{\mathbf{y}}$  stellt die Mittelwerte der multivariaten Zeitreihe dar. Um die ursprüngliche Zeitreihe  $\mathbf{y}$  in einer komprimierten Form zu beschreiben, werden nur die wichtigsten Hauptkomponenten (Spalten) der orthogonalen Matrix  $\mathbf{U}$  beibehalten. Die Auswahl der repräsentativen Komponenten wird mit Hilfe der bedeutenden Eigenwerte getroffen.

Die neu entstandene, reduzierte Hauptkomponentenmatrix  $\mathbf{U}_{red}$  wird für die Schätzung der „komprimierten“ Zeitreihe  $\hat{\mathbf{y}}$  wie folgt verwendet:

$$\hat{\mathbf{y}} = \bar{\mathbf{y}} + \mathbf{U}_{red} \mathbf{z} \quad (\text{Synthesegleichung}), \quad (2.105)$$

wobei die Komponenten von  $\mathbf{z}$  als Koordinaten der orthogonalen Basis anzunehmen sind:

$$\mathbf{z} = \mathbf{U}_{red}^T (\mathbf{y} - \bar{\mathbf{y}}) \quad (\text{Analysegleichung}). \quad (2.106)$$

Der durch die Transformation der Daten auf die wichtigsten Hauptachsen entstandene Fehler kann mit Hilfe des folgenden euklidischen Abstands berechnet werden:

$$\varepsilon_k = \|\mathbf{y}_k - \hat{\mathbf{y}}_k\|^2 \text{ mit } 1 \leq k \leq n_t. \quad (2.107)$$

Abbildung 2.3, links zeigt exemplarisch die Koordinatentransformation einer bivariaten Zeitreihe  $\mathbf{y} = [\mathbf{y}_1 \ \mathbf{y}_2]^T$ . Die erste Hauptkomponente (1. PC) entsteht in Richtung der größten Varianz der Daten. Die zweite Hauptkomponente steht senkrecht zur ersten Hauptkomponente. In Abbildung 2.3, rechts, wird die Bedeutsamkeit der zwei Komponenten prozentual dargestellt. Hier ist ersichtlich, dass die Information aus der Zeitreihe  $\mathbf{y}$  mit einer

einigen Hauptkomponente gut beschrieben werden kann. Die approximierte Information  $\hat{y}$  ist die Projektion von  $y$  auf die erste Hauptkomponente.




Abbildung 2.3: Hauptachsentransformation (links) und Bedeutsamkeit von Hauptachsen (rechts)

#### Nicht-lineare Hauptkomponentenanalyse

Die nicht-lineare Hauptkomponentenanalyse (eng. *non-linear principal component analysis*, NLPCA) generalisiert die lineare PCA durch Transformation von Daten auf nicht-lineare Koordinaten. Analog zu Gl. (2.106) projiziert die NLPCA die multivariate Zeitreihe  $y$  auf die Hauptkomponenten  $z$ :

$$z = \mathbf{G}(y). \quad (2.108)$$

$\mathbf{G}$  stellt eine nicht-lineare Vektor-Funktion dar. Diese beinhaltet eine Anzahl von  $d$  individuellen nicht-linearen Funktionen  $\mathbf{G} = [G_1, G_2, \dots, G_d]$ . Analog zu Gl. (2.105) kann die inverse Transformation der Daten auf die ursprüngliche Dimensionalität mit Hilfe einer zweiten nicht-linearen Vektor-Funktion  $\mathbf{H}$  wie folgt erreicht werden:

$$\hat{y} = \mathbf{H}(z). \quad (2.109)$$

Der entstandene Fehler lässt sich ebenfalls mit Hilfe des euklidischen Abstands, Gl. (2.107), quantifizieren.

Die NLPCA nutzt künstliche neuronale Netze zur Schätzung der nicht-linearen Funktionen aus Gl. (2.108) und (2.109). [CYBENKO 1989] hat nachgewiesen, dass Funktionen der Form



$$v_k = \sum_{j=1}^{N_2} w_{jk2} \sigma \left( \sum_{i=1}^{N_1} w_{ij1} u_i + b_j \right) \quad (2.110)$$

jede nicht-lineare Funktion  $v = f(u)$  schätzen können.  $v_k$  und  $u_i$  repräsentieren die Komponenten  $k$  und  $i$  von  $\mathbf{v}$  respektive  $\mathbf{u}$ .  $w$  sind die Gewichtungsfaktoren der Verbindung zwischen den Neuronen unterschiedlichen Schichten.  $b_j$  ist die Mittelwertverschiebung eines Neurons.  $\sigma(u)$  ist eine monoton wachsende Funktion, die Werte zwischen Null und Eins für jeden Eingang  $u$  annimmt. In den meisten Fällen [KRAMER 1991] wird  $\sigma(u)$  mit Hilfe einer Sigmoidaktivierungsfunktion dargestellt

$$\sigma(u) = \frac{1}{1 + e^{-u}}. \quad (2.111)$$

Zum Schätzen von arbiträren nicht-linearen Funktionen sind zwei Schichten mit  $N_1$  bzw.  $N_2$  Neuronen ausreichend, wenn die erste Schicht mit Hilfe von Sigmoidfunktionen aktiviert wird. Dadurch können die zwei nicht-linearen Vektor-Funktionen aus Gl. (2.108) und (2.109) mit jeweils einer versteckten Schicht mit Sigmoidaktivierungsfunktionen und einer Ausgangsschicht dargestellt werden. Die Ausgangsschicht wird mit Hilfe von linearen (L) oder nicht-linearen Funktionen (N) aktiviert.

Die Kombination der beiden Netze ergibt ein sog. Autoassoziatives Neuronales Netz (AANN) mit drei versteckten Schichten: *mapping*, *bottleneck* und *de-mapping* Schicht. Ein Schema des AANN für NLPCA ist in Abbildung 2.4 dargestellt.

Die erste versteckte Schicht, bestehend aus  $M_1$  Neuronen, stellt die Funktion  $\mathbf{G}$  dar. Diese bilden die  $m$  Eingangsvariablen einer Spalte von  $\mathbf{y}$  ab und projizieren diese schließlich auf die *bottleneck* Schicht, die aus  $d$  Neuronen besteht. Die Dimension  $d$  stellt auch die Anzahl der sog. nicht-linearen Hauptkomponenten dar. Analog zu  $\mathbf{G}$  nimmt die inverse Funktion  $\mathbf{H}$  die Zeilen von  $\mathbf{z}$  als Eingang und entpackt diese auf der *de-mapping* Schicht mit  $M_2$  Neuronen. In dieser Prozedur ist  $\mathbf{z}$  gleichzeitig der Ausgang von  $\mathbf{G}$  und der Eingang von  $\mathbf{H}$ . Schließlich rekonstruiert die Ausgangsschicht die Daten  $\hat{\mathbf{y}}$  (Dimension  $m \times n_t$ ), welche damit der Größe der Daten  $\mathbf{y}$  in der Eingangsschicht entspricht.

Allgemein werden die Dimensionen der *mapping* und der *de-mapping* Schichten gleich groß und größer als die Dimension der *bottleneck* Schicht gewählt ( $M_1 = M_2 = M > m$ ).

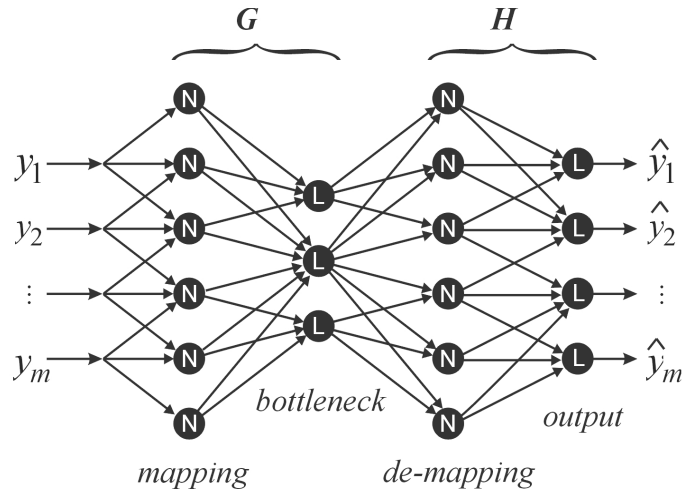


Abbildung 2.4: Autoassoziatives neuronales Netz, nach [KRAMER 1991]

Für eine adäquate Auswahl der Neuronenanzahl in unterschiedlichen Schichten wird in [KRAMER 1991] der *final prediction error* (FPE)

$$FPE_{NLPCA} = e_g \left( 1 + \frac{N_g}{N_b} \right) / \left( 1 - \frac{N_g}{N_b} \right) \quad (2.112)$$

oder das *Akaike's information criterion* (AIC) vorgeschlagen

$$AIC_{NLPCA} = \log(e_g) + 2 \frac{N_g}{N_b}. \quad (2.113)$$

In Gl. (2.112) und (2.113) repräsentiert  $N_g = (m + d + 1)(M_1 + M_2) + m + d$  die Gesamtanzahl der Gewichte. Die Gesamtanzahl der Variablen und Beobachtungen aus  $\mathbf{y}$  wird durch  $N_b = mn_t$  beschrieben.  $e_g = \varepsilon / (2N_b)$  stellt die gemittelte Summe der Fehlerquadrate dar. Für  $N_g \ll N_b$  zeigen beide Kriterien sehr ähnliche Ergebnisse, jedoch steigen für eine große Anzahl an Gewichten die FPE- schneller als die AIC-Werte. Um ein Minimum von FPE bzw. AIC festzulegen, werden die Gl. (2.112) und (2.113) mehrmals für unterschiedliche Dimensionen der Schichten berechnet.

[SANGER 1989] hat nachgewiesen, dass die lineare PCA auch mit Hilfe eines AANN-Netzes ohne *mapping* und *de-mapping* Schichten durchgeführt werden kann. Das AANN-Netz besteht dann nur aus der Eingangs-, der Ausgangs- und der linearen *bottleneck* Schicht.

### 2.4.3 Grundlagen der Informationstheorie

Die im Folgenden beschriebenen Aspekte der Informationstheorie [KÖHLER 2005] liefern eine Grundlage zur Quantifizierung redundanter Information zwischen den Sensorsignalen und somit auch für die Entwicklung von Ansätzen zur datenbasierten Sensorfehlererkennung.

[SHANNON 1948] lieferte mit seiner Definition des Begriffes Information eine wesentliche Grundlage der Informationstheorie. Das Ziel seiner Definition ist die Bereitstellung eines quantitativen Maßes für den Informationsgehalt von Symbolen einer Datenquelle, mit dem ein weitgehend intuitiver Umgang möglich sein soll. Bei gemessenen Schwingungen kann ein Sensor als Datenquelle und die diskret gemessenen Größen als Symbole der Datenquelle interpretiert werden.

Der Informationsgehalt des Symbols einer diskreten Datenquelle  $X$  wird nach [SHANNON 1948] als Maß für die „Überraschung“ des Empfängers definiert, der dieses Symbol erhält. D.h., je geringer die Auftretenswahrscheinlichkeit  $P(x_i)$  eines Symbols  $x$  mit dem diskreten Index  $i$ , desto größer ist die damit verbundene Information. Der Informationsgehalt eines Symbols  $x_i$  der diskreten Datenquelle  $X$  wird wie folgt berechnet

$$H(x_i) = -\log P(x_i), \quad (2.114)$$

wobei  $P(x_i)$  die Auftretenswahrscheinlichkeit von  $x$  zu dem diskreten Zeitpunkt  $i$  ist. Die Entropie, die den Informationsgehalt einer diskreten Datenquelle darstellt, wird gemäß der Shannonschen Definition mit dem Mittelwert der Informationsgehalte der einzelnen Quellensymbole beschrieben, d.h.

$$H(X) = E[H(x_i)] = -\sum_{\forall i} P(x_i) \log P(x_i). \quad (2.115)$$

Dadurch kann die Entropie auch als ein Maß für die Unordnung bzw. die Zufälligkeit eines Systems interpretiert werden. Ein System mit  $H = 0$  stellt ein perfekt geordnetes System dar. Der Informationsgehalt einer Verbundquelle wird als Verbundentropie bezeichnet und ist gegeben mit

$$H(X, Z) = -\sum_{\forall i} \sum_{\forall j} P(x_i, z_j) \log P(x_i, z_j), \quad (2.116)$$

wobei  $P(x_i, z_j)$  die Verbundwahrscheinlichkeit von  $X$  und  $Z$  ist. Diese kann als die Wahrscheinlichkeit des gemeinsamen Auftretens der Ereignisse  $x_i$  und  $z_j$  an einem

gemeinsamen diskreten Zeitpunkt  $(i, j)$  interpretiert werden. Die Entropie besitzt u.a. die Eigenschaft, dass die Gesamtinformation einer Verbundquelle aus der Information besteht, die  $X$  enthält plus der Information, die  $Z$  noch zusätzlich beisteuert, d.h.

$$H(X, Z) = H(X) + H(Z | X). \quad (2.117)$$

In Gl. (2.117) ist  $H(Z | X)$  die bedingte Entropie, d.h. jene Information, die  $Z$  noch erbringen kann, wenn  $X$  bereits bekannt ist. Falls  $X$  und  $Z$  statistisch unabhängig sind, gilt:

$$H(X, Z) = H(X) + H(Z). \quad (2.118)$$

Für die Bewertung der Unterschiedlichkeit zweier Verteilungsdichtefunktionen  $p$  und  $q$  (für diskrete Quellen) stellt die Kullback-Leibler-Distanz ein wichtiges Kriterium dar

$$D[p(x) || q(x)] = \sum_{\forall i} P(x_i) \log \frac{P(x_i)}{Q(x_i)}. \quad (2.119)$$

Die gemeinsame Information (eng. *Mutual Information*, MI), bekannt auch als Transinformation, ist ein Sonderfall der Kullback-Leibler-Distanz. Sie ist definiert als

$$\begin{aligned} MI(X; Z) &= \sum_{\forall i} \sum_{\forall j} P(x_i, z_j) \log \frac{P(x_i, z_j)}{P(x_i)P(z_j)} \\ &= D[P(x_i, z_j) || P(x_i)P(z_j)] \\ &= E \left[ \log \frac{P(x_i, z_j)}{P(x_i)P(z_j)} \right]. \end{aligned} \quad (2.120)$$

Die gemeinsame Information  $MI$  kann auch als die Reduktion der Unsicherheit von  $X$  durch die Kenntnis von  $Z$  und umgekehrt verstanden werden:

$$\begin{aligned} MI(X; Z) &= H(X) - H(X | Z) = H(Z) - H(Z | X) \\ &= H(X) + H(Z) - H(X, Z). \end{aligned} \quad (2.121)$$

Für kontinuierliche Quellen wird die MI anhand von Rand- und Verbundwahrscheinlichkeitsdichtefunktionen  $p(x)$  bzw.  $p(x, z)$  wie folgt definiert:

$$MI(X; Z) = \iint p(x, z) \log \frac{p(x, z)}{p(x)p(z)} dx dz, \quad (2.122)$$

Die Beziehungen zwischen den einzelnen Entropien und der Transinformation sind in einem VENN-Diagramm in Abbildung 2.5 dargestellt.

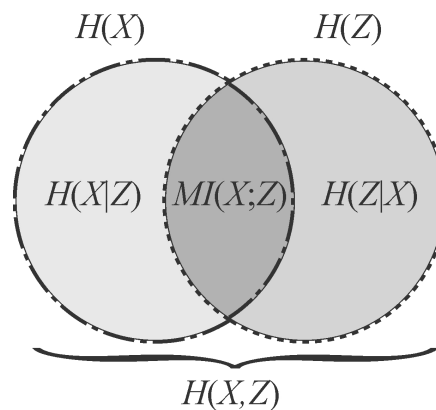


Abbildung 2.5: VENN-Diagramm für verschiedene Entropien

## 2.5 GRUNDLAGEN DER SIGNALANALYSE IM FREQUENZBEREICH

Dieser Abschnitt dient der Erläuterung der Basiswerkzeuge zur Zustandsüberwachung von rotierenden Maschinen im Frequenzbereich. Es werden hauptsächlich die Spektrum-, die Hüllkurvenspektrum-, die Cepstrum- und die Kurtosisanalyse<sup>1</sup> beschrieben, da diese Signalanalyseverfahren momentan den Stand der Technik beim *Condition Monitoring* (CM) von Windenergieanlagen bilden. Diese Grundlagen dienen zum einen dem Vergleich der Ergebnisse der „klassischen“ Verfahren mit denen aus Sicht der Anwendung bei WEAs „neuen“ Ansätzen in Abschnitt 5.2. Zum anderen bildet die folgende Beschreibung die theoretische Grundlage für die Methoden in Kapitel 4.

### 2.5.1 Fourieranalyse und Frequenzspektrum

Die Frequenzanalyse dient dazu, eine Schwingung in ihre Einzelkomponenten hinsichtlich der Frequenz zu zerlegen. Hierbei findet die Fouriertransformation (*FT*) ihre Anwendung. Sie ermöglicht die Überführung von Zeitsignalen in den Frequenzbereich durch die Zerlegung der Zeitfunktionen in die Summe einer unendlichen Anzahl harmonischer Einzelfunktionen mit unendlich fein gestaffelten Frequenzen. In diesem Zusammenhang lässt sich das Zeitsignal  $y(t)$  mit dem zugehörigen Fourierspektrum  $Y(f)$  (Einheit: Signaleinheit/Hz) durch die Gleichung

<sup>1</sup> Kurtosisanalyse wird im Zeit- und Frequenzbereich angewendet.

$$Y(f) = \int_{-\infty}^{\infty} y(t) \cdot e^{-j2\pi f t} dt \quad (2.123)$$

formulieren, vgl. [KOLERUS 2000]. Diese Gleichung wird auch als Fourierintegral bezeichnet. Allerdings ist diese allgemeine *FT* für praktische Anwendungen nur bedingt geeignet, da der Integrationsbereich unendlich ist. Abhilfe schafft hier die diskrete Fouriertransformation (*DFT*), die die allgemeine *FT* näherungsweise berechnet:

$$Y_q = FT(\mathbf{y}) = \sum_{k=0}^{n_t-1} y_k e^{-j \frac{2\pi k q}{n_t}}, \quad (q = 0, 1, \dots, n_t - 1). \quad (2.124)$$

Bei dieser Abwandlung wird ein Zeitsignalausschnitt endlicher Länge zugrunde gelegt, nach beiden Seiten implizit periodisch fortgesetzt und daraus eine Fourierreihe als Näherung berechnet.  $Y_q$  wird als finites Fourierspektrum der diskreten Zeitfunktion  $\mathbf{y}$  der Länge  $n_t$  oder als Frequenzspektrum bezeichnet.

Die digitale Berechnung bringt einige Besonderheiten mit sich, die bei der Signalanalyse beachtet werden müssen [KOLERUS 2000]:

- Durch die zeitdiskrete Abtastung eines Messsignals ergeben sich Verzerrungen, sobald die Abtastfrequenz gegenüber dem Frequenzgehalt des Signals zu klein ist. Diese Verzerrungen werden auch als Bandüberlappung oder Aliasing bezeichnet. Nach dem SHANNONSches Abtasttheorem sollte die Abtastfrequenz daher mindestens doppelt so groß sein, wie die höchste im Signal vorkommende Frequenz.
- Die Zeitbegrenzung der Abtastung („Zeit-“ oder „Analysefenster“) führt zum Auftreten von Seitenbändern im Frequenzbereich. Entspricht die Beobachtungsdauer nicht der Periodendauer der in dem Signal enthaltenen Frequenzen oder deren ganzzahligen Vielfachen, so beeinflussen diese Seitenbänder das diskrete Spektrum beispielsweise durch das Auftreten zusätzlicher Frequenzkomponenten. Dieses Phänomen wird als *Leakage*-Effekt bezeichnet. Durch spezielle Bewertungsfunktionen im Zeitfenster, wie z.B. das HANN-Fenster, kann dieser Effekt gemindert, jedoch nicht gänzlich vermieden werden.

Im Kontext einer Frequenzidentifikation wird oft das Amplitudenspektrum zur Betrachtung der in einem Signal enthaltenen Frequenzen angewendet. Dieses beschreibt die Amplituden, die im Signal im jeweiligen Frequenzbereich vorkommen. Physikalisch besser zu deuten ist hingegen das Leistungsdichtespektrum (engl.: *power spectral density*, PSD, Einheit:

Signaleinheit<sup>2</sup>/Hz). Die Fläche unterhalb der PSD entspricht der mittleren Leistung (quadratische Größe), die im Signal im jeweiligen Frequenzbereich enthalten ist.

Das Leistungsdichtespektrum beschreibt also die Verteilung der Leistung eines stationären Signals  $y$  über dem Frequenzbereich. Vor der Angabe der Gleichung des Leistungsdichtespektrums wird zuerst das Leistungsspektrum (Einheit: Signaleinheit<sup>2</sup>) eingeführt. Dieses wird durch den Erwartungswert der quadrierten absoluten Fouriertransformierten bestimmt [SWAMI *et al.* 2001]:

$$P_{yy}(f) = E[Y(f) \cdot Y^*(f)] = E[|Y(f)|^2]. \quad (2.125)$$

Das Leistungsspektrum kann aber auch nach dem Wiener-Khintchine Theorem als die Fouriertransformation der Autokorrelationsfunktion  $r_{yy}$  gedeutet werden [SWAMI *et al.* 2001]:

$$P_{yy}(f) = FT(\mathbf{r}_{yy}) \quad \text{mit} \quad (\mathbf{r}_{yy})_\tau = E[y_k \cdot y_{k+\tau}^T]. \quad (2.126)$$

Das Leistungsdichtespektrum kann nun einfach durch die Normierung des Leistungsspektrums mit der Abtastfrequenz  $f_s$  berechnet werden:

$$S_{yy}(f) = P_{yy}(f) / f_s. \quad (2.127)$$

Numerisch berechnet wird das Leistungsdichtespektrum in dieser Arbeit mit der Methode nach WELCH, bei der das Signal in eine definierte Anzahl sich überlappender Fenster unterteilt wird. Nähere Informationen sind in [WELCH 1963] zu finden.

### 2.5.2 Das Hüllkurvenspektrum

Das Hüllkurvenspektrum wird in der Regel in der Maschinenüberwachung zur Identifikation von Impulsfolgefrequenzen verwendet. Diese erscheinen als sogenannte Peaks, die eine Zeit lang aufgrund der Maschinenresonanz nachschwingen. Es wird also ein durch die Impulsfolge amplitudenmoduliertes Signal wahrgenommen. Ziel der Hüllkurvenbildung ist es, das Signal so zu demodulieren, dass nur noch die angesprochene Impulsfolgefrequenz übrig bleibt. Dieses Vorgehen ist aus der Nachrichtentechnik bekannt. Hier wird ein hochfrequentes Trägersignal mit dem Nutzsignal amplitudenmoduliert, um eine effizientere Übermittlung zu gewährleisten, vgl. Abbildung 2.6, links. Beim Empfänger wird durch die Hüllkurvenbildung das Nutzsignal vom Trägersignal getrennt bzw. demoduliert.

Im Vergleich zum Leistungsdichtespektrum des ursprünglichen Zeitsignals bietet das Hüllkurvenspektrum Vorteile in der Darstellung der relevanten Frequenzen. Während beim

Leistungsdichtespektrum hauptsächlich die Trägerfrequenz  $f_T$  angezeigt wird und die Modulationsfrequenz  $f_M$  lediglich als Seitenbänder auftauchen (siehe Abbildung 2.6), wird beim Hüllkurvenspektrum nur die Modulationsfrequenz angezeigt. Diese entspricht bei der Maschinendiagnose der „Schadensfrequenz“, während die unwichtige Trägerfrequenz beispielsweise einer Resonanzfrequenz der Maschine darstellt.

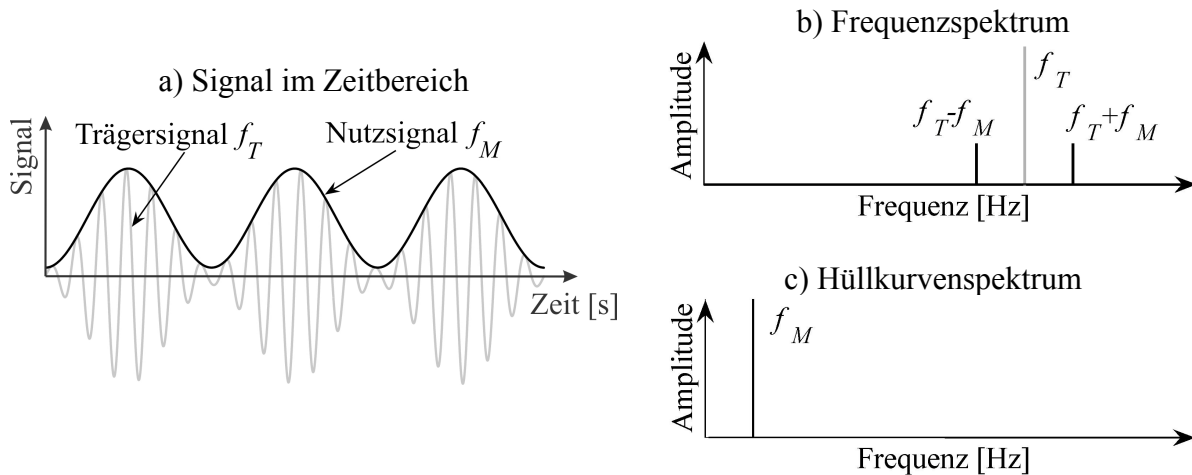


Abbildung 2.6: Vergleich Frequenzspektrum und Hüllkurvenspektrum

Die Hüllkurve kann auf mehrere Arten aus dem Zeitsignal extrahiert werden. Sowohl analog als auch digital kann das Signal hochpassgefiltert bzw. bandpassgefiltert, gleichgerichtet und anschließend tiefpassgefiltert werden [KLEIN 2003]. Eine Hochpassfilterung lässt nur die hochfrequenten Trägerfrequenzen durch. Mit dem Tiefpassfilter werden die Trägerfrequenzen unterdrückt, so dass nur die Hüllkurve verbleibt. Für diese Vorgehensweise muss jedoch bekannt sein, wie groß die Trägerfrequenz ungefähr ist.

Die Hüllkurve kann jedoch auch, wie häufig in der Praxis und auch in dieser Arbeit angewendet, mittels der Hilberttransformation gewonnen werden. Anschaulich formuliert, wird das Signal  $y$  hierbei fouriertransformiert, um  $90^\circ$  phasenverschoben und anschließend wieder rücktransformiert [KLEIN 2003]. Man erhält ein Signal  $y^{Hil}$ , dessen Realteil  $\text{Re}(y^{Hil}) = y$  das ursprüngliche Signal wiedergibt und dessen Imaginärteil  $\text{Im}(y^{Hil})$  die Hilberttransformierte ist:

$$y^{Hil} = \text{Re}(y^{Hil}) + j \cdot \text{Im}(y^{Hil}). \quad (2.128)$$

Der Betrag dieses Signals entspricht dann genau der Hüllkurve. Für eine genauere Erklärung der Hilberttransformation und auf die numerische Implementierung sei auf [OPPENHEIM 1998]



verwiesen. Wurde die Hüllkurve extrahiert, kann nun über die Fouriertransformation das Hüllkurvenspektrum berechnet werden.

### 2.5.3 Cepstrumanalyse

Die Cepstrumanalyse ist ein Verfahren, das unter anderem der Detektion regelmäßiger Strukturen in einem Frequenzspektrum dient [KOLERUS 2000]. Solche regelmäßigen Strukturen kommen oft im Zusammenhang mit Stoßimpulsen vor, bei denen verstärkt Harmonische und Seitenbandfamilien zum Vorschein kommen, wie es zum Beispiel bei defekten Verzahnungen der Fall ist. Neben dem Bereich der Zustandsüberwachung findet die Cepstrumanalyse vornehmlich in der Sprachanalyse und -erkennung [RANDALL 1987] sowie in der biomedizinischen Signalverarbeitung ihre Anwendung [BIGE 2006].

Allgemein wird das Cepstrum  $C_{yy}$  als die inverse Fouriertransformation einer logarithmierten Frequenzbereichsfunktion definiert:

$$C_{yy}(\tau) = FT^{-1}(\log F(f)). \quad (2.129)$$

Hierbei ist  $F(f)$  ein Amplitudenspektrum eines bereits fouriertransformierten Zeitsignals.  $FT^{-1}$  repräsentiert die inverse Fouriertransformation. Aus dieser Umkehrung stammt auch der Begriff *Cepstrum*, der durch eine Umkehrung der ersten Silbe von *Spectrum* (eng. für Spektrum) gebildet wird. In ähnlicher Weise sind auch weitere Bezeichnungen im Zusammenhang mit der Cepstrumanalyse entstanden, deren Pendanten aus der Spektralanalyse stammen:

Spektrum	→	Cepstrum
Frequenz	→	Quefrenz
Harmonische	→	Rahmonische
Magnitude	→	Gamnitude.

Durch die inverse Fouriertransformation erhält man für die Quefrenz  $\tau$  eine Zeiteinheit, die auf der Abszisse angetragen wird.

In der Praxis wird anstatt des normalen Cepstrums, analog zum Frequenz- und Leistungsspektrum das Leistungscepstrum  $LC_{yy}$  bevorzugt. Dieses ist das aus dem Leistungsspektrum  $P_{yy}(f)$  (siehe Gl. (2.125)) abgeleitete Cepstrum:

$$LC_{yy}(\tau) = FT^{-1}(\log P_{yy}(f)). \quad (2.130)$$

Wie bereits erwähnt, können mit Hilfe der Cepstrumanalyse Harmonische und Seitenbänder detektiert werden. Sind im Spektrum unter anderem mehrere Pegelmaxima mit dem Abstand  $\Delta f$  vorhanden, so erhält man im Cepstrum bei der entsprechenden Queffenz eine besonders hohe Amplitude.

Dieser Zusammenhang wird in Abbildung 2.7 verdeutlicht. Hier ist im Diagramm (a) ein Zeitsignal dargestellt, das alle 0,01 s einen Impuls erhält und mit einer Resonanzfrequenz von 4000 Hz jeweils kurz nachschwingt. Im normierten Frequenzspektrum (b) wird dies mit der höchsten Amplitude bei 4000 Hz deutlich. Die Seitenbänder im Abstand von 100 Hz entsprechen der Impulsfolge im Zeitsignal ( $f = 1/T = 1/0,01 \text{ s} = 100 \text{ Hz}$ ). Im Cepstrum wird nur noch die Queffenz bei 10 ms, entsprechend der Impulsfolge, und deren Rahmonische bei 20 ms, 30 ms, ... angezeigt. Die für die Zustandsdiagnose unwichtige Resonanzfrequenz von 4000 Hz, entsprechend einer Queffenz von 0,25 ms, ist hier jedoch nicht mehr zu finden, da das Cepstrum lediglich Periodizitäten im Frequenzspektrum wiedergibt, nicht jedoch einzelne größere Amplituden.




Abbildung 2.7: a) Zeitsignal, b) entsprechendes Frequenzspektrum und c) Cepstrum

### 2.5.4 Die spektrale Kurtosis

Zum Verständnis der spektralen Kurtosis ist es sinnvoll, die Kurtosis im Zeitbereich zunächst näher zu erläutern. Sie beschreibt die Wölbung oder den Exzess und damit die Spitzhaltigkeit<sup>1</sup> eines Signals  $y(t)$  und berechnet sich folgendermaßen:

$$\kappa_y = \frac{E[y^4] - 3E[y^2]^2}{E[y^2]^2} = \frac{E[y^4]}{E[y^2]^2} - 3. \quad (2.131)$$

Im Folgenden wird der Exzess als Kurtosis bezeichnet, obwohl die Kurtosis formal als „Exzess + 3“ definiert ist. Die Kurtosis beschreibt die Abweichung des Verlaufs einer gegebenen Wahrscheinlichkeitsverteilung vom Verlauf einer Normalverteilung [VRABIE *et al.* 2003]. Die Wahrscheinlichkeitsverteilungen werden entsprechend ihrer Kurtosis  $\kappa$  unterschiedlich bezeichnet:

- $\kappa = 0$ : normalgipflig oder mesokurtisch → beispielsweise die Normalverteilung
- $\kappa > 0$ : steilgipflig oder leptokurtisch → spitzere Verteilungen als Normalverteilung, Verteilungen mit starken Peaks
- $\kappa < 0$ : flachgipflig oder platykurtisch → abgeflachte Verteilung im Vergleich zur Normalverteilung

Im Frequenzbereich wird die spektrale Kurtosis (SK) als die Kurtosis einzelner Frequenzkomponenten definiert und ist damit im Gegensatz zur Kurtosis eine vektorielle Größe. [VRABIE *et al.* 2003] haben die folgende Formel zur Berechnung der spektralen Kurtosis hergeleitet:

$$K_y(f) = \frac{E[|Y(f)|^4] - 2E[|Y(f)|^2]^2}{E[|Y(f)|^2]^2} = \frac{E[|Y(f)|^4]}{E[|Y(f)|^2]^2} - 2. \quad (2.132)$$

Mit Hilfe der spektralen Kurtosis lässt sich beurteilen, ob eine bestimmte, im Frequenzspektrum auftretende Frequenz aus einer stochastischen, harmonischen oder nichtstationären Komponente des Signals resultiert:

- für  $K_y = 0$ : stationärer normalverteilter stochastischer Teil eines Signals,
- für  $K_y = -1$ : stationärer harmonischer Teil eines Signals,
- für  $K_y > 0$ : nichtstationärer Teil eines Signals.


---

<sup>1</sup> Vorausgesetzt wird, dass sich Schäden oft in impulshaltigen Signalen wieder spiegeln.

Das folgende Beispiel veranschaulicht die Eigenschaften der spektralen Kurtosis. Hierfür wird ein Signal angenommen, welches aus drei Signalkomponenten besteht:

- ein nichtstationäres Signal, das über die Zeit einen linearen Frequenzanstieg zwischen 0,06 und 0,09 Hz vorweist,
- ein reines Sinussignal mit der Frequenz 0,2 Hz,
- ein um die Frequenz 0,4 Hz band-pass gefiltertes weißes Rauschen.

Das Leistungsdichtespektrum (PSD) und die spektrale Kurtosis sind der Abbildung 2.8 zu entnehmen. Bei der spektralen Kurtosis ist die nichtstationäre Komponente bei ca. 0,08 Hz deutlich sichtbar. Diese hat eine positive Auslenkung im Spektrale-Kurtosis-Diagramm. Die Auslenkung bei 0,2 Hz im Leistungsdichtespektrum, wird mittels der spektralen Kurtosis als harmonisch und stationär identifiziert. Das gefilterte Rauschen hingegen kommt bei der spektralen Kurtosis im Gegensatz zum Leistungsdichtespektrum nicht zum Vorschein, da es normalverteilt ist.



**Abbildung 2.8: Leistungsdichtespektrum und spektrale Kurtosis eines Signal mit drei Komponenten**

Mit Hilfe der spektralen Kurtosis lässt sich somit beurteilen, in welchem Frequenzbereich die durch Schäden hervorgerufenen Impulsfolgen am Besten identifiziert werden können. In der Regel werden diese als Harmonische der Schadensfrequenz in der Nähe von Resonanzfrequenzen der Maschine entdeckt.

Im folgenden Kapitel werden die hier vorgestellten Grundlagen zur Erweiterung bzw. Entwicklung von Methoden zur Schadensdiagnose an der Struktur und später an den Maschinenkomponenten von WEAs verwendet.

### 3 STRUKTURSCHADENS DIAGNOSE

Das Kapitel 3 stellt das entwickelte Gesamtkonzept zur Schadenserkennung für den Turm und Tripod einer OWEA vor. Zu Beginn werden einige spezifische Eigenschaften der Anlagen bzgl. der eigenen Dynamik und die daraus entstehenden Anforderungen an die Algorithmen zur Schadenserkennung erläutert. Nach der Vorstellung des Konzeptes, wird jedes Modul der Schadenserkennungsstrategie detailliert beschrieben. Hierbei erfolgt zuerst die Beschreibung der Schadensdetektion bei veränderlichen Umgebungs- und Betriebszuständen (EOC), gefolgt von den in der Literatur vorhandenen Methoden. Anschließend wird die Berechnung von Schädigungsindikatoren unter Berücksichtigung der EOC Einflüsse mit Hilfe von Klassifikationsverfahren vorgestellt. In einem nächsten Abschnitt wird sowohl eine Methode zur Modalanalyse mit Hilfe von ARV-Modellen als auch eine modellgestützte Schadenslokalisationsmethode basierend auf der inversen Eigenwert- und Eigenformsensitivität präsentiert. Das Kapitel schließt mit der Vorstellung einer weiteren wichtigen Komponente des Gesamtkonzeptes ab: die Sensorfehleridentifikation. Wie bei der Schadenserkennung werden auch hier einige Ansätze aus der Literatur präsentiert und anschließend die entwickelten Methoden zur Sensorfehlerisolation und Signalrekonstruktion erläutert.

Um das Gesamtkonzept anschaulich zu präsentieren, wird die Methodenbeschreibung begleitet von Simulationen und Messungen an dem OWEA-Prototyp M5000-2 der Fa. AREVA-Wind.

#### 3.1 ANFORDERUNGEN AN SCHADENSERKENNUNGSMETHODEN FÜR OFFSHORE-WINDENERGIEANLAGEN

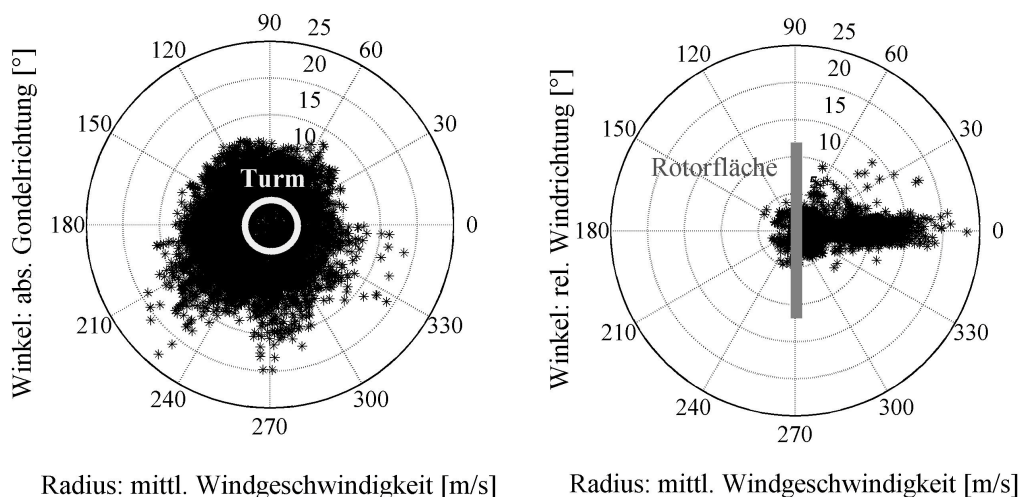
Die Anforderungen an geeignete Methoden zur Schadenserkennung an OWEA-Strukturkomponenten werden unter Berücksichtigung der Bauart und der spezifischen Betriebs- und Umgebungszustände der Anlage formuliert.

Die OWEAs mit Tripod-Fundament sind „schwingungsfreudige“, massive Strukturen aus Stahl. Die Wanddicken einer solchen Anlage betragen mindestens vier Zentimeter, so dass die Struktur der Anlage nur mit hohem Aufwand aktiv angeregt werden könnte. Bedingt durch ihre Größe ist ein dichtes Sensornetzwerk zur lokalen Überwachung aller Turm- und Tripodsegmente sehr kostenintensiv und nur schwer realisierbar. Der heutige Kenntnisstand über die tatsächlichen *hot spots* der Anlage erlaubt noch keinen ausschließlichen Einsatz

lokaler Überwachungstechniken mit aktiver Anregung, da Schäden, die nicht antizipiert werden, nicht identifizierbar sind.

Aus den oben genannten Gründen beschränkt sich diese Arbeit auf die Analyse von Daten mit Hilfe globaler *Output-Only*-Überwachungsmethoden. Hierbei werden Schwingungen, hervorgerufen aus der natürlichen Anregung der Struktur durch Wind und Wellen, mit einem auf der Gesamtstruktur verteilten, relativ groben Sensornetzwerk betrachtet.

Bei einer Auswahl geeigneter globaler Verfahren zur Schadensüberwachung müssen weiterhin die Änderungen in den Betriebs- und Umgebungszuständen der Anlage berücksichtigt werden: Windgeschwindigkeit, Windrichtung, Wellenhöhe, Temperatur und weitere atmosphärische Bedingungen, Position der Gondel, Pitchwinkel und Rotordrehzahl, Kolkungszustand, etc. Alle diese Parameter ändern sich mit der Zeit und verändern somit das dynamische Verhalten der Struktur. So beeinflusst z.B. die Windrichtung die Position der Gondel und damit die Turmeigenfrequenzen. Dieses Verhalten lässt sich mit der Unsymmetrie der Struktur der OWEA über die Turmachse (Transformatoren, Pumpen, etc. sind in dem Turm installiert) begründen, da Änderungen der Gondelposition zu Veränderungen in der Massenverteilung bzw. Massenträgheitsmomente des Turms führen. Abbildung 3.1 zeigt in einem Polardiagramm die über 10 Min. gemittelten Werte für die Gondelposition über der mittleren Windgeschwindigkeit (links) sowie die relative Windrichtung zur Gondelposition über der mittleren Windgeschwindigkeit (rechts) ermittelt an der Anlage M5000-2 während eines Jahres.



**Abbildung 3.1: Absolute Gondelrichtung (links) und relative Windrichtung (rechts) am OWEA Prototyp M5000-2 der Firma AREVA-Multibrid**

Auch die Temperatur trägt zu Veränderungen der Turmeigenfrequenzen bei. Einige Mittelwerte der Außentemperatur ermittelt an der Anlage M5000-2 über den Zeitraum eines Jahres aus 8759 Messdatensätzen sind in Abbildung 3.2 dargestellt. Hierbei können Temperaturspannen von bis zu 45°C beobachtet werden.

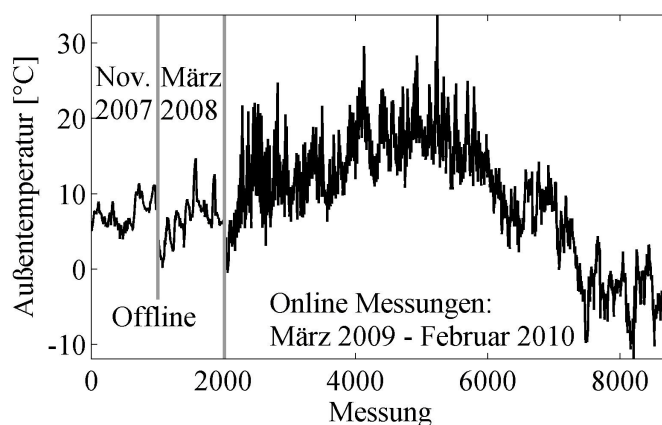


Abbildung 3.2: Temperaturänderungen an der OWEA M5000-2

Weitere Änderungen der Strukturodynamik ergeben sich aus der Struktur Anregung, welche die Betriebszustände bedeutend verändern können. Daher werden im Folgenden zunächst die wichtigsten Anregungsquellen einer OWEA erläutert.

#### *Stochastische Anregungsquellen*

Eine der wichtigsten Anregungsquellen für eine Windenergieanlage ist die stochastische, tieffrequente Anregung durch den Wind, die in der Fachliteratur auch als aerodynamische Anregung bekannt ist [GASCH und TWELE 2005]. Der Wind ist in den meisten Fällen WEIBULL-verteilt und regt Struktureigenfrequenzen im Bereich von etwa 0,2 bis 10 Hz an, [GASCH und TWELE 2005]. Abbildung 3.3 zeigt beispielhaft die Leistungsdichte der Windgeschwindigkeit (Böenspektrum), berechnet über einem Tag, bei einer mittleren Windgeschwindigkeit von ca. 11 m/s mit einer Turbulenzintensität<sup>1</sup> von ca. 13%. Hier ist zu erkennen, dass Windböen mit Frequenzen bis 3 Hz stärker in der Windböenleistungsdichte vertreten sind. Höhere Frequenzen haben ein geringes Anregungspotential. Der Peak bei ca. 0,75 Hz entsteht durch einem Strömungsabriss hinter einem Rotorblatt, wenn dieses bei Nenndrehzahl des Rotors die Messinstrumente passiert.

---

<sup>1</sup> Berechnet sich aus der Standardabweichung bezogen auf die mittlere Windgeschwindigkeit und repräsentiert prozentual die Schwankung in der Leistung der Windböe.




Abbildung 3.3: Windgeschwindigkeit und Böenspektrum

Die Anregung durch Windböen wird oft nach der mittleren oder Median-Windgeschwindigkeit und der Turbulenzintensität klassifiziert, siehe auch [GASCH und TWELE 2005]. Die statistischen Kennwerte ermitteln sich aus Zeitreihen gemessen über 10 Minuten. Die Anzahl der Aufzeichnungen - also die Häufigkeit - für unterschiedliche Klassen von Windgeschwindigkeiten und Turbulenzintensitäten werden in einer sog. *Capture-Matrix* dargestellt. Abbildung 3.4 zeigt beispielhaft die *Capture-Matrix* für 8759 Aufzeichnungen der Anlage M5000-2.

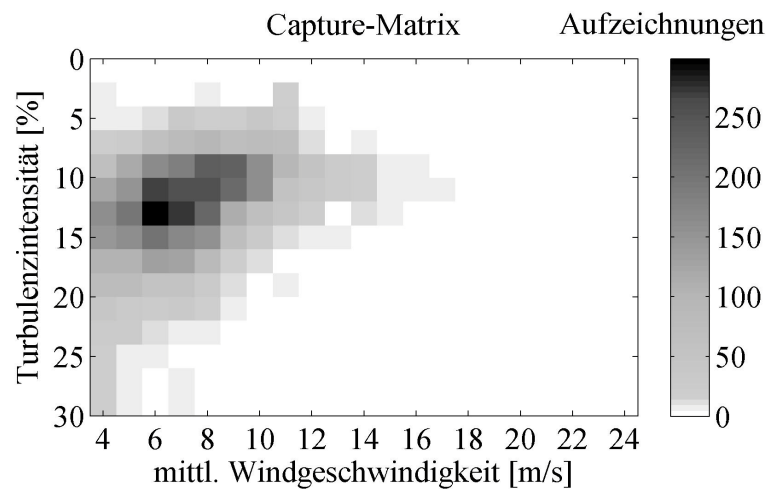


Abbildung 3.4: Capture-Matrix der Anlage M5000-2

OWEA werden neben dem Wind auch durch Wellen angeregt. Wellen werden als PIERSON-MOSKOWITZ-verteilt angenommen und kommen mit niedrigen Frequenzen vor [NICHOLS 2003]. Abbildung 3.5 zeigt beispielhaft ein simuliertes Spektrum und die daraus resultierenden unidirektionalen Wellen bei einem häufig auftretenden Wellengang mit einer Wellenhöhe von 0,5 m.






Abbildung 3.5: Simuliertes Wellenspektrum und Wellengang

### Periodische Anregungsquellen

Auch die Rotordrehzahl  $\Omega$  spielt eine wichtige Rolle bei der Anregung. Die Rotation der Blätter führt zu einem Strömungsabriss, wenn ein Rotorblatt den Turm passiert. Dadurch wird der Turm einer Anlage mit drei Rotorblättern u.a. immer mit einer Frequenz von  $3\Omega$  periodisch angeregt. Eine weitere Anregung, die an die Rotordrehzahl gekoppelt ist, entsteht aus der Massenunwucht der Rotorblätter. Diese regen den Turm periodisch mit  $\Omega$  an. Abbildung 3.6, links, zeigt beispielhaft anhand eines *Campbell*-Diagramms aus Kenndaten der M5000-2, bei welchen Rotordrehzahlen die erste Eigenfrequenz der Anlage durch die Turm-Blatt-Passage angeregt wird. Im ungünstigsten Fall (hier bei ca. 8-9 1/min) kann der Turm in Resonanz versetzt werden. Abbildung 3.6 rechts zeigt, dass die Wirkung der Rotorblatt-Passage auf die Anregung der ersten Eigenfrequenz einen deutlich stärkeren Einfluss hat als die Anregung durch den Wind.

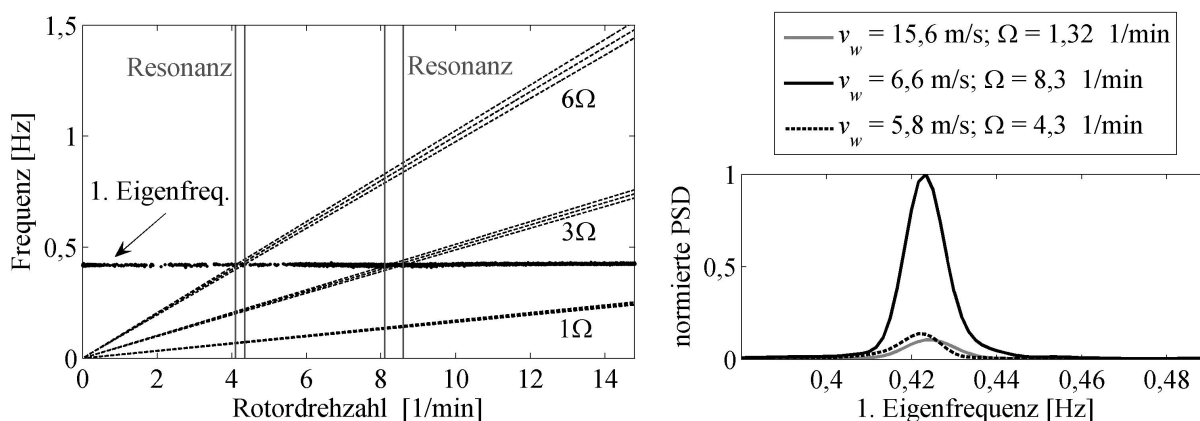


Abbildung 3.6: Campbell-Diagramm (links), Leistungsichte von Beschleunigungssignalen bei unterschiedlichen Windgeschwindigkeiten und Rotordrehzahlen (rechts)

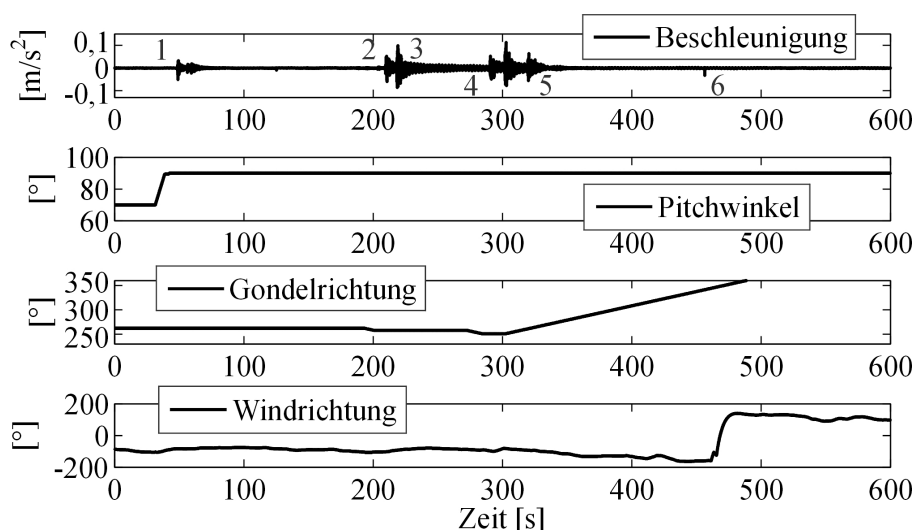
Eine weitere Quelle, die zu einer periodischen Anregung einer OWEA führt, entsteht aus dem sog. Windpark-Effekt. Hierbei handelt es sich um die Anregung durch Windböen von

Anlagen, die im Windnachlauf anderer Anlagen positioniert sind. Diese Böen entstehen aus der Windpassage der Rotorblätter vorstehender Anlagen.

### *Transiente Anregungsquellen*

Transiente Anregungen des Turmes entstehen hauptsächlich durch Manövriervorgänge der Gondel und der Rotorblätter. Es kommt oft vor, dass bei niedriger Windgeschwindigkeit die Position der Rotorblätter und der Gondel geändert werden, um aus dem vorhandenen Wind einen besseren Auftrieb zu erzielen. Dadurch entstehen plötzliche Änderungen der Massen- und Kräfteverteilungen, aus denen transiente Anregungen der Anlage resultieren. Weitere tieffrequente Anregungen ergeben sich aus Bremsmanövern. Auch plötzlicher Seitenwind oder extreme Windböen regen die Anlagen transient an.

Ein typisches Beispiel für eine transiente Anregung zeigt Abbildung 3.7. Das obere Teildigramm zeigt die über zehn Minuten gemessenen transienten Veränderungen in einem Signal eines auf dem Turm positionierten Beschleunigungsaufnehmers bei einer mittleren Windgeschwindigkeit von ca. 1,6 m/s. Der erste „Ausschlag“ wurde durch eine Änderung des Pitchwinkels verursacht, welcher kurzfristig einen besseren Auftrieb der Blätter eingeleitet hat. Die Peaks zwei bis fünf wurden durch die mehrfache Änderung der Gondelposition infolge einer geringfügigen Windrichtungsänderung ausgelöst. Die Änderungen von Pitchwinkel, Gondel- und Windrichtung sind in Abbildung 3.7 unterhalb des Beschleunigungsverlaufs dargestellt.




**Abbildung 3.7: Beispiel einer transienten Anregung durch Betriebsmanöver**

Die obengenannten Anregungsquellen bringen alle Komponenten einer Anlage in Schwingung, wobei die Vibrationen einzelner Komponenten wiederum weitere Teile des

Systems anregen. Dadurch entstehen sog. Koppelschwingungen zwischen Turm und Rotorblättern und zwischen Rotorblättern und Triebstrang.

Ein Nachweis der Instationarität der gemessenen Signale, verursacht durch die gleichzeitige Wirkung unterschiedlicher Anregungsquellen und unterschiedlicher Umgebungseinflüsse auf die Dynamik einer WEA, kann Abbildung 3.8 entnommen werden. Hier zeigen die Wahrscheinlichkeitsdichtefunktionen (eng. *probability density function*, PDF) der Turmkopfbeschleunigung<sup>1</sup> in Hauptwindrichtung, dass sich die statistischen Eigenschaften der Signale bedeutend mit der Zeit ändern.



**Abbildung 3.8: Wahrscheinlichkeitsdichtefunktionen einer Turmkopfbeschleunigung**

Nachweise für die Änderung der Dynamik der Strukturen in Abhängigkeit der EOCs, sowie Problemstellungen bei der Zustandsüberwachung von OWEAs bei veränderlichen Betriebs- und Umgebungseinflüssen werden auch beispielweise in [KULLAA 2003; ROHRMANN *et al.* 1999; ROHRMANN *et al.* 2007; RÜCKER 2007; SOHN 2007] vorgestellt.

Abschließend zu Abschnitt 3.1 lässt sich zusammenfassen, dass für eine globale Überwachung des Turmes bei unbekannter Anregung *Output-Only*-Methoden aus der Schwingungsanalyse im tieffrequenten Bereich verwendet werden. Gleichzeitig wird auch den spezifischen Betriebs- und Umgebungseinflüssen auf die Dynamik der Anlage sowie dem Einfluss der Anregung auf die gemessenen Signale Rechnung getragen.

Unter Berücksichtigung dieser Gegebenheiten und Anforderungen ist zunächst ein Gesamtüberwachungskonzept entwickelt worden, das im Folgenden detailliert vorgestellt wird.

### 3.2 DAS ÜBERWACHUNGSKONZEPT

Das Gesamtüberwachungskonzept besteht aus dem Aufbau unterschiedlicher Stufen der Schadensidentifikation in deren natürlicher Reihenfolge. Dieses wurde in [FRITZEN und

---

<sup>1</sup> Anlage M5000-2: 8759 Zeitreihen je 10 Min. Messdauer, gemessen am Sensor  $y_1$ , dargestellt in Abbildung 5.11.

KRAEMER 2009; FRITZEN *et al.* 2008; KRAEMER und FRITZEN 2007a; KRAEMER und FRITZEN 2008a] vorgestellt. In Abbildung 3.9 ist das Schadensdiagnosekonzept zur Überwachung einer OWEA schematisch dargestellt.

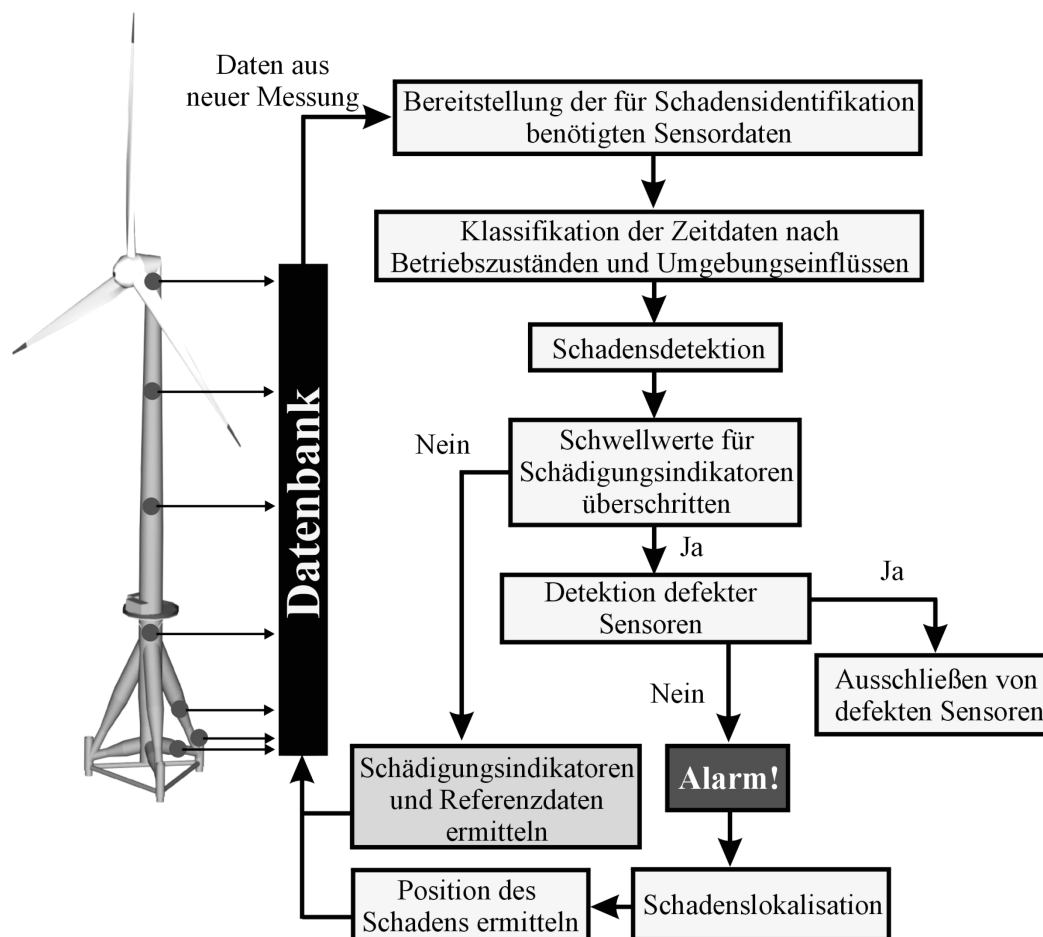


Abbildung 3.9: Gesamtüberwachungskonzept

Ausgehend von einer Datenbank werden dem Datenanalyzesystem zuerst die benötigten Messdaten bereitgestellt. Anhand einer anschließenden Ausreißeranalyse (siehe Abschnitt 3.3.4) wird die Entscheidung getroffen, ob die Daten zur Schadensidentifikation auf Basis von *Output-Only-Methoden* überhaupt geeignet sind.

In einem weiteren Schritt lassen sich die Daten nach den auf die Anlage einwirkenden Umgebungseinflüssen (Windgeschwindigkeit, Temperatur, etc.) sowie nach den Betriebszuständen der Anlage (Position der Gondel, etc.) klassifizieren. Die Schadensdetektion wird auf Basis von Residuen identifizierter Systeme für jede Klasse separat durchgeführt (vgl. Abschnitt 3.3.2). Sollte die Schadensdetektionsmethode eine Änderung in den Signalen feststellen, die nicht auf eine Änderung in den Betriebs- oder Umgebungseinflüssen zurückzuführen ist, so muss sichergestellt werden, ob diese Änderung tatsächlich Folge eines

Strukturschadens ist, oder ob lediglich ein Sensorfehler vorliegt. Erst jetzt wird das Modul zur Detektion defekter Sensoren eingeschaltet. Wie in Abschnitt 3.5 dargestellt, ist ein solches Modul notwendig, da Sensorfehler das Ergebnis der Schadensidentifikationsmethoden verfälschen. Besonders unter rauen Umgebungsbedingungen, wie auf dem Meer, kann die Lebensdauer der Sensoren und Messverstärker wesentlich kürzer sein, als unter „normalen“ Bedingungen. Wenn ein Sensorfehler aufgetreten ist, wird dieser Sensor von nun an von dem Schadensidentifikationsalgorithmus ausgeschlossen.

Sollte allerdings nach einer Signaländerung kein Sensorfehler gemeldet werden, dann ist mit einer gewissen Wahrscheinlichkeit ein Strukturschaden eingetreten. Nach der Alarminitialisierung wird das Modul zur Schadenslokalisierung aktiviert. Die Schadenslokalisierung erfolgt modellgestützt. Sie nutzt die aus den Messdaten extrahierten Modaldaten und basiert auf der Lösung eines inversen Problems, siehe Abschnitt 3.4.

In einem letzten Schritt werden die Indikatoren des Anlagen- und Messsystemzustandes an den Betreiber der Anlage übermittelt.

### **3.3 SCHADENSDETEKTION UNTER VERÄNDERLICHEN UMGEBUNGS- UND BETRIEBSZUSTÄNDEN**

Wie schon erwähnt ist die Berücksichtigung der EOCs bei der Schadenidentifikation sehr wichtig, da Veränderungen in den Signalmerkmalen nicht nur durch Schäden, sondern auch durch Veränderungen der Umgebungs- und Betriebszustände eines Systems hervorgerufen werden. Diese Problematik rückte in den letzten Jahren zunehmend in den Fokus, sodass eine Reihe von Methoden zur EOC-Kompensation entwickelt wurde. Diese werden in Abschnitt 3.3.1 zusammengestellt und dienen lediglich zur Erklärung der in Abschnitt 3.3.2 und 3.3.3 entwickelten Algorithmen.

#### **3.3.1 Beschreibung existierender Methoden und Einführung in die Problematik der EOC-Kompensation**

Um die Anwendbarkeit existierender Methoden zur EOC-Kompensation auf die spezielle Problematik der Schadenserkenkung an OWEAs zu überprüfen, werden einige Methoden vorgestellt. Nach [SOHN 2007] lassen sich die Ansätze in zwei Kategorien unterteilen:

- Methoden, die Messungen der EOC Variablen nicht benötigen.
- Methoden, die direkte Messungen der EOC Variablen nutzen.

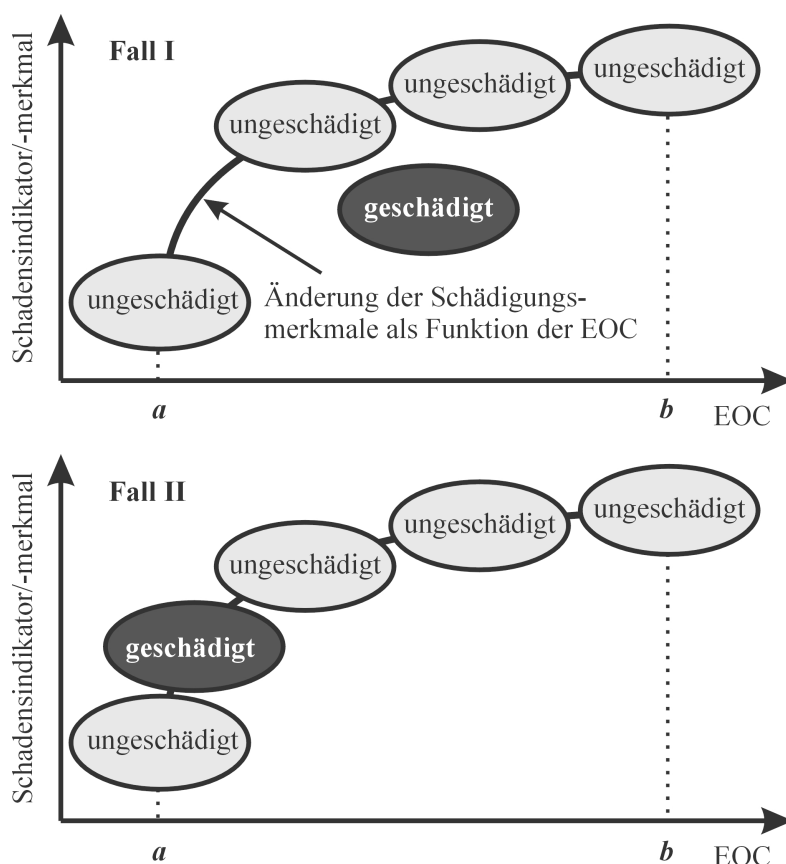
Das Ziel aller Ansätze ist, Schädigungssignaturen oder –merkmale (sog. *features*) in den gemessenen Zeitdaten in Form von Schädigungsindikatoren bereit zu stellen. Diese sollen möglichst sensitiv gegenüber Schäden und nicht sensitiv gegenüber Änderungen der EOCs sein. Daher sind diese Methoden prinzipiell so zu gestalten, dass unerwünschte Effekte der EOCs auf die extrahierten Merkmale minimal sind. Dieses Ziel ist allerdings mit *Output-Only*-Methoden und Schädigungsmerkmalen basierend auf charakteristischen tieffrequenten Schwingungen von OWEAs schwer realisierbar. Für diesen Fall gilt das in [WORDEN *et al.* 2005] erläuterte Prinzip: „Je sensitiver ein Schädigungsmerkmal gegenüber Strukturschäden ist, desto sensitiver ist es auch gegenüber EOC-Veränderungen“.

Beide oben erwähnte Klassen von Methoden zur EOC-Kompensation gehen davon aus, dass die Schädigungsmerkmale des ungeschädigten Zustandes als lineare oder nicht-lineare Funktionen der EOCs beschrieben werden können. Grenzen sich die geschädigten Zustände von der Funktion des ungeschädigten Zustands ab, so werden die EOCs nicht benötigt. Fallen aber geschädigte Zustände mit der Funktion der ungeschädigten Zustände zusammen, so ist eine Trennung zwischen ungeschädigtem und geschädigtem Zustand ohne Kenntnisse der EOC-Variablen nicht mehr möglich. In diesem Fall zeigt erst die Betrachtung der EOCs, dass gleiche Umgebungs- und Betriebszustände der Anlage verschiedene Schädigungsmerkmale hervorrufen. Der geschädigte Zustand liegt dabei nur „zufällig“ auf der Funktion des ungeschädigten Zustands. Um die beiden Methodenklassen besser zu erläutern, werden in Abbildung 3.10 prinzipielle Beispiele für den zweidimensionalen Fall dargestellt.

Die zwei Klassen von Methoden sind für Funktionen des ungeschädigten Zustands in einem betrachteten EOC-Intervall anwendbar, siehe das Intervall  $[a, b]$  in Abbildung 3.10. Außerhalb dieses Intervalls, kann nicht vorausgesagt werden, wie sich die Schädigungsmerkmale in Abhängigkeit der EOCs entwickeln/verhalten. Ausnahme davon machen lineare Funktionen die außerhalb der angelernten Grenzen extrapoliert werden können. Die Funktion des ungeschädigten Zustandes repräsentiert bei diesen Methoden den Referenzzustand des Systems. Dieser wird während einer sog. Lernphase (auch Training- oder Offline-Phase genannt) aus mehreren Stützstellen (Indikatoren-EOC-Kombinationen) gebildet. Die Genauigkeit, mit welchem ein Referenzzustand dem tatsächlichen ungeschädigten Zustand einer Struktur entspricht, hängt stark von der Anzahl und der Verteilung der „Referenzstützstellen“ ab.

Die Trennung zwischen geschädigtem und ungeschädigtem Zustand des Systems kann erst nach der Bildung des Referenzzustandes in einer sog. Testphase, die auch als Detektions- oder

Online-Phase bezeichnet ist, erfolgen. Dabei werden die extrahierten Merkmale/Indikatoren mit dem Referenzzustand des Systems verglichen.



**Abbildung 3.10: Zwei Muster zur Änderung der schädigungssensitiven Merkmale mit den EOCs nach [SOHN 2007]. Fall I: EOC müssen nicht gemessen werden; Fall II: EOC müssen gemessen werden**

Überschreiten die vordefinierten Abstände (z.B. Euklidischer Abstand) zwischen den aktuellen Merkmalen und dem Referenzzustand eine aus statistischer Sicht etablierte Grenze, spricht man über die Entdeckung eines neuen Zustands des Systems (eng. *Novelty Detection*). Dieser neue Zustand kann auf einer Änderung der Merkmale infolge von Strukturschäden basieren oder als Ergebnis einer ungenügenden Lernphase entstehen (d.h. der Referenzzustand wurde nicht ausreichend definiert).

Im Folgenden werden die bekanntesten Ansätze zur EOC-Kompensation erläutert.

### 3.3.1.1 Methoden ohne Messung der EOC Variablen

#### Hauptkomponentenanalyse (PCA)

Bei der Anwendung der PCA handelt es sich um den Aufbau eines Referenzzustandes mit Hilfe einer linearen Funktion. Dabei wird der mehrdimensionale Merkmalsraum der Signale auf eine niedrigere Dimension reduziert. Der Ansatz extrahiert zuerst die Hauptkomponenten

$U$  aus der Kovarianz  $\Sigma$  der Referenzmerkmale  $\theta$  mit Hilfe des Eigenwertproblems aus Gl. (2.104).  $\theta$  ist in diesem Fall als eine  $(N_f \times N_{Dref})$  - Matrix aufgebaut und beinhaltet  $N_f$  Merkmale gehörend zu  $N_{Dref}$  Messdatensätzen des ungeschädigten Zustands:

$$\theta = \begin{pmatrix} \theta_{1,1} & \theta_{1,2} & \cdots & \theta_{1,N_{Dref}} \\ \theta_{2,1} & \theta_{2,2} & \cdots & \theta_{2,N_{Dref}} \\ \vdots & \vdots & \ddots & \vdots \\ \theta_{N_f,1} & \theta_{N_f,2} & \cdots & \theta_{N_f,N_{Dref}} \end{pmatrix}. \quad (3.1)$$

Der Referenzzustand  $\hat{\theta}$  des Systems kann, analog zu Gl. (2.105) - (2.106), als Projektion der Referenzmerkmale auf den reduzierten Raum (hier eine lineare Funktion) verstanden werden.

$$\hat{\theta} = \bar{\theta} + U_{red} z. \quad (3.2)$$

Der sog. Schädigungsindikator berechnet sich, analog zu Gl. (2.107), mit Hilfe des Euklidischen Abstands zwischen allen  $N_f$  Merkmalen der Daten aus der Detektionsphase  $N_{Dref} < n_m \leq N_D$  und des Referenzzustands:

$$DI_{n_m}^{PCA} = \|\theta_{n_m} - \hat{\theta}_{n_m}\|^2. \quad (3.3)$$

Hierbei bezeichnet  $n_m$  die laufende Nummer eines Messdatensatzes und  $N_D$  die Anzahl aller zur Verfügung stehender Messdatensätze.

Die Hauptkomponentenanalyse wurde von [YAN *et al.* 2005] zur Schadensanalyse bei Änderung der EOCs angewendet. Hierbei wurden die ersten Eigenfrequenzen am Beispiel eines Simulationsmodells und einer Holzbrücke im Labor als schadensensitive Merkmale verwendet. Der einzige EOC Einfluss auf das dynamische Verhalten der Strukturen war die Temperatur. Die Ergebnisse zeigten, dass die Kompensation der Temperatureinflüsse gut durchführbar war, solange sich alle Eigenfrequenzen linear mit der Temperatur geändert haben.

#### *Nicht-lineare Hauptkomponentenanalyse (NLPCA)*

Für nicht-lineare Veränderungen der Merkmale mit dem EOC, wird von dem im Abschnitt 2.4.2 dargestellten Autoassoziativen Neuronalen Netz (AANN) Gebrauch gemacht [KRAMER 1991]. Das AANN nutzt die extrahierten Merkmale der unbeschädigten Struktur als Eingangsgrößen. Das Netz ist „trainiert“ um Beziehungen zwischen den extrahierten Merkmalen und den EOCs zu identifizieren. Diese Beziehungen sind unsichtbare, intrinsische Variablen



des neuronalen Netzes. Wenn das Netz adäquat trainiert ist, dann wird die Ausgangsschicht (*Output layer*) des AANN, die extrahierten Merkmale aus dem Eingang des AANN gut reproduzieren. Die NLPCA kann vorhandene nicht-lineare Korrelationen zwischen den Merkmalen erkennen, da diese in den nicht-linearen Aktivierungsfunktionen des *Mapping* und *De-Mapping Layers* angeleert wurden, siehe Abschnitt 2.4.2 und Abbildung 2.4.

[SOHN *et al.* 2002] und [SOHN *et al.* 2005] haben die AANN zur Schadensdiagnose an einem Masse-Feder-System mit acht Freiheitsgraden verwendet. Unterschiedliche EOCs wurden durch die Änderung der Leistung in dem Anregungssignal erzielt. Als Signalmerkmale wurden die Koeffizienten eines univariaten AR-Modells genutzt (siehe Gl. (2.50) für  $m = 1$ ). SOHN bezeichnet den Schädigungsindikator für die Testphase als *Novelty Indicator*, und berechnet diesen mit Hilfe eines Mahalanobis-Abstands, der den Euklidischen Abstand zusätzlich mit den Diagonalelementen der Kovarianzmatrix aller Merkmale des Referenzzustands  $\Sigma_{\theta_{ref}}$  normiert:

$$DI_{n_m}^{NLPCA} = (\theta_{n_m} - \hat{\theta}_{n_m})^T \Sigma_{\theta_{ref}}^{-1} (\theta_{n_m} - \hat{\theta}_{n_m}). \quad (3.4)$$

Die Ergebnisse haben gezeigt, dass Veränderungen in der Anregungsleistung gut kompensiert werden konnten, solange diese vom AANN mit angeleert worden sind.

#### *Berechnung mehrerer Referenzen*

Eine vereinfachte Variante des *Novelty Indicators* wurde in [SOHN *et al.* 2001] und [SOHN und FARRAR 2001] mit Hilfe eines univariaten AR-Modells einer Referenzmessung vorgestellt. Die Modellkoeffizienten wurden als lineare Filter für die nachkommenden Messdaten verwendet und die Standardabweichung des Referenzresiduums  $\sigma(\epsilon_{ref})$  mit den Standardabweichungen der Residuen der aktuell gemessenen Daten  $\sigma(\epsilon_{n_m})$  verglichen. Wenn

$$\sigma(\epsilon_{n_m}) / \sigma(\epsilon_{ref}) > h \quad (\text{z.B. } h = 1) \quad (3.5)$$

dann entspricht dies einem neuen Zustand der Struktur. Zur Validierung dieser Methode wurde das gleiche Experiment wie bei der NLPCA genutzt. Zur Kompensation der Umgebungseinflüsse nutzt man mehrere Zeitreihen zur Berechnung unterschiedlicher Referenzen, welche durch den Vergleich der AR-Koeffizienten der Zeitsignale während der Lernphase entstehen. Unterscheiden sich die AR-Koeffizienten einer aktuellen Zeitreihe von einer vorausgewählten Referenzzeitreihe (z.B. infolge einer EOC-Veränderung), dann werden diese zur Referenzdatenbasis herangezogen.

### Faktorenanalyse (FA)

[KULLAA 2003] hat eine Methode zur Kompensation der EOCs auf Grundlage der Faktorenanalyse [JOHNSON und WICHERN 1998] entwickelt.

Die Faktorenanalyse ist eine Form der multivariaten Analyse basierend auf einem mathematischen Modell, das die Korrelationen zwischen einer großen Anzahl von Variablen anhand einer kleinen Anzahl von  $d$  Basis-Faktoren (eng. *underlying factors*) zu erklären versucht. Das mathematische Modell ist wie folgt beschrieben:

$$\boldsymbol{\theta} = \boldsymbol{\mu} + \mathbf{A}\boldsymbol{\xi} + \boldsymbol{\varepsilon}. \quad (3.6)$$

In Gl. (3.6) ist  $\boldsymbol{\mu}$  ein konstanter Vektor mit den Mittelwerten des Modells,  $\mathbf{A}$  eine Gewichtungsmatrix (eng. *factor loadings*),  $\boldsymbol{\xi}$  ein Vektor mit versteckten Modellfaktoren, die die unbekannt EOC-Einflüsse repräsentieren, und  $\boldsymbol{\varepsilon}$  ist ein Vektor mit den Einzelfaktoren (eng. *unique factors*). Das Faktor-Modell wird mit Hilfe von Messdaten der ungeschädigten Struktur aufgebaut und verwendet die Schätzung der Basis-Faktoren  $\hat{\boldsymbol{\xi}}$  zur Eliminierung der EOC-Effekte. Da die verbliebenen Einzelfaktoren unabhängig von Änderungen der angelernten EOCs sind, werden diese zur Bildung der Schadensindikatoren benutzt:

$$\hat{\boldsymbol{\varepsilon}} = \boldsymbol{\theta} - \boldsymbol{\mu} - \mathbf{A}\hat{\boldsymbol{\xi}}. \quad (3.7)$$

Wenn die Struktur beschädigt ist, kann das trainierte Modell ( $\mathbf{A}\hat{\boldsymbol{\xi}}$ ) die Änderung von  $\hat{\boldsymbol{\varepsilon}}$  nicht „erklären“. Dadurch wird ein Schaden in den Änderung der Einzelfaktoren sichtbar. Die Schätzung der versteckten Faktoren  $\hat{\boldsymbol{\xi}}$  und deren Gewichtungen erfolgt als ein Optimierungsproblem, was z.B. mit Hilfe der Methode der kleinsten Fehlerquadrate oder des *Expectation Maximization* (EM) Algorithmus [GHAHRAMANI und HINTON 1996] gelöst werden kann. Die Schadensindikatoren werden aus der ersten Hauptkomponente von  $\hat{\boldsymbol{\varepsilon}}$  gebildet und steigen mit zunehmendem Strukturschaden an.

[KULLAA 2006a] und vorher [GHAHRAMANI und HINTON 1996] haben für den Fall, dass sich die extrahierten Merkmale nicht-linear oder nur stückweise linear gegenüber Änderungen der EOCs verhalten, die sog. *Mixture of Factor Analysis* (MFA) entwickelt. Hierbei handelt sich um die Beschreibung des Systems mit mehreren FA-Modellen. Eine weitere Art der nicht-linearen Faktorenanalyse (NLFA) - sehr ähnlich zu der NLPCA - wird mit Hilfe von AANN [LÄMSÄ und KULLAA 2007] erreicht.

[KULLAA 2004] hat die FA und die MFA auf ein Kransimulationsmodell angewandt. Hierbei änderten sich die ersten fünf Eigenfrequenzen und Eigenmoden der Struktur mit der Position der Teleskoparme des Krans. Nach dem Anlernen der gesamten Bandbreite der Teleskoparmpositionen in einem Faktor-Modell konnte der Einfluss dieser Positionen auf ausgewählte Merkmale eliminiert und ein Schaden korrekt identifiziert werden.

Weiterhin hat [KULLAA 2006a] die FA und MFA auch auf Messdaten der Brücke Z24 in der Schweiz angewendet. Hier wurden nur die ersten vier Eigenfrequenzen der Struktur als Merkmale verwendet. Als Trainingsdaten für die Faktor-Modelle kamen Messdaten eines Jahres zum Einsatz. Der Schaden, eingeführt im dritten Jahr, konnte nach der Temperaturkompensation korrekt detektiert werden.

Aus der Literatur (vgl. z.B. [YAN *et al.* 2005] mit [KULLAA 2002]) sind Vergleiche der Ergebnisse der FA, PCA, MFA und NLPCA bekannt. Diese haben gezeigt, dass diese Methoden in ihrer Leistungsfähigkeit zur Kompensation von Umgebungseinflüssen durchaus gleichwertig sind.

#### *Missing Data Analyse (MDA)*

Im Gegensatz zu den anderen Methoden ist die MDA parameterfrei. Daher ist hier eine Anpassung weiterer Variablen, wie z.B. die Hauptkomponentenanzahl bei der PCA-Methode, für die Schadensdetektion nicht notwendig. Dieser Ansatz lässt sich unter der Annahme, dass die extrahierten Merkmale  $\theta$  normalverteilt sind und den Mittelwertvektor  $\mu$  und die Kovarianzmatrix  $\Sigma$  besitzen, verwenden.

Die MDA versucht ein Merkmal aus den Korrelationen weiterer Merkmale zu schätzen und nutzt das Residuum zwischen den geschätzten und realen Merkmalen als Schädigungsindikator. Die Zerlegung der Merkmalsmatrix  $\theta$  in fehlende (unbekannte) Merkmale  $u$  und gemessene Merkmale  $v$  wird anhand der dazugehörigen Mittelwertvektoren (Untervektoren) und Kovarianzmatrizen (Untermatrizen) wie folgt dargestellt:

$$\mu = \begin{bmatrix} \mu_u \\ \mu_v \end{bmatrix}, \quad \Sigma = \begin{bmatrix} \Sigma_u & \Sigma_{uv} \\ \Sigma_{vu} & \Sigma_v \end{bmatrix}. \quad (3.8)$$

[KULLAA 2008] hat gezeigt, dass die als unbekannt gesetzten Merkmale  $u$  mit Hilfe einer noch unbekannt Matrix  $K_{MDA}$  und der bekannten Merkmale  $v$  geschätzt werden können:

$$\hat{u} = K_{MDA} v. \quad (3.9)$$

Die optimale Gewichtung  $\mathbf{K}_{MDA} = \boldsymbol{\Sigma}_{uv} \boldsymbol{\Sigma}_v^{-1}$  wird nach KULLAA durch die Minimierung des quadratischen Fehlers  $E[(\mathbf{u} - \hat{\mathbf{u}})(\mathbf{u} - \hat{\mathbf{u}})^T]$  erzielt. Die Matrix  $\mathbf{K}_{MDA}$  wird aus Merkmalen des ungeschädigten Systems bei unterschiedlichen EOCs bestimmt, vgl. Gl. (3.1). Die Schätzung der Merkmale in der Testphase ist wie folgt definiert:

$$\hat{\mathbf{u}} = \boldsymbol{\mu}_u + \mathbf{K}_{MDA}(\mathbf{v} - \boldsymbol{\mu}_v). \quad (3.10)$$

Die praktische Berechnung erfolgt, indem in jeder Rechenschleife jeweils nur ein Merkmal als unbekannte Größe gesetzt wird, bis alle Merkmale einmal als unbekannt gesetzt wurden. Die geschätzte Merkmalmatrix baut sich somit aus den separat geschätzten Merkmalvektoren  $\hat{\boldsymbol{\theta}} = [\hat{\mathbf{u}}_1 \quad \hat{\mathbf{u}}_2 \quad \cdots \quad \hat{\mathbf{u}}_{N_f}]^T$  auf. Der größte Eigenwert der Kovarianzmatrix des Residuums  $\boldsymbol{\varepsilon} = \boldsymbol{\theta} - \hat{\boldsymbol{\theta}}$  liefert die Indikatoren für den Strukturzustand.

In [KULLAA 2008] wurde das selbe Kransimulationsmodell mit den gleichen Merkmalen wie bei der Validierung der MFA in [KULLAA 2004] verwendet. Die eingeführten Schäden konnten je nach verwendetem Merkmal und Größe des Schadens zufriedenstellend detektiert werden. Bei diesem Beispiel wurde aber auch gezeigt, dass sich die Ergebnisse durch Kenntnisse über die EOC, besonders im Fall der Nutzung der Eigenfrequenzen als Merkmale, entscheidend verbessern lassen.

In [KULLAA 2005] wurden aus simulierten Zeitdaten des Kransimulationsmodells die AR-Koeffizienten als Merkmale extrahiert. Die Ergebnisse der MDA haben gezeigt, dass die Schäden gut detektiert werden konnten.

In [KULLAA 2008] wurde auch eine Brücke aus Holz zur Schadensdetektion verwendet. Die Umgebungseinflüsse waren die Temperatur und die Feuchtigkeit. Nach einer ausreichend langen Trainingszeit für den Algorithmus wurde dieser erfolgreich angewendet. Die Merkmale waren hier manuell ausgewählte Eigenfrequenzen und Schwingungsformen der Brücke.

#### *Weitere Methoden*

In [VANLANDUIT *et al.* 2005] wird die Singulärwertzerlegung (eng. *singular value decomposition*, SVD) zur Schadensidentifikation unter veränderlichen EOCs angewendet. Die Idee dahinter ist, dass globale Änderungen der Struktursteifigkeit, z.B. infolge Temperaturänderungen, eine lineare Veränderung der Eigenfrequenzen der Struktur bewirken. Eine effiziente Methode zur Entdeckung nicht-linearer Änderungen, z.B. infolge von Schäden, ist die Berechnung der Distanz zwischen linearen Unterräumen der Merkmale und dem

Vergleich dieser bei der ungeschädigten und ggf. bei der geschädigten Struktur. Die Autoren stellen drei SVD-Techniken, basierend auf der Methode der kleinsten Fehlerquadrate (LS), der iterativen SVD und der robusten SVD vor.

Eine weitere Methode die den Phasenraum für die Schadensdetektion bei Anregungen durch Wellen und Wind nutzt, wurde von [NICHOLS 2003] vorgestellt. Die Methode versucht das dynamische Verhalten des Systems mit Hilfe von Referenzdaten vorauszusagen. Sie basiert, wie alle anderen bisher vorgestellten Methoden, auf der Annahme, dass Veränderungen in der Leistung des Eingangssignals in einer ausreichend großen Bandbreite in den Referenzdaten angelernt sind. Da sich dieser Ansatz in erster Linie zur Kompensation der Effekte unterschiedlicher Leistungen eines Anregungssignals auf die Strukturantworten eignet und bislang nur mit Hilfe sehr einfacher Simulationsmodelle validiert wurde, wird hier auf eine detaillierte Beschreibung verzichtet.

Ein alternativer Ansatz zur Kompensation von nicht-linearen Effekten der Umgebung auf die Strukturdynamik kann mit Hilfe von Selbstorganisierenden Karten (eng. *Self Organizing Maps*) erzielt werden [KRAEMER *et al.* 2010]. Hierbei werden sog. *Kohonen*-Netze [KOHONEN 2001] zur Reduktion des Merkmalsraums verwendet und der  $d$ -dimensionale Raum der Merkmale in einer Trainings-Phase auf eine zwei- oder eindimensionale Karte komprimiert. Der Mahalanobis-Abstand zwischen den trainierten Merkmalen zur Erstellung der Karte und den bestehenden *Features* wird als Schadensindikator verwendet. Diese Methode ähnelt dem NLPCA-Ansatz, bietet aber, bedingt durch ihre Gestaltung, weitere Möglichkeiten zur Visualisierung der Beziehungen zwischen den Schädigungssignaturen und den Strukturzuständen in Abhängigkeit der Umgebungsveränderungen.

### 3.3.1.2 Methoden mit Messung der EOC Variablen

#### *Regressionsanalyse*

[PEETERS 2000] hat eine Regressionsanalyse der Eigenfrequenzen der Brücke Z24 durchgeführt. Dafür wurde ein ARX-Modell<sup>1</sup> verwendet. Die Eingangsgrößen des Modells waren die gemessenen Temperaturen und die Ausgangsgrößen die ersten vier Eigenfrequenzen der Brücke. Als Schädigungsindikatoren standen die statistischen Merkmale der Residuen zwischen den Modell und den gemessenen Zeitdaten zur Verfügung. Das Modell wurde mit Zeitdaten, aufgenommen über den Zeitraum eines Jahres, aufgebaut. Dadurch ließen sich die

---

<sup>1</sup> AR-Modell mit bekanntem Input.

Effekte aller Temperaturen auf die Eigenfrequenzen sehr gut anlernen. Hierbei wurde ein bilineares Verhalten der Eigenfrequenzen in Abhängigkeit der Temperaturen unterhalb und oberhalb von 0° C beobachtet. [PEETERS 2000] zeigt, dass der Temperatureinfluss auf die erste Eigenfrequenz mit Hilfe des ARX-Modells kompensiert und der eingeführte Schaden korrekt detektiert werden kann.

[SOHN *et al.* 1998] hat einen linearen Filter für die Schadenserkenkung unter Temperatureinflüssen an der Alamosa Canyon Bridge verwendet. Die Ergebnisse haben gezeigt, dass die Umgebungseinflüsse gut kompensiert werden können, solange diese vorher in dem Modell angelernt worden sind.

#### *Nullraum-basierte Fehlerdetektionsmethode (Nullspace-Based Fault Detection, NSFD)*

Die von [BASSEVILLE *et al.* 2000] entwickelte Methode nutzt die Systemidentifikation mit Hilfe der SSI-Methode aus Abschnitt 2.2.1 zur Generierung von Residuen. Die Referenz wird aus den Messdaten der ungeschädigten Struktur mit Hilfe des linken Nullraums  $\mathbf{K}_0$  der  $\mathbf{H}_0$ -Matrix aufgebaut, siehe auch Gl. (2.42) und (2.43). Wie in Gl. (3.11) dargestellt, ist der linke Nullraum, auch als linker Kern oder Kernelraum einer Matrix bekannt, ein Annihilator der Referenzhankelmatrix

$$\mathbf{K}_0 \mathbf{H}_0 = \mathbf{0}. \quad (3.11)$$

Um den linken Nullraum  $\mathbf{K}_0$  der Blockhankelmatrix zu bestimmen, wird Gl. (2.44) wie folgt umgeformt:

$$\mathbf{U}^T \mathbf{H}_0 = \mathbf{S} \mathbf{V}^T. \quad (3.12)$$

Für alle nicht signifikanten Werte der Singulärwertmatrix  $\mathbf{S}$  ist das Produkt  $\mathbf{S} \mathbf{V}^T = \mathbf{0}$ . Dadurch ergibt sich, dass der Nullraum der Anteil der  $\mathbf{U}$ -Matrix ist, die mit der Hankelmatrix multipliziert dem Anteil der Singulärmatrix mit den nicht signifikanten Werten entspricht.

Die Modellresiduen berechnen sich aus dem skalaren Produkt zwischen dem Referenzkernelraum und den Hankelmatrixen der Messdaten der Testphase

$$\boldsymbol{\varepsilon}_{n_m} = \mathbf{K}_0 \mathbf{H}_{n_m}. \quad (3.13)$$

Ist kein Schaden vorhanden, dann geht  $\boldsymbol{\varepsilon}_{n_m}$  gegen Null. Ein Schädigungsindikator aus diesen Residuen wurde in [MENGELKAMP 2006] vorgeschlagen. Hierbei wird ein einziger Indikator für den aktuellen Zustand des Systems aus den normierten Residuen berechnet:

$$DI_{n_m}^{NSFD} = \zeta_{n_m}^T \hat{\Sigma}^{-1} \zeta_{n_m} \quad \text{mit} \quad \zeta_{n_m} = \text{vec}(\varepsilon_{n_m})^1. \quad (3.14)$$

$\hat{\Sigma}$  ist ein Vektor mit Varianzen der Residuen für den ungeschädigten Fall und wird aus  $N_\Sigma$  Residuenvektoren berechnet:

$$\hat{\Sigma} = \frac{1}{N_\Sigma - 2} \sum_{q=2}^{N_\Sigma} \zeta_q \zeta_q^T. \quad (3.15)$$

Bedingt durch die Formulierung des Indikators<sup>2</sup> ist diese Methode sehr empfindlich gegenüber Strukturveränderungen, aber gleichzeitig auch gegenüber Veränderungen in den EOCs.

Die Methode kann als Ansatz, der keine Messungen der EOCs benötigt, eingestuft werden, wenn der Aufbau des linken Kerns mit Hilfe von Zeitreihen erfolgt, die alle veränderlichen EOCs berücksichtigen. Allerdings ist in vielen Fällen eine einzige Messung über einen langen Zeitraum (bis alle EOCs erfasst worden sind) kaum realisierbar.

[BASSEVILLE *et al.* 2006] hat dieses Problem durch den Aufbau von neuen Referenzmatrizen

$\mathbf{H}_0^j$  für jede bisher nicht betrachtete aber relevante EOC gelöst. Eine „Gesamtreferenzmatrix“  $\mathbf{H}_0^{EOC}$  wurde als Mittelwert aus den Einzelreferenzmatrizen konstruiert:

$$\mathbf{H}_0^{EOC} = \frac{1}{N_{EOC}} \sum_{j=1}^{N_{EOC}} \mathbf{H}_0^j, \quad (3.16)$$

wobei  $N_{EOC}$  die Anzahl aller relevanten EOCs ist. Aus dieser Matrix entsteht ein einzelner linker Kernelraum  $\mathbf{K}_0^{EOC}$ , mit dem alle angelernten EOCs kompensiert werden können. Die von Effekten der EOCs „befreiten“ Schädigungsindikatoren werden hier mit Hilfe der Gl. (3.14) und (3.16), also mit  $\mathbf{K}_0^{EOC}$  anstatt  $\mathbf{K}_0$ , berechnet.

[FRITZEN *et al.* 2003] haben mehrere Nullräume  $\mathbf{K}_0^j$  genutzt um Schädigungsindikatoren für unterschiedliche EOCs getrennt zu berechnen. Hankelmatrizen  $\mathbf{H}_0^j$  der Zeitreihen, die z.B. unter dem Umgebungseinfluss  $j$  aufgenommen sind, wurden hier mit  $\mathbf{K}_0^j$  multipliziert.

---

<sup>1</sup> *vec* wandelt eine Matrix in einen Vektor um, wobei die Spaltenvektoren der Matrix in dem Vektor untereinander angeordnet werden.

<sup>2</sup> Hier werden Abweichungen von einem bereits identifizierten System betrachtet.

[BASSEVILLE *et al.* 2006] verwendete in einem Laborversuch einen beidseitig eingespannten Balken aus Aluminium für das Testen der Methode zur Schadensdetektion. Hierbei wurde der Balken mit einer speziellen Vorrichtung gedehnt, um den Einfluss unterschiedlicher Temperaturen zu simulieren. [FRITZEN *et al.* 2003] verwendeten ihre Variante mit mehreren Referenzen zur Kompensation von Temperatureinflüssen auf eine CFK-Platte mit Stringern. Die Ergebnisse haben gezeigt, dass eine Schadensdetektion nur mit Hilfe der Kompensation des Temperatureinflusses möglich ist.

### 3.3.2 Auswahl des Algorithmus und der schädigungssensitiven Merkmale

Bei der Auswahl eines geeigneten Algorithmus zur Schadensdetektion an OWEAs werden die spezifischen dynamischen Eigenschaften aus Abschnitt 3.1 und deren Effekte auf die Schädigungsmerkmale berücksichtigt. Dabei ist darauf zu achten, der Kompensation der EOCs auf die Schädigungsindikatoren Rechnung zu tragen. Im Hinblick auf den Aufbau eines autonomen Systems zur Schadenserkenkung (vgl. Abbildung 3.9) werden, auch wenn nur zweitrangig, bei der Auswahl des Algorithmus und der *Features* der Automationsgrad wichtiger Vorgänge (Merkmalextraktion und Kompensation von EOCs) berücksichtigt.

Vor der Erläuterung des Schadensdetektionsalgorithmus und der damit verbundenen Extraktion von Schadensmerkmalen, zeigt das Folgende zuerst prinzipiell, welche Ansätze zur Kompensation von EOC-Effekte auf die Schadensmerkmale speziell zur Anwendung an OWEAs einbezogen werden sollen.

#### 3.3.2.1 Zur Auswahl des Algorithmus für die Berücksichtigung von EOCs

Die Eignung der Algorithmen zur EOC-Kompensation wird mit Hilfe eines synthetischen Verlaufs zweier hypothetischer Merkmale erläutert, siehe Abbildung 3.11. Hierbei wird angenommen, dass sich die Korrelation der beiden Merkmale nicht-linear mit den EOCs ändert. Die Abweichung der Merkmale von der ursprünglichen „Merkmalfunktion“ soll den Einfluss des Messrauschens oder der Merkmalextraktionsungenauigkeiten simulieren. Die vier nummerierten Ausreißer in Abbildung 3.11 repräsentieren Abweichungen der Merkmale von der Verteilung der anderen Testdaten.

Repräsentativ für die Klasse der Methoden zur Erkennung von nicht-linearen Korrelationen ohne Messung der EOCs, lässt sich hier die NLPCA verwenden.



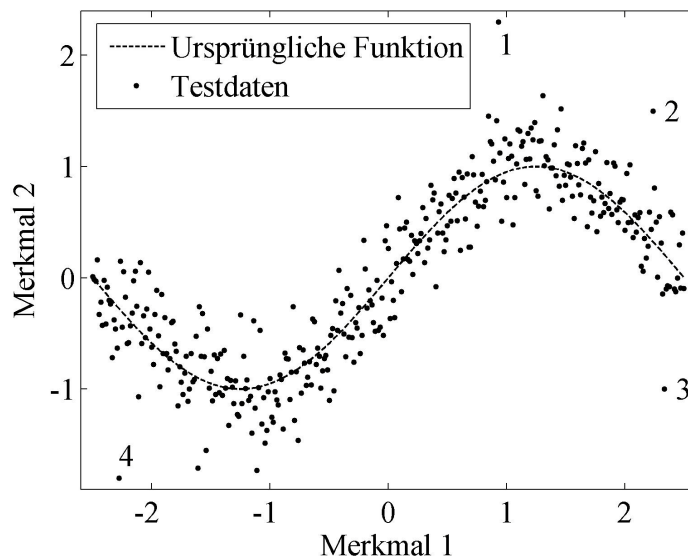


Abbildung 3.11: Beispiel eines zweidimensionalen Merkmalraums

Die vorhandenen Trainingsdaten werden zum Aufbau eines AANNs<sup>1</sup> genutzt. Falls sich die relevanten Änderungen der Merkmale in den Trainingsdaten widerspiegeln, kann die nicht-lineare Hauptachse (hier mit Hilfe des AANNs bestimmt) die Testdaten approximieren, siehe Abbildung 3.12. Testdaten die sich nicht ausreichend mit Hilfe des Netzes beschreiben lassen, werden als Ausreißer<sup>2</sup> erkannt.

Bei OWEAs ist es aber kaum möglich, Änderungen der dynamischen Eigenschaften infolge aller möglichen Veränderungen der gleichzeitig auftretenden EOCs in kurzer Zeit anzulernen. In der Realität lässt sich die gesamte „Bandbreite“ der Einflüsse aller möglichen EOC-Kombinationen erst nach mehreren Monaten zufriedenstellend erfassen.

Um die Anwendung des AANN in diesem Fall zu veranschaulichen, wird, wie in Abbildung 3.13 (links) dargestellt, nur ein Teil der Merkmalszustände angelernt. Da der entstandene Referenzzustand nur für den angelernten Bereich repräsentativ ist und sich dadurch ein falscher Verlauf der Hauptachse am Rande des angelernten Gebiets ergibt, werden Testdaten die außerhalb dieses Bereichs liegen, fälschlicherweise als Ausreißer<sup>3</sup> erkannt und tatsächliche Ausreißer nicht identifiziert, wie hier die Ausreißer 2 und 4 in Abbildung 3.13, links.

<sup>1</sup> Die *mapping* und *de-mapping* Schichten sind jeweils aus vier Neuronen und die *bottleneck*-Schicht aus einem Neuron aufgebaut, siehe Abbildung 2.4 und Legende der Abbildung 3.12.

<sup>2</sup> Für die Ausreißeranalyse der Daten wurde der Mahalanobis-Abstand zwischen den Merkmalen und deren Projektion auf das AANN aus Gl. (3.4) angewendet. Der Grenzwertwert der Abstände richtete sich nach dem F-Test aus Gl. (3.60) für ein Konfidenzintervall  $\alpha = 0,05$ .

<sup>3</sup> Diese Form der Ausreißeranalyse bzgl. Schadenserkenkung ist in der Literatur als *Novelty Detection* bekannt.




Abbildung 3.12: Beispiel einer Projektion von Testdaten auf ein AANN

Abbildung 3.13 (rechts) verdeutlicht, dass Methoden zur Erkennung von linearen Korrelationen zwischen den Merkmalen in diesen Fall (gleiche Trainingsdaten wie in Abbildung 3.12) nur mit großen „Einbußen“ bzgl. der Genauigkeit der Ausreißerererkennung angewendet werden können. Zum Aufbau des Referenzzustandes in Abbildung 3.13, rechts, wurde die PCA repräsentativ für die Klasse der Ansätze zur Erkennung von linearen Korrelationen angewendet.




Abbildung 3.13: Ausreißeranalyse mit Hilfe eines ungenügend angelernten AANNs (links) und der PCA (rechts)

Die auf der NLPCA und der PCA basierenden Ansätze, eignen sich bei ungenügendem Training nur eingeschränkt zur Kompensation von Effekten der EOCs und bergen in sich die

Gefahr, dass eine nicht ausreichende Lernphase für das Verhalten der Merkmale zu falschen Rückschlüssen über den Zustand der Struktur führt, siehe Abbildung 3.10 (Fall II). Aus diesen Gründen wird das Prinzip eines adaptiven Ansatzes vorgestellt, der sich an noch nicht angelegte Testdaten aus der Online-Phase anpasst. Dieser Ansatz basiert im ersten Schritt auf einer Klassifikation der Trainingsdaten, wobei die entstandenen Klassen mit Hilfe von Testdaten validiert werden können. Für die Klassifikation wurde der *k-medoid* Algorithmus aus Abschnitt 2.4.1 verwendet. Abbildung 3.14 zeigt beispielhaft den Aufbau der Referenzzustände mit Hilfe von vier Klassen basierend auf den Trainingsdaten der Abbildung 3.13 (links).

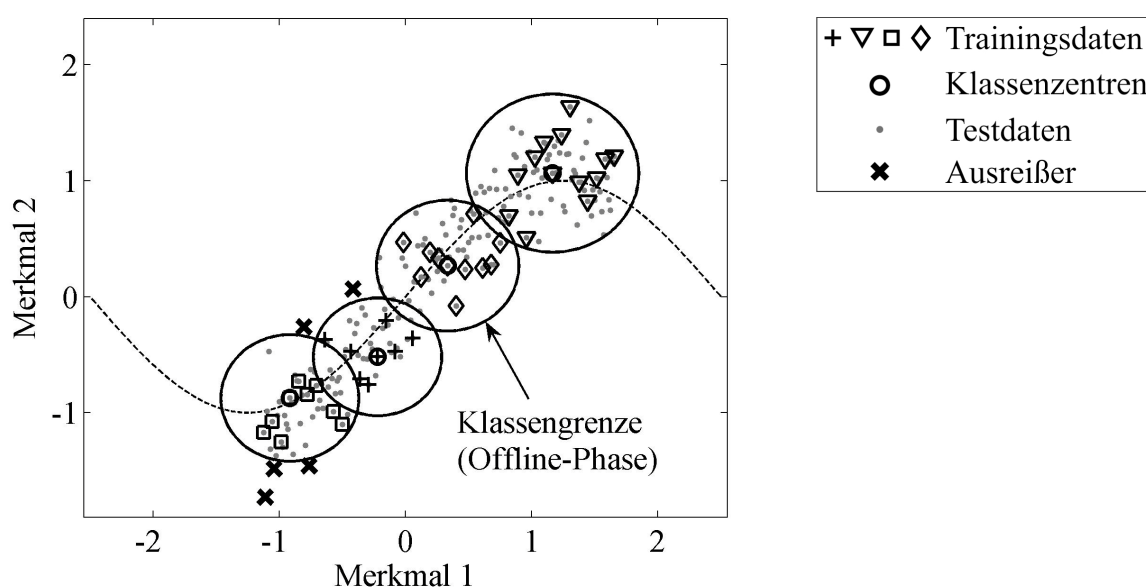


Abbildung 3.14: Referenzen für die Offline-Phase einer Klassifikation

Wenn neue Testdaten während der Online-Phase entstehen, die in keine Klasse der Offline-Phase passen, dann werden in einem zweiten Schritt anhand einiger „Stützstellen“ neue Klassen aufgebaut. Dieser Vorgang ist in Abbildung 3.15 dargestellt. Insgesamt befinden sich hier 14 aus 361 Daten außerhalb der Klassengrenzen, wobei nur vier Merkmalskombinationen tatsächliche Ausreißer sind. Bei der Betrachtung der fälschlicherweise identifizierten Ausreißer muss beachtet werden, dass es sich hier nur um ein Beispiel zur prinzipiellen Erläuterung des adaptiven Verfahrens handelt, welches aber in Abschnitt 3.3.3 mit entsprechenden Schadensdetektionsalgorithmen kombiniert wird und zu einer entsprechend anderen Ergebnisinterpretation führt.

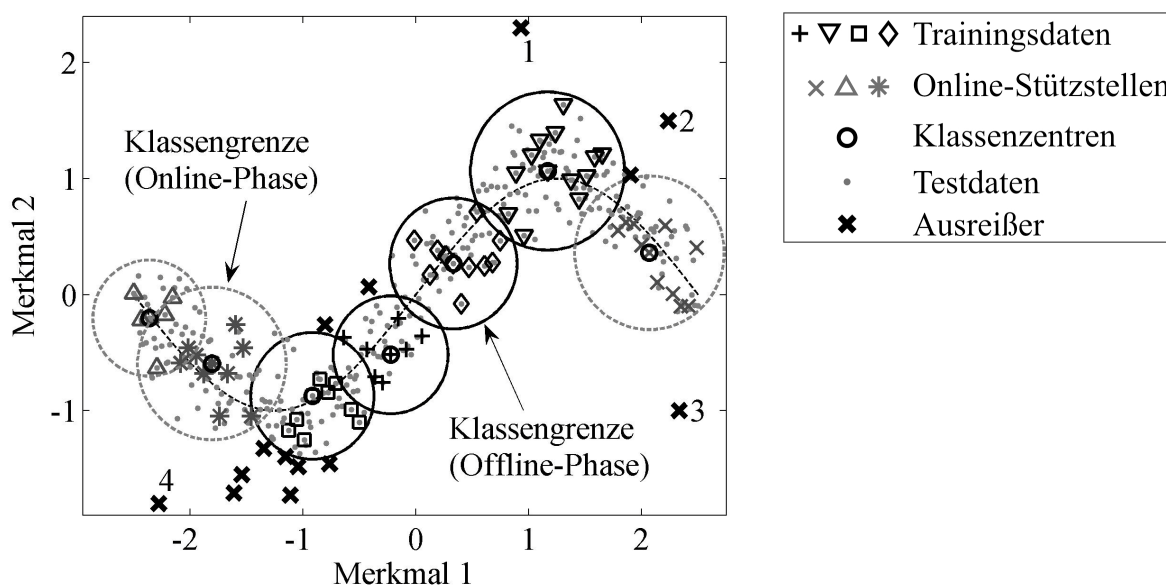


Abbildung 3.15: Referenzen für die Online-Phase einer Klassifikation

Ein prinzipieller Nachteil der Methoden, die adaptiv den Referenzraum erweitern, besteht grundsätzlich darin, dass Merkmale der geschädigten Struktur zum Aufbau von Referenzen genutzt werden und somit der geschädigte Zustand der Struktur mit angelernt wird. Eine Lösung für dieses Problem kann, wie Abschnitt 3.3.3 beschrieben, durch die Anwendung eines adaptiven Verfahrens mit Hilfe von Klassifikationstechniken und der Berücksichtigung der gemessenen EOCs erreicht werden.

### 3.3.2.2 Zur Auswahl geeigneter schädigungssensitiver Merkmale

Die bisher am häufigsten in der Literatur (siehe auch Abschnitt 3.3.1) verwendeten Merkmale, zur Beschreibung der dynamischen Eigenschaften von *Output-Only* angeregten Strukturen sind Modaldaten in Form von Eigenfrequenzen, Dämpfungsverhältnissen und Schwingungseigenformen bzw. Modenkrümmung, siehe z.B. [ANDERSEN und KIRKEGAARD 1998; MAECK 2003; PEETERS 2000]. Die Modaldaten eignen sich gut zur Erkennung kleiner Strukturschäden, wenn die Anzahl der Sensoren auf der Struktur für eine eindeutige Identifikation der relevanten Schwingungsformen<sup>1</sup> ausreicht. Wenn die Anzahl der Sensoren unzureichend ist, geben nur die Verschiebungen der Eigenfrequenzen im Frequenzspektrum Auskunft über den Zustand der Struktur. Dies verringert stark die Sensitivität der Identifikation gegenüber kleiner Strukturschäden.

<sup>1</sup> In der Regel sieht man die Signatur kleiner Strukturschäden in der Veränderung von höheren Schwingungsmoden.

Weitere sehr oft in der Literatur verwendete, schädigungssensitive Merkmale die auch in Modaldaten überführt werden können (siehe Abschnitt 2.2.2), sind autoregressive Koeffizienten von Zeitreihen, siehe z.B. [FASSOIS und SAKELLARIOU 2007; NAIR und KIREMIDJIAN 2007; SOHN *et al.* 2005; SOHN *et al.* 2001; SOHN und FARRAR 2001; SOHN *et al.* 2002]. Diese eignen sich jedoch nur dann zum Zwecke der Schadenserkenkung an OWEAs, wenn die Anzahl der extrahierten Koeffizienten groß genug ist, um die Dynamik der Struktur wiederzugeben, vgl. Abbildung 3.16. Eine anschauliche Methode zur Bestimmung der notwendigen Koeffizientenanzahl ist der Vergleich der Leistungsdichtespektren aus der klassischen Fouriertransformation mit denen aus den AR-/ARMA-Koeffizienten. Für die Berechnung des Leistungsdichtespektrums werden die AR- und gegebenenfalls die MA-Koeffizienten des optimalen Modells in den Frequenzbereich transformiert [BROERSEN 2006], wobei das autoregressive  $A(z)$  und das Moving-Average Polynom  $B(z)$  im Frequenzbereich folgendermaßen definiert sind:

$$A(z) = \sum_{l=0}^p A(l)z^{-l}, \quad B(z) = \sum_{l=0}^q B(l)z^{-l} \quad \text{mit} \quad z = e^{j2\pi f}, \quad (3.17)$$

mit  $A(l=0) = B(l=0) = 1$ . Aus den beiden berechneten Polynomen lässt sich das Leistungsdichtespektrum des ARMA-Prozesses wie folgt berechnen:

$$S_{yy}(f) = \frac{|B(z)|^2}{|A(z)|^2} \sigma_e^2, \quad (3.18)$$

wobei  $\sigma_e^2$  die Varianz des Eingangssignals ist. Ein solches Spektrum für ein Signal der Anlage M5000-2 zeigt, dass die Modellierung des dynamischen Verhaltens mit nur wenigen Koeffizienten nicht ausreichend ist, siehe Abbildung 3.16.

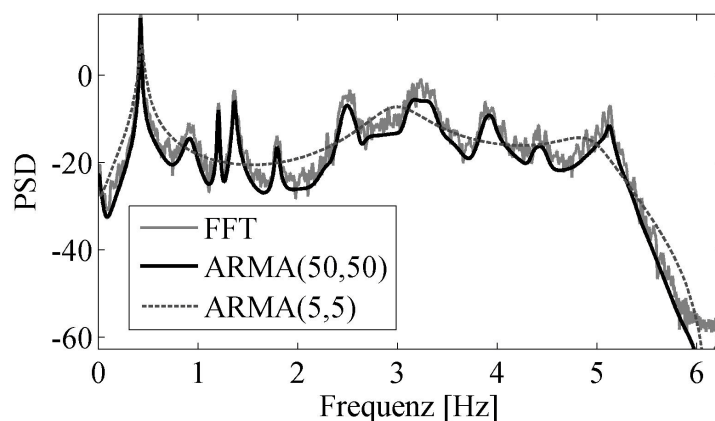


Abbildung 3.16: Spektren aus FFT und unterschiedlichen ARMA-Modelle

Andere eher selten verwendeten Merkmale in der SHM von langsam schwingenden Strukturen sind Koeffizienten der diskreten Wavelet Transformationen [KIM und MELHEM 2004] oder Kennwerte gemessener Zeitreihen in Form von statistischen Momenten 1. bis 4. Ordnung [FARRAR *et al.* 2007], etc.

Da zur Überwachung von großen OWEA ein dichtes Sensornetzwerk auf dem Turm aus Kostengründen und unter der Wasseroberfläche auch aus technischer Sicht heutzutage nicht realisierbar ist, werden zum Zweck der Schadensdetektion in dieser Arbeit nicht direkt die Schwingungsmoden, sondern die Residuen der identifizierten Systeme auf der Basis der SSI/ERA-Methode, vgl. Gl. (3.14), oder ARV-Modellen, vgl. Gl. (2.50), verwendet. Diese Residuen zeigen direkt die Abweichungen der Zeitdaten von einem identifizierten System. Dadurch sind sie sensitiver gegenüber Systemveränderungen als die Modaldaten, siehe Abschnitt 5.1.1, können in einem automatischen Modus aus den Zeitdaten extrahiert und durch geeignete Algorithmen zu einem einzigen Schädigungsindikator zusammengefasst werden. Die auf der Basis der AR-Koeffizienten oder der SSI-Methode extrahierten Schwingungsmoden werden lediglich zur Modellanpassung und zur Schadenslokalisierung in Abschnitt 3.4 benutzt.

### 3.3.2.3 Residuen aus der Stochastic Subspace Identification (SSI)

Die Residuen, aus der SSI-Methode berechnen sich nach Gl. (3.11)-(3.14) und wurden bereits in [BASSEVILLE *et al.* 2000; BASSEVILLE *et al.* 2006; FRITZEN *et al.* 2003; MENGELKAMP 2006] zur Schadensdetektion verwendet (siehe auch Abschnitt 3.3.1.2). Sie repräsentieren Abweichungen von dem in Gl. (2.48) und (2.49) identifizierten linearen System. Eine geeignete Systemordnung wird anhand der signifikanten Singulärwerte der Matrix  $\mathbf{S}$  in Gl. (2.44) festgelegt.

Für die Unterscheidung des ungeschädigten vom geschädigten Zustand einer Struktur, wurde bereits in [MENGELKAMP 2006] die statistische Modellierung der Residuen in Form von Schädigungsindikatoren, vgl. Gl. (3.14), mit Hilfe einer Extremwertverteilung (EV), siehe auch [CASTILLO *et al.* 2005], vorgeschlagen und erfolgreich durchgeführt. Auf dem Gebiet der schwingungsbasierten Schadenserkenkung wurde die EV erstmals in [SOHN *et al.* 2005] zur Modellierung der statistischen Verteilung der Schädigungsindikatoren genutzt. Auch in dieser Arbeit wird die Verteilung der Extremwerte der Schadensindikatoren des ungeschädigten Strukturzustandes  $\mathbf{DI}''$  mit Hilfe einer modifizierten Form der EV dargestellt (ein Extremwert stellt den höchsten Wert aus einer festen Anzahl an Schadensindikatoren

dar). Die generalisierten Extremwertverteilung (GEV) kombiniert drei Verteilungen zu einer einzigen Verteilungsform, die sich durch die Variation ihrer Parameter an die Extremwerte anpasst. Die Dichtefunktion der GEV ist nach [KOTZ und NADARAJAH 2001]:

$$p(\mathbf{DI}^u; \zeta, \mu, \sigma) = \left(\frac{1}{\sigma}\right) \left(1 + \zeta \frac{(\mathbf{DI}^u - \mu)}{\sigma}\right)^{-1 - \frac{1}{\zeta}} \exp \left[ - \left(1 + \zeta \frac{(\mathbf{DI}^u - \mu)}{\sigma}\right)^{-\frac{1}{\zeta}} \right] \quad (3.19)$$

für  $1 + \zeta \frac{(\mathbf{DI}^u - \mu)}{\sigma} > 0$ .

Hierbei repräsentiert  $\sigma$  den Skalierungs-,  $\mu$  den Orts- und  $\zeta$  den Formparameter der GEV. Sie werden in dieser Arbeit anhand der Matlab-Funktion „`gevfit.m`“ geschätzt. Je nach Parameter der Verteilung nähern sich die Wahrscheinlichkeitsdichtefunktionen (PDF) einer der folgenden bekannten Verteilungen: für  $\zeta = 0$  ergibt sich eine GUMBEL-Verteilung, für  $\zeta > 0$  eine FRECHET-Verteilung und für  $\zeta < 0$  eine WEIBULL-Verteilung. Hierbei soll beachtet werden, dass

$$p = 0 \text{ für } \begin{cases} \mathbf{DI}^u > -\frac{\sigma}{\zeta} + \mu \text{ und } \zeta < 0 \\ \mathbf{DI}^u < -\frac{\sigma}{\zeta} + \mu \text{ und } \zeta > 0 \end{cases} \quad (3.20)$$

Ein Beispiel für die Variation der PDFs mit unterschiedlichen Formparametern ist in Abbildung 3.17 dargestellt.




Abbildung 3.17: Beispiel von Wahrscheinlichkeitsdichtefunktionen der GEV

Die Anpassung der Verteilung an die Schädigungsindikatoren und somit die Schätzung der Parameter  $\sigma$ ,  $\mu$  und  $\zeta$  erfolgt durch die Maximierung der Wahrscheinlichkeit (eng. *Maximum Likelihood Estimation*, MLE), bei der die geschätzte Wahrscheinlichkeitsdichtefunktion der empirischen Dichtefunktion entspricht. Mit welcher Wahrscheinlichkeit  $P$  ein

Schädigungsindikator  $DI_{n_m}$  eines aktuellen Messdatensatzes  $n_m$  vorkommen kann, legt die Summenhäufigkeit (CDF) der  $GEV(DI_{n_m}; \mu, \sigma, \zeta)$  fest:

$$P = 1 - GEV(DI_{n_m}; \mu, \sigma, \zeta) = 1 - \exp \left\{ - \left[ 1 + \zeta \left( \frac{DI_{n_m} - \mu}{\sigma} \right) \right]^{-\frac{1}{\zeta}} \right\}. \quad (3.21)$$

Das Vertrauensintervall für die Schadensindikatoren lässt sich mit Hilfe eines ausgewählten Konfidenzintervalls  $\alpha$  festlegen und ein Schwellenwert mit der inversen GEV für die Schadenswahrscheinlichkeit  $1 - \alpha$  berechnen. Die  $H_0$  Hypothese für ein ungeschädigtes /unverändertes System kann für

$$H_0 : DI_{n_m}^{NSFD} < GEV_{1-\alpha}^{-1} \quad (3.22)$$

angenommen werden. Sollte der Schädigungsindikator den identifizierten Schwellenwert unzulässig überschreiten, dann ist davon auszugehen, dass signifikante Änderungen des Systems aufgetreten sind. Die aufgestellte Hypothese wird verworfen und die  $H_1$  Hypothese angenommen:  $H_1 : DI_{n_m}^{NSFD} \geq GEV_{1-\alpha}^{-1}$ .

Sollte die Lernphase zu kurz ausfallen, dann stehen nicht genug Messdaten und Indikatoren zur Berechnung der Extremwerte zur Verfügung. In diesem Fall kann nur die Verteilung der vorhandenen Indikatoren nach Gl. (3.19) geschätzt werden. Die Festlegung des Schwellenwertes bei der Betrachtung von relativ vielen oder wenigen vorhandenen Indikatoren wird anhand eines Simulationsbeispiels erläutert:

**Simulationsbeispiel 1:** Genutzt wird ein FE-Modell eines einseitig fest eingespannten Stahl-Balkens mit einer Länge von einem Meter und einem Querschnitt von 75×10mm. Die Knoten des FE-Modells<sup>1</sup> (x) und die „Messknoten“ (o) sind in Abbildung 3.18 dargestellt. Die Anregung erfolgt über ein weißes Rauschen an Knoten 21. Die zehn fiktiven Messkanäle werden simultan mit 1200Hz abgetastet und die Messsignale um 5% der Standardabweichung des Signals  $y_1$  verrauscht. Aus Anschaulichkeitsgründen für eine spätere Anwendung des Beispiels bei der Modalanalyse werden hier mit Hilfe des Modalansatzes aus Gl. (2.18)

---

<sup>1</sup> Für diese Simulation wird gezielt ein FE- und kein analytisches Modell verwendet, da dieses in der Erläuterung der unterschiedlichen Verfahren zur Modalanalyse, Sensorfehlererkennung und Signalrekonstruktion, die zum Teil eine Modelldiskretisierung benötigten, genutzt wird.



gezielt nur Zeitreihen mit Beschleunigungsdaten, welche die ersten fünf Moden in der Messrichtung beinhalten, simuliert. Die Schwingungen werden nach Gl. (2.5) proportional mit  $\beta = 10^{-6}$  gedämpft (sehr schwache Dämpfung, charakteristisch für Stahlstrukturen).




Abbildung 3.18: Balken mit „Sensorpositionen“

Abbildung 3.19, links, zeigt den Verlauf der Schädigungsindikatoren für den ungeschädigten (Datensätze 1-4200) und den geschädigten Zustand (Datensätze 4201-5240) des Balkens. Der erste Datensatz wurde als Referenz angenommen. Der Schaden entstand durch eine Steifigkeitsreduktion des Elementes Nr. 7 um 30%.

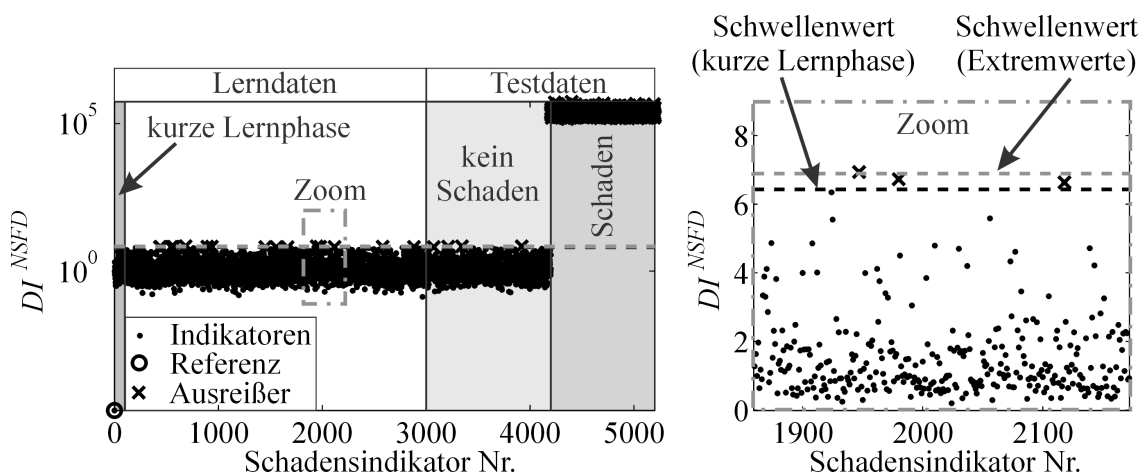



Abbildung 3.19: Ergebnis einer Schadensdetektion mit unterschiedlich langen Lernphasen am Beispiel eines einseitig eingespannten Balkens


Bei relativ vielen Daten, wie hier 3000 Datensätzen in der Lernphase, kann die GEV aus den Extremwerten der Indikatoren aufgebaut werden. Zu beachten ist, dass die Anzahl der Indikatoren (Indikatorenblocklänge), woraus sich ein Extremwert berechnen lässt, wenn auch nur in geringem Maße, einen Einfluss auf die Aufstellung des Schwellenwertes hat, siehe Abbildung 3.20, links. In Abbildung 3.20, rechts, ist das Wahrscheinlichkeitspapier für die Anpassung der GEV an die Extremwerte der 3000 Indikatoren bei einer Indikatorenblocklänge von 25 Indikatoren dargestellt. Daraus ergeben sich 120 Extremwerte.



**Abbildung 3.20:** Einfluss der Indikatorenblocklänge auf den Schwellenwert (links); Summenhäufigkeit der Indikatoren und der angepassten GEV (rechts)

Der aufgestellte Schwellenwert konnte mit den nächsten 1200 Indikatoren der Testphase (noch kein Schaden vorhanden) erfolgreich überprüft werden.

Sind hingegen nur wenige Daten in der Lernphase vorhanden, können die Extremwerte nicht mehr berechnet werden. Ein möglicher Kompromiss für diesen oft in der Praxis auftretenden Fall ist die Anpassung einer empirischen, parameterfreien Verteilung an die Schädigungsindikatoren. Eine weitere Möglichkeit, die auch in dieser Arbeit genutzt wird, besteht in der gezielten Anpassung der GEV anhand ihrer Parameter an die vorhandenen Indikatoren. Dabei entspricht die geschätzte Wahrscheinlichkeitsdichtefunktion der empirischen Dichtefunktion. Im vorliegenden Beispiel lässt sich eine FRECHET-Verteilung an die ersten 100 Indikatoren aus Abbildung 3.19 (siehe die „kurze Lernphase“) anpassen. Die „Güte“ der Anpassung zeigt die Wahrscheinlichkeitsdichte (PDF) und die Summenhäufigkeit (CDF) der Indikatoren und der Verteilung in Abbildung 3.21. Die Konfidenzgrenzen der empirischen Verteilung (KAPLAN-MEIER) in Abbildung 3.21, rechts, sind mit Hilfe der GREENWOOD-Gleichung geschätzt, siehe [COX und OAKES 1984].



**Abbildung 3.21:** PDF (links) und CDF (rechts) der Indikatoren und der angepassten FRECHET-Verteilung

Auch der mit einer kurzen Lernphase aufgestellte Schwellenwert konnte mit den nächsten 4100 Indikatoren erfolgreich überprüft werden<sup>1</sup>. Der Schwellenwert, berechnet während der „kurzen Lernphase“, zeigt in diesem Fall relativ geringe Abweichungen von dem aus Extremwerten berechneten Schwellenwert, siehe Abbildung 3.19, rechts. Dadurch kann angenommen werden, dass die an die 100 Indikatoren angepasste FRECHET-Verteilung auch für die weiteren 4100 Indikatoren repräsentativ ist.

Sind allerdings zu wenig Indikatoren, z.B. weniger als 30, vorhanden, dann kann kein Schwellenwert mehr berechnet werden, da die Wahrscheinlichkeit groß ist, dass diese Indikatoren nicht repräsentativ für den ungeschädigten Zustand der Struktur sind.

#### 3.3.2.4 Residuen aus Vektor-Autoregressiven Modellen

Alternativ zu den Residuen der SSI-Methode können auch Residuen aus autoregressiven Modellen zur Schadensdetektion genutzt werden. Das Residuum eines  $m$ -variaten ARV-Modells der Ordnung  $p$  stellt die Abweichung eines aktuellen Messdatums  $n_m$  von dem in Gl. (2.56) und (2.57) identifizierten linearen System dar und berechnet sich wie folgt:

$$(\boldsymbol{\varepsilon}_k)_{n_m} = (\mathbf{y}_k)_{n_m} - \sum_{l=1}^p (\mathbf{A}_l)_{ref} (\mathbf{y}_{k-l})_{n_m}, \quad \text{mit } 1 \leq n_m \leq N_D. \quad (3.23)$$

$(\mathbf{A}_l)_{ref}$  ist hier eine Referenzmatrix mit AR-Koeffizienten der gemessenen Zeitdaten im ungeschädigten Zustand. Gl. (3.23) kann auch als Differenz zwischen einem gemessenen und einem mit ARV-Modellen geschätzten Datensatz verstanden werden

$$\boldsymbol{\varepsilon}_{n_m} = \mathbf{y}_{n_m} - \hat{\mathbf{y}}_{n_m}. \quad (3.24)$$

Die Anzahl der notwendigen Koeffizienten wird mit Hilfe der FPE/SBC-Kriterien aus Gl. (2.52) bzw. (2.53) festgelegt (siehe auch Abbildung 3.27) und die akkurate Darstellung der Struktur dynamik mit Hilfe von Stabilitätsplots abgesichert. Dieses Ziel kann mit Hilfe einer Modalanalyse mit ARV-Modellen erreicht werden, vgl. Abschnitt 3.4.1.

Die Residuen nachfolgender Messungen  $n_m$  werden aus der Differenz zwischen den gemessenen  $m$ -variaten Zeitreihen und den mit Hilfe der AR-Koeffizienten geschätzten

---

<sup>1</sup> Bei einem Konfidenzintervall  $\alpha=0,02$  wird auch dieser Schwellenwert von ca. 2% der Indikatoren des ungeschädigten Zustandes überschritten.

Zeitreihen ermittelt. Ein Schädigungsindikator kann z.B. aus dem Mittelwert der Bestimmtheitsmaße<sup>1</sup>  $R^2$  einzelner Residuen aufgebaut werden [NETER *et al.* 1996]:

$$R_{n_m}^2 = \frac{1}{m} \sum_{s=1}^m \left( 1 - \sqrt{\frac{\sum (\mathbf{y}_{n_m} - \hat{\mathbf{y}}_{n_m})^2}{\sum (\mathbf{y}_{n_m} - \bar{\mathbf{y}}_{n_m})^2}} \right). \quad (3.25)$$

Um gleichzeitig die Modellkomplexität zu berücksichtigen wird das korrigierte Bestimmtheitsmaß  $\bar{R}^2$ , auch als bereinigtes, adjustiertes oder angepasstes Bestimmtheitsmaß bezeichnet, vorgeschlagen, welches zusätzlich die Modellordnung  $p$  berücksichtigt:

$$\bar{R}_{n_m}^2 = 1 - \left( 1 - R_{n_m}^2 \right) \frac{n_t - 1}{n_t - p - 1}. \quad (3.26)$$

Das Bestimmtheitsmaß zeigt die Qualität der linearen Approximation  $\hat{\mathbf{y}}$ . Wenn  $\bar{R}^2 = 1$  besteht ein perfekter linearer Zusammenhang zwischen  $\mathbf{y}$  und  $\hat{\mathbf{y}}$ , sollte allerdings  $\bar{R}^2 \ll 1$  oder sogar negativ sein, dann besteht kein linearer Zusammenhang zwischen der Zeitreihe und ihrer Schätzung. Für ein ungeschädigtes System kann  $\hat{\mathbf{y}}$  gut mit Hilfe der AR-Koeffizienten des Modells aus der Gl. (3.23) geschätzt werden, z.B. für  $R^2 > 0,8$ . Andererseits kann eine schlechte Schätzung auf Schäden oder auf Änderung der EOCs zurückgeführt werden, die Veränderungen in dem dynamischen Verhalten der Struktur hervorgerufen haben. Das Bestimmtheitsmaß hat allerdings keine Aussagekraft über die Signifikanz des ermittelten Zusammenhangs zwischen  $\mathbf{y}$  und  $\hat{\mathbf{y}}$ . Dazu sollte zusätzlich ein Signifikanztest durchgeführt werden. Analog zu anderen Techniken für univariate Zeitreihen, siehe Gl.(3.5), wird hier ein Signifikanztest mit Hilfe der geschätzten Residuenkovarianzmatrizen des ARV-Modells vorgeschlagen, die nach [NEUMAIER und SCHNEIDER 2001] wie folgt definiert sind:

$$\Sigma_{n_m} = \frac{1}{n_t - mp - 1} \sum_{k=1}^{n_t} (\boldsymbol{\varepsilon}_k)_{n_m} (\boldsymbol{\varepsilon}_k)_{n_m}^T. \quad (3.27)$$

Hierbei sollen die Kovarianzmatrizen  $\Sigma_{n_m}$  mit der Kovarianzmatrix  $\Sigma_{ref}$  einer Referenzzeitreihe verglichen werden. Der Vergleich zwischen den Kovarianzmatrizen, kann mit Hilfe unterschiedlicher Werkzeuge der multivariaten Analyse von Varianzen (eng. *Multivariate*

<sup>1</sup> auch als Determinationskoeffizient, eng. *coefficient of determination* bekannt.

*Analysis of Variances*, MANOVA) wie z.B. dem M-BOX-Test [ANDERSON 1958; BOX 1949; STEVENS 1992] erfolgen, der auf dem Test der Wahrscheinlichkeitsverhältnisse (eng. *Likelihood Ratio Test*) [COX und HINKLEY 1974] basiert. In der Literatur werden diese Tests auch als sog. Homoskedastizitäts- oder Varianzhomogenitäts-Tests bezeichnet.

Der BOXsche M-Test<sup>1</sup> wird bei der Diskriminanzanalyse zum Test auf Gleichheit von Streuungen in Gruppen verwendet. Dabei überprüft man, ob die Hypothese

$$H_0 : \mathbf{S} = \mathbf{S}_i \quad (3.28)$$

angenommen werden kann, wobei  $\mathbf{S}$  eine aus  $g$  Gruppen von Kovarianzmatrizen  $\mathbf{S}_i$  gemittelte Kovarianzmatrix (eng. *pooled covariance matrix*) ist. Dieser Test wurde von [BOX 1949] auf Basis der Wahrscheinlichkeitsverhältnisse entwickelt. Die Prüfgröße für den Test ist die Größe  $M$  nach BOX:

$$M = (\tilde{n} - g) \log |\mathbf{S}| - \sum_{i=1}^g (\tilde{n}_i - 1) \log |\mathbf{S}_i| \quad (3.29)$$

mit

$$\mathbf{S} = \frac{1}{\tilde{n} - g} \sum_{i=1}^g (\tilde{n}_i - 1) \mathbf{S}_i \quad \text{und} \quad \tilde{n} = \sum_{i=1}^g \tilde{n}_i. \quad (3.30)$$

$m$  repräsentiert die Anzahl der Vektoren und  $\tilde{n}_i$  die Anzahl der Daten in jedem Vektor aus denen  $\mathbf{S}_i$  geschätzt ist. Bei jeweils genügend großem  $\tilde{n}_i$  ist die Prüfgröße annähernd  $\chi^2$ -verteilt mit

$$f_{\chi^2} = \frac{m(m+1)(g-1)}{2} \quad (3.31)$$

Freiheitsgraden. Das Signifikanzniveau  $P$  berechnet sich aus der Summenhäufigkeit der  $\chi^2$ -Verteilung für  $M(1-\gamma)$  mit  $f_{\chi^2}$ -Freiheitsgraden. Dieses stellt die Wahrscheinlichkeit dar, mit der die berechnete Prüfgröße vorkommen kann:

$$P = 1 - \chi^2 \left( M(1-\gamma), f_{\chi^2} \right), \quad (3.32)$$

wobei

---

<sup>1</sup> M steht für *Modified likelihood statistic*.

$$\gamma = \frac{2m^2 + 3m - 1}{6(m+1)(g-1)} \left( \sum_{i=1}^g \frac{1}{(\tilde{n}_i - 1)} - \frac{1}{(\tilde{n} - g)} \right) \quad (3.33)$$

so angepasst wird, dass der Schwellenwert für das Konfidenzintervall  $\alpha$  direkt aus der inversen  $\chi^2$ -Verteilung mit  $f_{\chi^2}$ -Freiheitsgraden berechnet werden kann:

$$M(1 - \gamma) < (\chi^2)_{1-\alpha, f_{\chi^2}}^{-1} \quad (3.34)$$

Übersteigt die Prüfgröße den Schwellenwert, dann liegt ein signifikanter Unterschied zwischen den Kovarianzmatrizen  $\mathbf{S}_i$  vor und die  $H_0$  Hypothese wird verworfen.

Für relativ kleine Werte  $\tilde{n}_i$  wird die Prüfgröße als annähernd  $F$ -verteilt mit den Freiheitsgraden  $f_{F_1}$  und  $f_{F_2}$  angenommen:

$$f_{F_1} = \frac{m(m+1)(g-1)}{2}, \quad f_{F_2} = \frac{(f_{F_1} + 2)}{(\tau - \gamma^2)} \quad (3.35)$$

Hierbei berechnet sich  $\tau$  wie folgt:

$$\tau = \frac{(m-1)(m+2)}{6(g-1)} \left( \sum_{i=1}^g \frac{1}{(\tilde{n}_i - 1)^2} + \frac{1}{(\tilde{n} - g)^2} \right) \quad (3.36)$$

Das Signifikanzniveau  $P$  wird dann über die kumulative  $F$ -Verteilung

$$P = 1 - F\left(M(1/f_{F_1} - \gamma/f_{F_1} - 1/f_{F_2})\right) \quad (3.37)$$

und der Schwellenwert für die Prüfgröße aus der inversen der  $F$ -Verteilung mit dem Konfidenzintervall  $\alpha$  berechnet:

$$M(1/f_{F_1} - \gamma/f_{F_1} - 1/f_{F_2}) < F_{1-\alpha, f_{F_1}, f_{F_2}}^{-1} \quad (3.38)$$

Basierend auf dem M-BOX-Test kann die Signifikanz des Zusammenhangs der Residuenkovarianzmatrizen mit Hilfe der Hypothese

$$H_0 : \Sigma_{pool} = \Sigma_{n_m} \quad (3.39)$$

ermittelt werden.  $\Sigma_{pool}$  ist hier eine Kovarianzmatrix gemittelt aus  $\Sigma_{ref}$  und  $\Sigma_{n_m}$  nach Gl. (3.30) und  $\tilde{n}_i = n_i - mp - 1$ . Die Schädigungsindikatoren können jetzt aus den Verhältnis der zwei Kovarianzmatrizen berechnen werden:

$$DI_{n_m}^{ARV} = M(1 - \gamma) \text{ für } n_t - mp - 1 \rightarrow \infty, \quad (3.40)$$

$$DI_{n_m}^{ARV} = M\left(1/f_{F_1} - \gamma/f_{F_1} - 1/f_{F_2}\right) \text{ für kleine } n_t - mp - 1.$$

Wenn diese Indikatoren die vorgegebenen Schwellenwerte aus der Gl. (3.34) bzw. (3.38) nicht überschreiten, dann charakterisieren sie die ungeschädigte Struktur. Andernfalls überschreiten die Indikatoren die Schwellenwerte, wenn z.B. die Struktur geschädigt ist.

Bei der Festlegung des Schwellenwertes in Gl. (3.34) und (3.38) spielt die Anzahl der Daten im betrachteten Vektor  $\tilde{n}_i$  eine große Rolle. Je größer die Anzahl ist, umso vertrauenswürdiger wird die Schätzung der Kovarianzmatrizen eingestuft und schon geringfügige Abweichungen zwischen den Kovarianzmatrizen werden dadurch stärker bestraft. Gerade diese Eigenschaft macht die Schadensindikatoren aus Gl. (3.40) sehr empfindlich gegenüber geringsten Änderungen in den Residuen, die durch Schäden aber auch durch Änderungen der Betriebszustände verursacht werden können.

### 3.3.3 Anwendung von Klassifikationsverfahren zur Kompensation von Effekten veränderlicher Umgebungs- und Betriebszustände auf die schädigungssensitiven Merkmale

#### 3.3.3.1 Der Algorithmus zur EOC-Kompensation

Um die Effekte der EOC auf die Residuen zu berücksichtigen, wird in dieser Arbeit, wie schon in Abschnitt 3.3.2.1 dargestellt, von Klassifikationsverfahren Gebrauch gemacht. Hierbei handelt es sich um eine Methode, die gleichzeitig ein Merkmal des Strukturzustands (Schadensindikator) aus der Schwingungssignatur und eine oder mehrere gemessene EOC verwendet (siehe Fall II in Abbildung 3.10 und Abschnitt 3.3.1).

In Abbildung 3.22 ist der Algorithmus als Flussdiagramm dargestellt. Er besteht aus einer Lern- und einer Testphase. Durch Anwendung von Klassifikationsverfahren, wie in Abbildung 3.14 und Abbildung 3.15 beispielhaft gezeigt, sollen möglichst wenige repräsentative Betriebszustände und Umgebungseinflüsse, die Veränderungen des Schädigungsparameters verursachen, gefunden und die Einflüsse von nicht angelernten EOCs auf die Schädigungsmerkmale, auch während der Testphase, weiter angelernt werden.

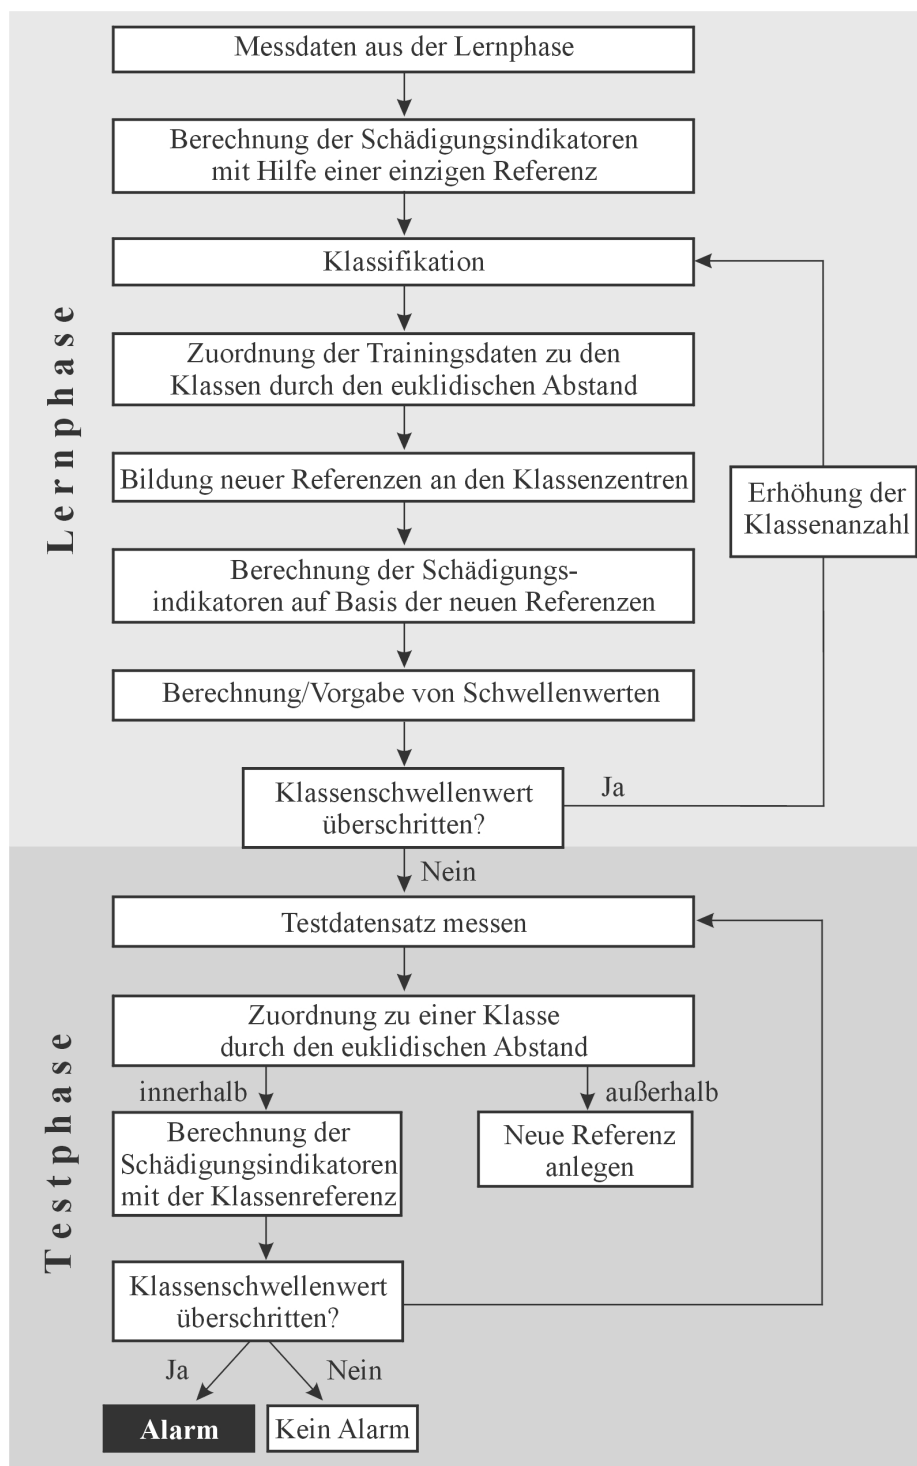


Abbildung 3.22: Flussdiagramm: Algorithmus zur Schadendetektion unter veränderlichen Umgebungseinflüssen mit Hilfe von Klassifikationsverfahren

### Lernphase

In der Lernphase wird gefordert, dass innerhalb dieser Zeit kein Strukturschaden vorhanden ist. Sollte es doch vorkommen, dass die Anlage Schaden genommen hat, so kann dieser im weiteren Verlauf nicht mehr erkannt werden, d.h. der Schaden wird mittrainiert.



In einem ersten Schritt werden die Schädigungsindikatoren aus mehreren vorhandenen Messdaten mit Hilfe einer einzigen Referenz berechnet. Hierfür wird Gl. (3.14) für die NSFD und Gl. (3.40) für die auf ARV-Modellen basierende Methode angewendet. Dieser Vorgang wird benötigt, um den Einfluss der EOC auf die Schädigungsindikatoren festzulegen. Dadurch wirkt die Klassifikation wie eine „Sensitivitätsanalyse“ der Indikatoren unter Einwirkung der EOC. Die somit errechneten Schädigungsindikatoren werden zusammen mit den betrachteten EOCs ( $\theta^{EOC}$ ) als Eingangsgrößen

$$\theta = [DI \ \theta^{EOC}] \quad (3.41)$$

für die Klassifikation mit Hilfe des *k-medoid*-Algorithmus verwendet (siehe Abschnitt 2.4.1). Für die Validierung der Klassifikation wird der *Clustering*vorgang mehrmals mit unterschiedlichen Initialisierung der Klassenzentren gestartet und das Ergebnis mit der kleinsten Partitionsvarianz nach Gl. (2.93) zur weiteren Berechnung gewählt.

Nach der Klassifikation werden die Schädigungsindikatoren für jede Klasse separat neu berechnet, wobei sich die Referenzdaten für jede Klasse an den entstandenen Klassenzentren befinden. In Gl. (3.42) werden beispielhaft für die NSFD-Methode die  $i$  Residuen der Klasse  $S_j$  (repräsentativ für eine EOC-Kombination) mit Hilfe von  $i$  Hankelmatrizen und einem linken Kernelraum des Klassenreferenzdatensatzes (Index 0) berechnet

$$\zeta_i^{(S_j)} = \text{vec}[\mathbf{K}_0^{(S_j)} \mathbf{H}_i^{(S_j)}], \quad i \in S_j, \quad j = 1 \dots c \quad (c = \text{Anzahl aller Klassen}) \quad (3.42)$$

Die Schädigungsindikatoren einer betrachteten Klasse entstehen nach dem gleichen Muster wie in Gl. (3.14)

$$DI_i^{(S_j)} = \zeta_i^{(S_j)T} \hat{\Sigma}^{-1(S_j)} \zeta_i^{(S_j)}. \quad (3.43)$$

Unmittelbar nach der Berechnung der Schadensindikatoren, können bei einer genügend großen Anzahl von Daten die Schwellenwerte für jede Klasse nach Gl. (3.44) festgelegt werden, vgl. auch Gl. (3.22).

$$H_0 : DI_i^{(S_j)} < [\text{GEV}^{(S_j)}]_{1-\alpha}^{-1}. \quad (3.44)$$

Die voreingestellte Anzahl von Klassen bestimmt die Sensitivität der Methode gegenüber der Entdeckung kleiner Strukturschäden und somit die Höhe des Schwellenwertes aus der generalisierten Extremwertverteilung. Die Anzahl der Klassen kann so ausgelegt werden, dass es für eine bestimmte Klasse nicht zu einer Überschreitung eines voreingestellten Schwellenwertes kommt. Eine weitere Möglichkeit - in dieser Arbeit nicht weiter verfolgt - ist die

Steuerung der Klassenanzahl über einen erwarteten Schadenstyp oder das Schadensausmaß. Mit Hilfe von Simulationen oder aus Erfahrungswerten kann die Klassenanzahl festgelegt werden, um einen bestimmten Schaden zu entdecken.

Sollte die Anzahl der Klassen für einen Schadensidentifikationszweck nicht zufriedenstellend sein, kann sie verringert oder erhöht werden, wobei der Klassifikationsvorgang erneut in der Lernphase durchgeführt wird.

Analog zu der NSFD-Methode kann die bisherige Vorgehensweise auch auf die Schadensindikatoren der ARV-Methode angewendet werden, indem die Größe  $M$  von BOX für jede Klasse  $S_j$  separat und für jeden Datensatz  $i$  dieser Klasse ermittelt wird. Hierbei ergeben sich zuerst aus dem Vergleich der Residuenkovarianzmatrizen  $\mathbf{S}_i^{(S_j)}$  mit der Klassenreferenzkovarianzmatrix  $\mathbf{S}_0^{(S_j)}$  für  $g = 2$  die Matrizen  $\Sigma_{pool}$ , siehe auch Gl. (3.30) und (3.39):

$$\Sigma_{pool_i}^{(S_j)} = \frac{1}{2}(\mathbf{S}_i^{(S_j)} + \mathbf{S}_0^{(S_j)}). \quad (3.45)$$

Somit kann jetzt die Größe  $M$  nach Gl. (3.29) berechnet werden. Dieses wird dann zur Ermittlung des Schadensindikators nach Gl. (3.40) benötigt.

$$M_i^{(S_j)} = (n_t - mp - 2) \cdot \log \left( \frac{|\Sigma_{pool_i}^{(S_j)}|^2}{|\mathbf{S}_0^{(S_j)}| |\mathbf{S}_i^{(S_j)}|} \right). \quad (3.46)$$

Falls die vorgegebenen Schwellenwerte aus Gl. (3.34) oder (3.38) schon während der Lernphase überschritten werden, sollte eine Klassifikation mit erhöhter Zentrenanzahl erfolgen bis es nicht mehr zu einer Schwellenwertüberschreitung kommt. Da diese Methode auf einem Testverfahren mit schon im Voraus festgelegten Schwellenwerten beruht, kann es dazu kommen, dass ungenügende Daten in der Testphase zu einer ungenügenden Homogenität zwischen den Kovarianzmatrizen führen und dadurch zu eine sehr großen Anzahl an Klassen und Rechenzeiten. Um dieses Verhalten zu vermeiden, kann man hier auf den statistischen Test verzichten, die  $M$ -Werte für jede Klasse anhand der GEV modellieren und die Schwellenwerte analog zu der Gl. (3.44)  $M_i^{(S_j)} < [\text{GEV}^{(S_j)}]_{1-\alpha}^{-1}$  aufstellen.

### *Testphase*

Die Testphase schließt sich der Lernphase unmittelbar an. In dieser Phase werden neue Daten gemessen und während des Monitoring-Prozesses nur anhand ihrer zugehörigen EOCs zu den

Klassen zugewiesen. Dies erfolgt über den euklidischen Abstand der Daten  $\theta_{n_m}^{EOC}$  zu den etablierten Klassenzentren  $\mu_{c_j}^{EOC}$ :

$$d_{n_m}^{test} = \min \left\| \theta_{n_m}^{EOC} - \mu_{c_j}^{EOC} \right\|^2 \quad \text{mit} \quad \mu_{c_j}^{EOC} = \frac{1}{N_j - 1} \sum_{i \in S_j} \theta_i^{EOC} \quad (3.47)$$

Bei einem Abstand  $d_{n_m}^{test}$  zum Zentrum  $\mu_{c_{zug}}^{EOC}$  der nächsten Klasse (Index *zug*), der kleiner als die Klassengrenze

$$d_{n_m}^{test} \leq \max_{i \in S_{zug}} \left\| \theta_i^{EOC} - \mu_{c_{zug}}^{EOC} \right\|^2 \quad (3.48)$$

ist, wird dieser Testdatensatz (Datum) zu der Klasse zugewiesen und ein Schadensindikator zusammen mit dem Referenzdatensatz der Klasse berechnet. Ist der Schädigungsindikator größer als der für diese Klasse berechnete Schwellenwert, dann kann dieses Verhalten auf einen Schaden zurückgeführt werden. Sollte der Abstand zum nächsten Klassenzentrum größer als die Klassengrenze sein, dann lässt sich dieser Datensatz keiner bisherigen Klasse zuweisen. Diese Situation deutet auf einen bislang nicht angelernten Effekt einer EOC-Konfiguration hin. In diesem Fall wird dieses Datum zum Referenzdatensatz einer neuen Klasse. Die Grenze  $r^{test}$  aller Klassen, entstanden während der Testphase, wird als Mittelwert der Klassengrenzen aus der Lernphase definiert

$$r^{test} = \frac{1}{c-1} \sum_{j=1}^c \max_{i \in S_j} \left\| \theta_i^{EOC} - \mu_{c_j}^{EOC} \right\|^2. \quad (3.49)$$

Der Schwellenwert für eine neue Klasse kann erst nach Aufbau der Verteilung der Indikatoren berechnet werden. Sollte ein Strukturschaden während des Aufbaus von neuen Klassen vorkommen, dann lässt sich dieser später mit Indikatoren dieser Klassen nicht mehr erkennen. In diesem Fall wird der Schaden erst entdeckt, wenn angelernte EOC vor dem Auftreten der Strukturveränderung wieder vorkommen, z.B. wenn der aktuelle Indikator mit Referenzdaten aus der Trainingsphase berechnet wird. Ein Flussdiagramm des Algorithmus ist in der Abbildung 3.22 dargestellt.

### 3.3.3.2 Alternative EOC-Kompensation mit Hilfe von Fuzzy-Klassifikation

Die *Fuzzy*-Klassifikation bietet eine weitere Möglichkeit zur Kompensation der EOC-Effekte bei den Schadensindikatoren. Die hier erläuterte Methode ist eine Erweiterung des Ansatzes

von [BASSEVILLE *et al.* 2006] aus Gl. (3.16). Dieser Ansatz berechnet die Schadensindikatoren bisher mit Hilfe einer gemittelten Hankelmatrix. Dadurch werden unterschiedliche EOC-Einflüsse auf die Indikatoren gleich gewichtet. In dem erweiterten Ansatz soll jeder einzelne Indikator mit unterschiedlich gewichteten Hankelmatrizen ermittelt werden. Der erste Schritt in der Offline-Phase ist, wie im Abschnitt 3.3.3.1 beschrieben, die Berechnung aller Indikatoren mit einer einzigen Referenz. Die nachträgliche Klassifikation der Indikatoren (zusammen mit den zugehörigen EOC) erfolgt dann durch den *Fuzzy*-Algorithmus beschrieben in Abschnitt 2.4.1. Hierbei wird zusätzlich der *k-medoid*-Algorithmus genutzt, um die Klassenzentren an die nächstliegenden Eingangsdaten  $\theta$  heranzuziehen. Danach wird Gl. (2.99) zur Bestimmung der Gewichtungen  $w_{ji}$  erneut berechnet.

Die Referenzhankelmatrix für einen Datensatz  $i$  berechnet sich somit aus mehreren unterschiedlich gewichteten Hankelmatrizen  $\mathbf{H}_0^{(\mu_{c_j})}$  der Referenzdatensätze, welche die Referenzen/Klassenzentren  $\mu_{c_j}$  repräsentieren

$$(\mathbf{H}_0)_i^{EOC} = \sum_{j=1}^c w_{ji} \mathbf{H}_0^{(\mu_{c_j})}. \quad (3.50)$$

Der linke Nullraum  $(\mathbf{K}_0)_i^{EOC}$  für den Datensatz  $i$  kann nun nach Gl. (3.11) aus der Hankelmatrix  $(\mathbf{H}_0)_i^{EOC}$  berechnet werden. Der Schädigungsindikator gestaltet sich somit zu:

$$DI_i = \zeta_i^T (\Sigma^{-1})^{EOC} \zeta_i \quad \text{mit} \quad \zeta_i = \text{vec}[(\mathbf{K}_0)_i^{EOC} \mathbf{H}_i] \quad (3.51)$$

und

$$\Sigma^{EOC} = \frac{1}{j-1} \sum_{j=1}^c (\zeta_j)^{(\mu_{c_j})} (\zeta_j^T)^{(\mu_{c_j})} \quad (3.52)$$

mit  $(\zeta_j)^{(\mu_{c_j})}$  als Residuum des Datensatzes an dem Klassenzentrum  $\mu_{c_j}$ .

Während der Testphase werden die Datensätze  $n_m$  durch Gewichtungsfaktoren  $w_{jn_m}$  den aufgestellten Klassenzentren zugewiesen

$$w_{jn_m} = \frac{d_{jn_m}^2}{\sum_{j=1}^c d_{jn_m}^2} \quad (3.53)$$

und die Schadensindikatoren entsprechend der Gl. (3.50) und (3.51) für  $n_m = i$  berechnet.

Im Fall einer ungeschädigten Struktur (Index  $u$ ) ist die Abweichung zwischen der aktuell ermittelten Hankelmatrix und der Referenzhankelmatrix:

$$\Delta \mathbf{H}_{n_m} = \mathbf{H}_{n_m}^{(u)} - \sum_{j=1}^c w_{jn_m} \mathbf{H}_0^{(\mu_{c_j})} = 0. \quad (3.54)$$

Ist im Gegensatz dazu ein Schaden vorhanden (Index  $g$ ), so wirkt sich dies auf die Einträge der Matrix  $\Delta \mathbf{H}_{n_m}$  aus, die jetzt von Null abweichen:

$$\mathbf{H}_{n_m}^{(g)} = \mathbf{H}_{n_m}^{(u)} + \Delta \mathbf{H}_{n_m}. \quad (3.55)$$

Die Auswirkung eines Schadens auf das Residuum lässt sich somit z.B. mit der Veränderung des Abstands zwischen  $\mathbf{H}_{n_m}^{(g)}$  und den aufgestellten Klassenzentren deuten. Diese können mit

Hilfe des Zusatzterms  $\sum_{j=1}^c w_{jn_m} \Delta \mathbf{H}_{n_m}^{(\mu_{c_j})}$  wie folgt ausgedrückt werden<sup>1</sup>:

$$\begin{aligned} \zeta_{n_m}^{(g)} &= (\mathbf{K}_0)_{n_m}^{EOC} \sum_{j=1}^c w_{jn_m} (\mathbf{H}_0^{(\mu_{c_j})} + \Delta \mathbf{H}_{n_m}^{(\mu_{c_j})}) \\ &= \underbrace{(\mathbf{K}_0)_{n_m}^{EOC} \sum_{j=1}^c w_{jn_m} \mathbf{H}_0^{(\mu_{c_j})}}_{=0} + \underbrace{(\mathbf{K}_0)_{n_m}^{EOC} \sum_{j=1}^c w_{jn_m} \Delta \mathbf{H}_{n_m}^{(\mu_{c_j})}}_{\neq 0} \neq 0. \end{aligned} \quad (3.56)$$

$\Delta \mathbf{H}_{n_m}^{(\mu_{c_j})}$  in Gl. (3.56) repräsentiert eine Änderung des Referenzzustandes an den Klassenzentren infolge des Schadens. Ein Schaden kann aber auch direkt aus dem Produkt des linken Nullraums und der Hankelmatrix einer geschädigten Struktur

$$\begin{aligned} \zeta_{n_m}^{(g)} &= (\mathbf{K}_0)_{n_m}^{EOC} \mathbf{H}_{n_m}^{(g)} = (\mathbf{K}_0)_{n_m}^{EOC} (\mathbf{H}_{n_m}^{(u)} + \Delta \mathbf{H}_{n_m}) \\ &= \underbrace{(\mathbf{K}_0)_{n_m}^{EOC} \mathbf{H}_{n_m}^{(u)}}_{=0} + \underbrace{(\mathbf{K}_0)_{n_m}^{EOC} \Delta \mathbf{H}_{n_m}}_{\neq 0} \neq 0 \end{aligned} \quad (3.57)$$

erkannt werden.

Der Vorteil der Methode ist, dass der EOC-Einfluss auf die Schadensindikatoren durch entsprechende Gewichtungen berücksichtigt ist. Dadurch wird hier - im Gegensatz zu [BASSEVILLE *et al.* 2006] - die Berechnung der Indikatoren auf Grund von repräsentativen,

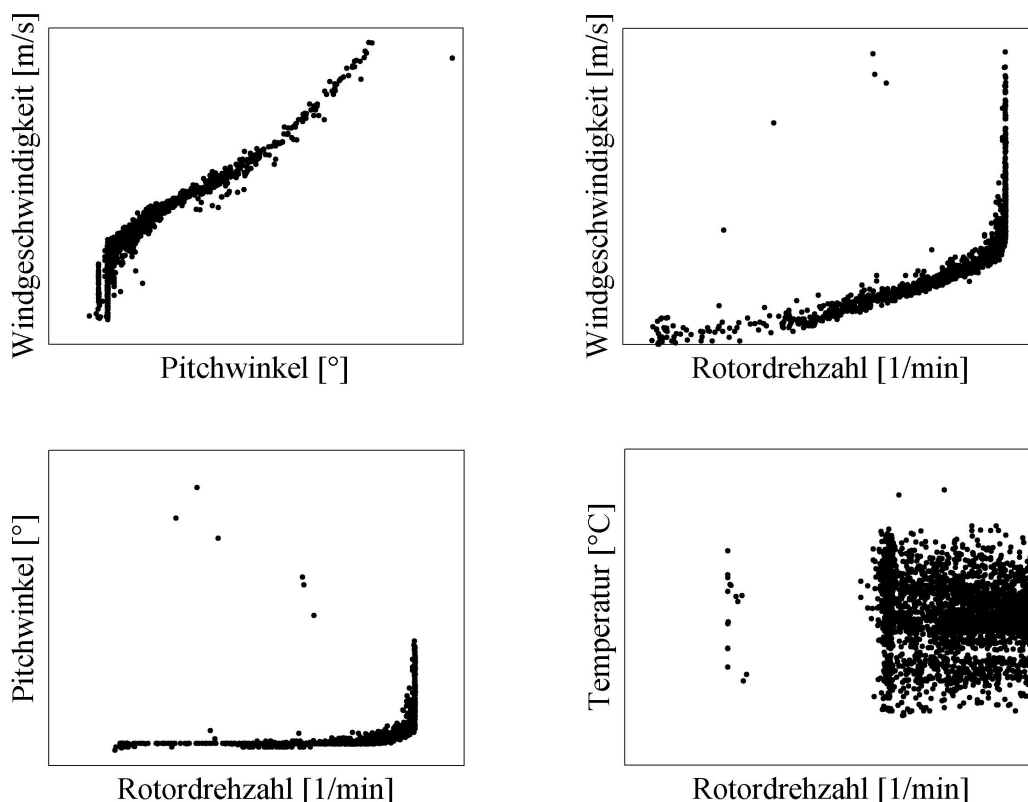
---

<sup>1</sup> Aus Übersichtlichkeitsgründen wird in Gl. (3.56) und (3.57) auf die Beschreibung des Residuums als  $\zeta_{n_m} = \text{vec}[\dots]$  verzichtet.

nächstliegenden Referenzen durchgeführt. Ein Nachteil der Methode ist, dass die angelernten Einflüsse auf die Indikatoren nicht mehr durch den Aufbau neuer Klassen in der Testphase erweitert werden können. Bei einer ausreichend guten Trainingsphase, ist diese Methode dem auf dem *k-means* basierten Ansatz vorzuziehen, da sich der Schwellenwert, nach Gl. (3.22), aus einer einzigen GEV-Verteilung der Indikatoren berechnen lässt.

### 3.3.3.3 Reduktion der Dimensionalität des Eingangsparameteraums

Sollten lineare oder nicht-lineare Korrelationen zwischen den gemessenen Umgebungseinflüsse und der danach geregelten Betriebszuständen der Anlage bestehen, dann bietet sich eine Reduktion der EOC-Variablen mit Hilfe von PCA bzw. NLPCA an. Dadurch soll ein exponentieller Anstieg der Klassenanzahl nach Möglichkeit vermieden werden. Ein Beispiel dazu gibt Abbildung 3.23.



**Abbildung 3.23: Beispielhafte Korrelationen zwischen unterschiedlichen EOCs**

Abbildung 3.23 zeigt anhand gemessener EOCs an der Anlage M5000-2, dass der Pitchwinkel mit der Rotordrehzahl und mit der Windgeschwindigkeit regelungsbedingt in einer gewissen nicht-linearen Korrelation stehen. Diese drei EOCs können mit einer einzigen nicht-linearen Hauptachse beschrieben werden. Da die ersten drei EOCs verständlicherweise nicht mit der

Temperatur korrelieren, führt die Komprimierung der Daten zu einer Dimensionalitätsreduktion von vier auf zwei. Die Projektion der EOCs auf Hauptachsen und die Überprüfung dieser Datenreduktion befindet sich im Ergebniskapitel in Abbildung 5.28 bzw. Abbildung 5.29. Dadurch kann die Klassifikation ohne weitere beträchtliche Informationsverluste anhand der ersten zwei nicht-linearen Komponenten anstatt der vier erwähnten EOCs vorgenommen werden.

### 3.3.4 Datenvorauswahl für Schadenserkenngsalgorithmen

Um die Bedingungen für den Einsatz der obengenannten Methoden zu gewährleisten, dürfen zur Zustandsüberwachung einer Struktur nur geeignete Daten herangezogen werden.

Da alle Methoden zur Schadenidentifikation schwingungsbasiert sind, sollen nur Zeitdaten von einer gut angeregten Struktur ausgewertet werden. Gemessene Zeitdaten mit einem schlechten Signal-zu-Rauschen-Verhältnis können besonders bei einer automatischen Auswertung der Zeitdaten zu falschen Interpretationen des Strukturzustandes führen. Weiterhin benötigen die *Output-Only*-Methoden zur Schadensidentifikation eine stochastische Anregung. Zeitdaten mit Ausreißern infolge transienter Vorgänge in der Anregung verletzen diese Annahme und können die Ergebnisse der Auswertung verfälschen, siehe auch Abschnitt 3.1.

Das Vermeiden der Auswertung von Daten mit Ausreißern wird mit Hilfe der multivariaten Ausreißeranalyse (engl. *outlier analysis*) erreicht. [BARNETT und LEWIS 1984] schlagen hierfür den Mahalanobis-Abstand vor. Der Mahalanobis-Abstand ist ein Distanzmaß zwischen Punkten in einem mehrdimensionalen Vektorraum und wird durch die folgende Formel beschrieben:

$$M_D = (\mathbf{y} - \bar{\mathbf{y}})^T \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \bar{\mathbf{y}}). \quad (3.58)$$

Mathematisch ergibt sich die Mahalanobis-Distanz aus dem Logarithmus einer  $m$ -dimensionalen Normalverteilung mit dem Erwartungswertvektor  $\bar{\mathbf{y}}$  und der Kovarianzmatrix  $\boldsymbol{\Sigma}$ .

$$N(\bar{\mathbf{y}}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{m/2} \sqrt{|\det(\boldsymbol{\Sigma})|}} \exp\left[-\frac{1}{2} (\mathbf{y} - \bar{\mathbf{y}})^T \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \bar{\mathbf{y}})\right]. \quad (3.59)$$

Ein Schwellenwert für die Mahalanobis-Abstände kann mit Hilfe eines F-Tests für multivariate Zeitreihen mit den Freiheitsgraden  $m$  und  $n_t - m - 1$  bestimmt werden. Nach [YANG und LEE 1987] und [RENCHER 2002] ergibt sich für den oberen Schwellenwert  $T_M$ :

$$T_M = \frac{m(n_t - 1)^2 F_{1-\alpha/n_t, m, n_t - m - 1}^{-1}}{n_t(n_t - m - 1) + n_t m F_{1-\alpha/n_t, m, n_t - m - 1}^{-1}}. \quad (3.60)$$

$F_{1-\alpha/n_t, m, n_t - m - 1}^{-1}$  ist die Inverse einer kumulativen F-Verteilung mit den gegebenen Freiheitsgraden und dem Konfidenzintervall  $\alpha$ . Für Zeitreihen mit einer großen Anzahl  $n_t - m - 1$  Freiheitsgraden wurde in [RENCHER 2002] eine BONFERRONI-Korrektur des Konfidenzintervalls mit  $1 - \alpha/n_t$  vorgeschlagen.

In Abbildung 3.24 und Abbildung 3.25 wird diese Methode veranschaulicht. Abbildung 3.24 zeigt beispielhaft drei normalverteilte Signale ( $m = 3$ ) mit je 1000 Datenpunkten ( $n_t = 1000$ ) und unterschiedlichen Standardabweichungen. Das zweite und das dritte Signal haben jeweils einen Ausreißer, die in grau markiert sind. Diese Ausreißer werden nach der Anwendung der multivariaten Ausreißeranalyse durch die Überschreitung des Schwellenwertes der Mahalanobis-Norm identifiziert, vgl. Abbildung 3.25.




Abbildung 3.24: Multivariate Zeitreihe mit zwei Ausreißern im Signal 2 und 3






Abbildung 3.25: Identifizierter Ausreißer mit Hilfe des Mahalanobis-Abstandes für  $\alpha=0,05$

Abschließend zu Abschnitt 3.3 wird zusammengefasst, dass die Schadensdetektion mit Hilfe von Residuen aus Zeitreihenmodellen (SSI oder ARV) durchgeführt werden. Die Kompensation der EOC-Einflüsse auf die Schadensindikatoren geschieht mit Hilfe von Klassifikationsverfahren unter Einbeziehung gemessener Umgebungs- und Betriebszustände.

### 3.4 MODELLGESTÜTZTE SCHADENSLOKALISATION MIT HILFE VON MODALDATEN

Das Schadenslokalisationsmodul folgt, wie schon im Gesamtüberwachungskonzept beschrieben (Abbildung 3.9), unmittelbar nach der Detektion einer strukturellen Veränderung. Der erste Teil des Abschnitts befasst sich mit der Extraktion der Modaldaten aus den Messdaten, die in einem zweiten Abschnittsteil zur Schadenslokalisierung genutzt werden.

#### 3.4.1 Modalanalyse mit Vektor-Autoregressiven Modellen

Die experimentelle *Output-Only*-Modalanalyse umfasst die Charakterisierung des dynamischen Verhaltens schwingungsfähiger Systeme mit Hilfe ihrer Eigenschwingungsgrößen: Eigenfrequenz, Eigenschwingungsform und Dämpfungsverhältnisse. Diese physikalischen Größen können aus gemessenen Zeitreihen im Zeit- und Frequenzbereich extrahiert werden. Eine Übersicht unterschiedlicher Methoden ist in z.B. [ANDERSEN *et al.* 1999; EWINS 2000; HEYLEN *et al.* 1998; PEETERS 2000] vorgestellt.

Die im Abschnitt 2.2 vorgestellten Methoden zur Systemidentifikation bieten eine Grundlage sowohl zur Schadensdetektion mit Hilfe von Residuen der identifizierten Systeme, als auch eine Grundlage für die Modalanalyse. So erhält man die Eigenwerte und Eigenvektoren des

Systems mit Hilfe des Eigenwertproblems aus Gl. (2.30). Nach der Transformation der Eigenwerte in den zeitkontinuierlichen Bereich

$$\lambda_i = \frac{\ln(\delta_i)}{\Delta t} = -\xi_i \omega_i \pm j \underbrace{\sqrt{1-\xi_i^2}}_{\omega_{D_i}} \omega_i \quad (\Delta t = \text{Zeitinkrement}), \quad (3.61)$$

können die folgenden physikalischen Größen des Systems berechnet werden:

$$\begin{aligned} \text{Eigenfrequenzen: } f_i &= \frac{\omega_{D_i}}{2\pi} = \frac{\text{Im}(\lambda_i)}{2\pi} && (\omega_{D_i} = \text{Eigenkreisfrequenzen der} \\ & && \text{gedämpften Schwingung)} \\ \text{Dämpfungsverhältnisse: } \xi_i &= \frac{-\text{Re}(\lambda_i)}{|\lambda_i|} \end{aligned} \quad (3.62)$$

$$\text{Eigenformen: } \Phi = [\varphi_1 \quad \varphi_2 \quad \dots \quad \varphi_i] = C_y \Psi.$$

Die an den Stellen  $C_y$  extrahierten komplexen Moden werden oft mit Hilfe linearer Regression auf die reelle Achse transformiert. In Abbildung 3.26 ist beispielhaft der komplexe Eigenvektor für eine Mode einer schwach und proportional gedämpften Schwingung dargestellt.

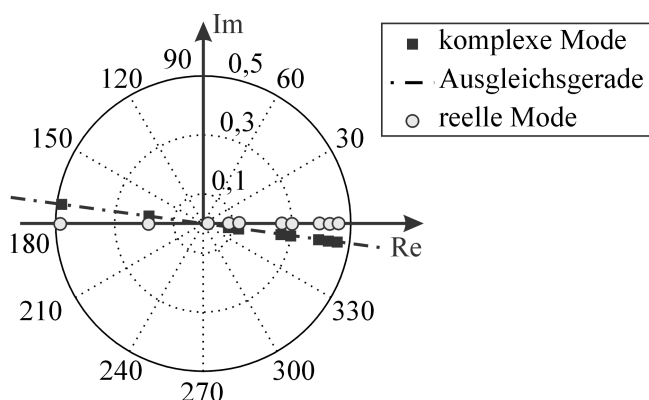


Abbildung 3.26: Transformation komplexer Moden auf die reelle Achse

Nach der Berechnung der Systempole werden die physikalischen von den mathematischen Polen getrennt. Dazu lassen sich die sog. Stabilitätsplots nutzen. Hierfür werden die Pole mit dem im Abschnitt 2.2.2 beschriebenen ARV-Modell (vgl. Gl. (2.56), (2.57), (2.30) und (3.62)) mehrmals für verschiedene Modellordnungen  $p$  berechnet. Um die stabilen Pole des Systems von den instabilen zu trennen, werden nur diejenigen Pole als stabil betrachtet, welche sich von einer Modellordnung  $l-1$  zur nächst höheren Modellordnung  $l$  in nur einem vorgegebenen Toleranzbereich ändern ( $2 \leq l \leq p$ ). Unter anderem definieren [EWINS 2000;

HEYLEN *et al.* 1998] drei Kriterien für die Auswahl der stabilen Frequenzen, der stabilen Dämpfungsverhältnisse und den stabilen Eigenformen:

$$1. \text{ Kriterium: (Stabile Frequenzen):} \quad \text{ftol} \geq \frac{|f_{l-1} - f_l|}{f_{l-1}} 100\% \quad (3.63)$$

$$2. \text{ Kriterium: (Stabile Dämpfungsverhältnisse):} \quad \text{dtol} \geq \frac{|\xi_{l-1} - \xi_l|}{\xi_{l-1}} 100\% \quad (3.64)$$

$$3. \text{ Kriterium: (Stabile Eigenformen):} \quad \text{MACtol} \leq \frac{(\boldsymbol{\varphi}_l^T \boldsymbol{\varphi}_{l-1})^2}{\|\boldsymbol{\varphi}_l^T\|^2 \|\boldsymbol{\varphi}_{l-1}\|^2} \quad (3.65)$$

wobei  $\text{ftol}$ ,  $\text{dtol}$  und  $\text{MACtol}$  *a priori* festgelegte Toleranzbereiche für die stabilen Größen repräsentieren. Gängige Werte für die Toleranzbereiche sind z.B.:  $\text{ftol} = 1\%$ ,  $\text{dtol} = 5\%$  und  $\text{MACtol} = 0,99$  [Ewins 2000; Heylen *et al.* 1998; Peeters 2000]. Hierbei soll beachtet werden, dass  $\text{MACtol} = 1$  eine perfekte Übereinstimmung der Eigenformen darstellt.

Um die Berechnung unnötig hoher Modellordnungen zu vermeiden, kann eine *a priori* geeignete Modellordnung über den Final Prediction Error (FPE) oder über das Schwarz-Bayesian Criterion (SBC) getroffen werden, siehe Gl. (2.52)-(2.53). Die AR-Modellordnung kann auch nach [HAAKE 2010] aus der Anzahl der notwendigen Abtastpunkte zur Erfassung der ersten Struktureigenfrequenz geschätzt werden.

Die Genauigkeit, einige Eigenschaften und die Vorgehensweise bei der betrachteten Methode zur Modalanalyse werden im Folgenden aus Anschaulichkeitsgründen anhand simulierter Schwingungsdaten des schon verwendeten FE-Modells des Balkens aus Abbildung 3.18 vorgestellt (siehe Simulationsbeispiel 1 auf Seite 80).

Die für den Stabilitätsplot notwendigen Informationen über die Modellordnung lassen sich über einen der zwei erwähnten Kriterien (FPE oder SBC) ermitteln.

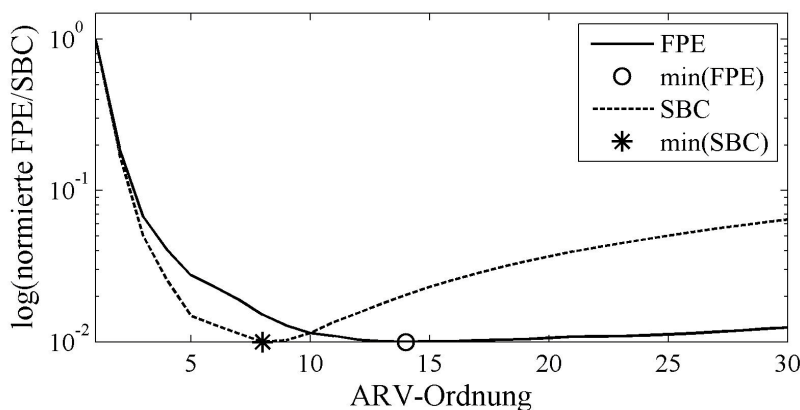



Abbildung 3.27: Geeignete Modellordnung nach dem FPE- und SBC-Kriterium

Abbildung 3.27 zeigt, dass eine Modellordnung von 8 nach dem SBC-Kriterium und eine Modellordnung von 14 nach dem FPE-Kriterium ausreichend für die Darstellung der Dynamik des Systems ist. Der Stabilitätsplot nutzt die Informationen der FPE und SBC-Kriterien und berechnet die Systempole für die Modellordnungen 2 bis 16, wie in Abbildung 3.28 dargestellt. Die Punkte (.) stellen hier alle Pole des Systems, die Kreuze (x) die stabilen Eigenfrequenzen, die Pluszeichen (+) die gleichzeitig stabilen Frequenzen und Dämpfungsverhältnisse und die Kreise (o) die gleichzeitig stabilen Frequenzen, Dämpfungsverhältnisse und MAC-Werte der Eigenschwingungsformen dar. Die Kurve in Abbildung 3.28 stellt ein aus allen beteiligten Sensoren gebildetes auf die Modellordnung normiertes und gemittelt Leistungsdichtespektrum dar. Dieses wird für die Berechnungen der Modalanalyse nicht verwendet und dient lediglich zu einem visuellen Vergleich zwischen den Spektren und berechneten Eigenfrequenzen des Systems.



**Abbildung 3.28: Stabilitätsplots mit Hilfe von ARV-Modellen**

Die Eigenformen der stabilen Pole, hier für die 14. Ordnung dargestellt, zeigen die Schwingungsformen des Systems und können ebenfalls mit Hilfe der Gl. (3.62) visualisiert werden. Abbildung 3.29 zeigt den Vergleich zwischen den normierten Schwingungen des Modells an den Messknoten und den mit der Modalanalyse aus den Zeitdaten identifizierten Schwingungen. Hierbei muss beachtet werden, dass es sich um die Transformation der identifizierten Schwingungen auf die reelle Achse handelt, vgl. Abbildung 3.26.




Abbildung 3.29: Gegenüberstellung der Eigenschwingungsformen

Eine andere Darstellungsform des Vergleiches zwischen den Modellschwingungen (FE-Moden) und den Schwingungen aus der Modalanalyse (MA-Moden) bieten die relativen Abweichungen in den Eigenfrequenzen, die Abweichungen der Dämpfungsverhältnisse, und das MAC-Kriterium, vgl. Abbildung 3.30.




Abbildung 3.30: Vergleich zwischen den Eigenfrequenzen (links), Dämpfungsverhältnissen (Mitte) und Schwingungsformen (rechts)

Analog zu der Vorgehensweise bei der Modalanalyse mit ARV-Modellen, können Stabilitätsplots für die Extraktion von dynamischen Merkmalen einer Struktur auch mit Hilfe des SSI-Algorithmus aufgestellt werden. Abbildung 3.31 zeigt einen Stabilitätsplot, erstellt mit Hilfe der Gleichungen (2.30), (2.48), (2.49), (3.61) und den drei Kriterien für stabile Frequenzen, Dämpfungsverhältnisse und Eigenformen. Die Ordnung  $p$  der berechneten Hankel-Matrizen, verwendet für den Plot in Abbildung 3.31, richtet sich nach der Anzahl der signifikanten Singulärwerte in der Matrix  $S$  aus Gl. (2.44).




Abbildung 3.31: Stabilitätsplots mit Hilfe der SSI

Die Stabilitätsplots können auch zur Erweiterung des Algorithmus für eine automatische Modalanalyse genutzt werden. Wenn *a priori* Kenntnisse über die Eigenfrequenzen, Dämpfungsverhältnisse und Schwingungsmoden des Systems aus einer Referenzmodalanalyse vorliegen, kann die Modalanalyse ohne eine manuelle Auswahl der stabilen Pole durchgeführt werden.

Um den Einfluss der veränderlichen EOCs oder kleine Strukturschäden auf die Dynamik des Systems zu berücksichtigen, werden dazu geeignete Toleranzbereiche für die Schwankungen der Eigenfrequenzen und –schwingungsformen eingeführt. Hierfür lassen sich zuerst die stabilen Frequenzen  $(f_{st})_{n_m}$  jeder Messung bzgl. der stabilen Frequenzen einer Referenzmessung  $(f_{st})_{ref}$  für die Messungen  $1 \leq n_m \leq N_D$  in einem Toleranzbereich  $\alpha_f$  (z.B.  $\alpha_f = 0,1$ )

$$(f_{st})_{ref} - (f_{st})_{ref} \cdot \frac{\alpha_f}{2} \leq (f_{st})_{n_m} \leq (f_{st})_{ref} + (f_{st})_{ref} \cdot \frac{\alpha_f}{2} \quad (3.66)$$

überwachen. Die Grenzen für die Frequenzintervalle können je nach Gestaltung des Referenzstabilitätsplots auch unterschiedlich gewählt werden. Das ist besonders dann notwendig, wenn benachbarte Eigenfrequenzen sehr nah beieinander liegen.

Zur Überprüfung der Ergebnisse lassen sich schließlich die Eigenschwingungsformen aller Pole  $(\Phi_{st})_{n_m}$  der  $n_m$ -ten Messung in den gewählten Intervallen mit den Eigenschwingungsformen  $(\Phi_{st})_{ref}$  der Referenzmessung vergleichen. Dabei soll ein Grenzwert

$\alpha_{\phi_{max}}$  (z.B.  $\alpha_{\phi_{max}} = 0,05$ )

$$\alpha_{\phi_{max}} \geq 1 - \frac{[(\Phi_{st}^T)_{ref}(\Phi_{st})_{n_m}]^2}{\|(\Phi_{st}^T)_{ref}\|^2 \|(\Phi_{st})_{n_m}\|^2} \quad (3.67)$$

nicht überschritten werden.

Um nach der Anwendung der Gl. (3.67) einen einzigen Wert pro Frequenzintervall zu erhalten, wird der Mittelwert der verbliebenen stabilen Pole im untersuchten Intervall gebildet. Die Standardabweichung dieser Werte stellt die Streuung der Pole in dem vorgegebenen Intervall dar und ist dadurch auch ein Maß für die Unsicherheit der Erwartungswerte.

Die bereits beschriebenen Modaldaten eines identifizierten Systems können jetzt mit den berechneten Modaldaten eines geometrisch parametrisierten Referenzmodells verglichen werden. Änderungen in den Modaldaten können somit auf lokale Änderungen der Modellparameter zurückgeführt werden. Dieses lässt sich mit Hilfe einer inversen Eigensensitivitätsmethode erreichen.

### 3.4.2 Schadenslokalisierung mit inversen Eigenwert- und Eigenvektorsensitivitäten

Die hier vorgestellte Methode basiert im Wesentlichen auf der Anwendung bestehender Regressionstechniken zur Lösung eines Gleichungssystems, siehe Abschnitt 3.4.2.1. Somit wird hier auf die Arbeiten von [BALAGEAS *et al.* 2006; FRITZEN *et al.* 1998; NATKE 1992] bezüglich der Aufstellung der Systemgleichungen und auf die Arbeit von [BOHLE 2005] hinsichtlich der robusten Lösung des Gleichungssystems und notwendiger Vorselektionsverfahren zurückgegriffen. Schließlich wird diese Methode für ihre Anwendung in Verbindung mit FE-Modellen mit vielen Freiheitsgraden, die zur Schadenserkenkung an OWEAs notwendig sind, angepasst. Hierbei wird diese um einen weiteren Schritt zur Parametervorselektion mit Hilfe einer schrittweisen Regression erweitert.

#### 3.4.2.1 Aufstellung des Gleichungssystems

Die inverse Eigensensitivitätsmethode ist eine bereits etablierte Methode für die modellgestützte Schadenslokalisierung und basiert auf der Minimierung folgender Zielfunktion:

$$J(\Delta \mathbf{p}) = \boldsymbol{\varepsilon}^T \mathbf{W}_\varepsilon \boldsymbol{\varepsilon} + \Delta \mathbf{p}^T \mathbf{W}_p \Delta \mathbf{p} \rightarrow \min. \quad (3.68)$$

Dabei soll gleichzeitig

$$\boldsymbol{\varepsilon} = \mathbf{S}\Delta\mathbf{p} - \mathbf{r} \quad (3.69)$$

und die Veränderungen der Modellparameter  $\Delta\mathbf{p}$  minimiert werden, wobei beide jeweils mit den symmetrischen und positiv definiten Matrizen  $\mathbf{W}_\varepsilon$  bzw.  $\mathbf{W}_p$  gewichtet sind.  $\mathbf{S}$  aus Gl. (3.69) repräsentiert die Sensitivität des Modells bzgl. der Veränderungen in den berechneten Modaldaten und  $\mathbf{r}$  das Residuum zwischen den gemessenen Modaldaten, siehe auch Gl. (3.74)-(3.79).

Das Minimierungsproblem kann unter Berücksichtigung der Gl. (3.69) durch das Nullsetzen folgender Ableitung gelöst werden:

$$\frac{\partial J}{\partial \mathbf{p}} = 2\mathbf{S}^T \mathbf{W}_\varepsilon \mathbf{S} \Delta\mathbf{p} - 2\mathbf{S}^T \mathbf{W}_\varepsilon \mathbf{r} + 2\mathbf{W}_p \Delta\mathbf{p} = 0. \quad (3.70)$$

Aus der Umstellung der Gl. (3.70) folgt die Sensitivitätsgleichung für den Modellparametervektor:

$$(\mathbf{S}^T \mathbf{W}_\varepsilon \mathbf{S} + \mathbf{W}_p) \Delta\mathbf{p} = \mathbf{S}^T \mathbf{W}_\varepsilon \mathbf{r}. \quad (3.71)$$

Da die Zielfunktion  $J$  nicht-linear ist, von dem Parametervektor  $\Delta\mathbf{p}$  beeinflusst wird und  $\boldsymbol{\varepsilon}$  stückweise linear von  $\Delta\mathbf{p}$  abhängt, muss das Problem

$$\begin{pmatrix} \mathbf{W}_\varepsilon^{1/2} \mathbf{S} \\ \mathbf{W}_p^{1/2} \end{pmatrix} \Delta\mathbf{p} = \begin{pmatrix} \mathbf{W}_\varepsilon^{1/2} \mathbf{r} \\ \mathbf{0} \end{pmatrix}. \quad (3.72)$$

iterativ gelöst werden. Im Kontext einer einfachen linearen Regression lässt sich die Gl. (3.72) für  $\mathbf{W}_p = \mathbf{0}$  und  $\mathbf{W}_\varepsilon = \mathbf{I}$  in ein überbestimmtes Gleichungssystem der Form

$$\mathbf{S}\Delta\mathbf{p} = \mathbf{r} \quad (3.73)$$

überleiten. Dabei erklären sich die Ursachen für das Residuum  $\mathbf{r}$  mit Hilfe der Sensitivitätsmatrix  $\mathbf{S}$ . Hierfür werden die Residuen extrahierter Modaldaten des geschädigten (Index  $g$ ) und des ungeschädigten (Index  $ref$ ) Systems gebildet und miteinander verglichen. Für die Eigenfrequenzresiduen  $\mathbf{r}_f$  gilt damit

$$(\mathbf{r}_f)_i = \frac{\Delta f_i}{(f_{ref})_i} = \frac{(f_g)_i - (f_{ref})_i}{(f_{ref})_i}. \quad (3.74)$$



Die Abweichungen der massennormierten Eigenvektoren des geschädigten Systems im Vergleich zum ungeschädigten Referenzsystem bilden sich zu

$$(\mathbf{r}_\varphi)_i = (\boldsymbol{\varphi}_g)_i - (\boldsymbol{\varphi}_{ref})_i. \quad (3.75)$$

Der Gesamtresiduenvektor ist aus den Teilresiduen aus Gl. (3.74) und (3.75) wie folgt zusammengestellt:

$$\mathbf{r}_{f\varphi} = \begin{bmatrix} \mathbf{r}_f \\ \mathbf{r}_\varphi \end{bmatrix}. \quad (3.76)$$

Die zugehörige Sensitivitätsmatrix besteht aus den in Abschnitt 2.3.1 hergeleiteten Ausdrücken der Eigenfrequenzsensitivitäten für das Referenzmodell (aus Übersichtlichkeitsgründen wird hier auf die Indizierung der Modalgrößen mit *ref* verzichtet):

$$\mathbf{S}_f = \begin{pmatrix} \frac{1}{f_1} \frac{\partial f_1}{\partial p_1} & \frac{1}{f_1} \frac{\partial f_1}{\partial p_2} & \dots \\ \frac{1}{f_2} \frac{\partial f_2}{\partial p_1} & \ddots & \vdots \\ \vdots & \dots & \frac{1}{f_{n_\lambda}} \frac{\partial f_{n_\lambda}}{\partial p_{n_e}} \end{pmatrix} \quad (3.77)$$

und der Sensitivitätsmatrix der Eigenvektoren (siehe auch Abschnitt 2.3.2), bei der die Eigenvektorsensitivitäten nach einem Parameter untereinander angeordnet sind

$$\mathbf{S}_\varphi = \begin{pmatrix} \frac{\partial \boldsymbol{\varphi}_1}{\partial p_1} & \frac{\partial \boldsymbol{\varphi}_1}{\partial p_2} & \dots \\ \frac{\partial \boldsymbol{\varphi}_2}{\partial p_1} & \ddots & \vdots \\ \vdots & \dots & \frac{\partial \boldsymbol{\varphi}_{n_\lambda}}{\partial p_{n_e}} \end{pmatrix}. \quad (3.78)$$

Die Indizes  $n_\lambda$  und  $n_e$  aus den Gl. (3.77) und (3.78) repräsentieren die Gesamtanzahl der betrachteten Moden bzw. die Gesamtanzahl der berücksichtigten Parameter. Die kombinierte Sensitivitätsmatrix für die Eigenfrequenzen und die Eigenvektoren wird dann zu

$$\mathbf{S}_{f\varphi} = \begin{bmatrix} \mathbf{S}_f \\ \mathbf{S}_\varphi \end{bmatrix}. \quad (3.79)$$

Für die sinnvolle Bildung des Residuums ist es erforderlich, dass die einander zugeordneten Eigenvektoren einen positiven MSF haben, also gleich orientiert sind, siehe auch Abschnitt 2.3.3. Wenn die Gl. (3.74)-(3.79) in Gl. (3.73) eingefügt wird, so erhält man das folgende lineare Gleichungssystem mit den entsprechenden Dimensionen:

$$\underbrace{\begin{bmatrix} 1 & \frac{\partial f_1}{\partial p_1} & \frac{1}{f_1} \frac{\partial f_1}{\partial p_2} & \dots \\ f_1 & \frac{\partial \varphi_1}{\partial p_1} & \frac{\partial \varphi_1}{\partial p_2} & \dots \\ 1 & \frac{\partial f_2}{\partial p_1} & \ddots & \vdots \\ f_2 & \frac{\partial \varphi_2}{\partial p_1} & \ddots & \vdots \\ \vdots & \dots & \dots & \dots \\ \frac{\partial \varphi_1}{\partial p_1} & \frac{\partial \varphi_1}{\partial p_2} & \dots & \dots \\ \frac{\partial \varphi_2}{\partial p_1} & \frac{\partial \varphi_2}{\partial p_2} & \dots & \dots \\ \frac{\partial \varphi_1}{\partial p_1} & \frac{\partial \varphi_1}{\partial p_2} & \dots & \dots \\ \vdots & \dots & \dots & \dots \\ \frac{\partial \varphi_{n_\lambda}}{\partial p_1} & \frac{\partial \varphi_{n_\lambda}}{\partial p_2} & \dots & \dots \\ \vdots & \dots & \dots & \dots \end{bmatrix}}_{(n_\lambda + n_\lambda \cdot n) \times n_e} \underbrace{\begin{bmatrix} \Delta p_1 \\ \vdots \\ \Delta p_{n_e} \end{bmatrix}}_{n_e \times 1} = \underbrace{\begin{bmatrix} (r_f)_1 \\ \vdots \\ (r_f)_{n_\lambda} \\ (r_\varphi)_1 \\ \vdots \\ (r_\varphi)_{n_\lambda} \end{bmatrix}}_{(n_\lambda + n_\lambda \cdot n) \times 1} \quad (3.80)$$

wobei  $n$  die Anzahl der Freiheitsgrade eines einzelnen Eigenvektors des Referenzmodells darstellt. Für Systeme mit einer sehr hohen Anzahl an Freiheitsgraden werden nur die Freiheitsgrade der  $m$  Messstellen betrachtet.

#### 3.4.2.2 Lösung des Gleichungssystems

Die Lösung des linearen Gleichungssystems (3.80) nach den Parameteränderungen  $\Delta \mathbf{p}$  erfolgt bei einer Vereinfachung der Gl. (3.68) mit Hilfe der Methode der kleinsten Fehlerquadrate (LS). Dabei werden die Elemente von  $\Delta \mathbf{p}$  als Koeffizienten des linearen Regressionsmodells geschätzt. Diese Schätzung erfolgt durch die Minimierung der Summe der quadrierten Abweichung:

$$J(\Delta \mathbf{p}) = \boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon} = (\mathbf{r} - \mathbf{S} \Delta \mathbf{p})^T (\mathbf{r} - \mathbf{S} \Delta \mathbf{p}). \quad (3.81)$$

Es wird angenommen, dass die Spalten der Matrix  $\mathbf{S}$  linear unabhängig sind, d.h.: die Matrix  $\mathbf{S}$  hat vollen Spaltenrang, bzw. die Matrix  $\mathbf{S}^T \mathbf{S}$  ist positiv definit und damit invertierbar. Unter diesen Annahmen ist das Minimierungsproblem eindeutig lösbar und die geschätzten Parameter ergeben sich zu

$$\Delta \hat{\mathbf{p}} = (\mathbf{S}^T \mathbf{S})^{-1} \mathbf{S}^T \mathbf{r}. \quad (3.82)$$

Die Matrix  $\mathbf{S}^T \mathbf{S}$  aus Gl. (3.82) ist auch als Hessematrix der Zielfunktion  $J(\Delta \mathbf{p})$  bekannt. Um fehlerhafte Parameterschätzungen zu vermeiden, muss die Hessematrix gut konditioniert sein. In der Praxis liegt eine erhebliche Schwierigkeit bei der Lösung schlecht gestellter, inverser Probleme vor, die sich durch eine hohe Empfindlichkeit der LS-Lösung gegenüber kleinen Fehlern in der Sensitivitätsmatrix oder Rauschen im Residuum einstellt [BOHLE 2005]. Das Problem entsteht, wenn Vektoren in der Sensitivitätsmatrix nahezu linear abhängig sind und damit wenigstens ein Singulärwert nahe Null liegt, weswegen die Konditionszahl<sup>1</sup> der Hessematrix sehr groß wird. Diese Matrix hat dann noch vollen Spaltenrang, kann damit formal invertiert und zur LS-Lösung verwendet werden. Allerdings erhöhen sich dadurch die Varianzen der Parameterschätzung stark, so dass der ermittelten Lösung nicht mehr vertraut werden kann. Das Ansteigen der Matrixdimension führt zu einer zusätzlichen Verschlechterung der Konditionierung. Dieses Verhalten kann man bei Sensitivitätsmatrizen beobachten, die aus FE-Modellen mit sehr vielen Freiheitsgraden entstanden sind. Um dennoch zu brauchbaren Lösungen auch bei schlecht gestellten inversen Problemen zu gelangen, können Regularisierungsverfahren eingesetzt werden.

#### 3.4.2.2.1 PARAMETERSCHÄTZUNG MIT HILFE DER TYCHONOV-REGULARISIERUNG

Die TYCHONOV-Regularisierung, auch als *Ridge Regression* bekannt, erfolgt durch die Addition eines erweiterten Strafterms in der Zielfunktion der Gl. (3.81) oder durch die folgende Gestaltung der Gewichtungsmatrizen aus Gl. (3.68):  $\mathbf{W}_p = \delta \mathbf{I}$  und  $\mathbf{W}_\varepsilon = \mathbf{I}$ .

$$J(\Delta \mathbf{p}) = (\mathbf{r} - \mathbf{S}\Delta \mathbf{p})^T (\mathbf{r} - \mathbf{S}\Delta \mathbf{p}) + \delta \Delta \mathbf{p}^T \Delta \mathbf{p}. \quad (3.83)$$

Die Minimierung der Zielfunktion aus Gl. (3.83) führt zur LS-Lösung:

$$\Delta \hat{\mathbf{p}} = (\mathbf{S}^T \mathbf{S} + \delta \mathbf{I})^{-1} \mathbf{S}^T \mathbf{r}, \quad (3.84)$$

wobei der Regularisierungsfaktor  $\delta$  zu der Diagonalen der Hessematrix  $\mathbf{S}^T \mathbf{S}$  addiert wird. Damit lässt sich die Kondition der Hessematrix in Abhängigkeit von  $\delta$  unmittelbar beein-

---

<sup>1</sup> Die Konditionszahl ist definiert als das Verhältnis zwischen dem größten und dem kleinsten Eigenwert der Hessematrix.

flussen. Der Regularisierungsfaktor beeinflusst nur geringfügig die bedeutenden Eigenwerte der Hessematrix. Kleine Eigenwerte werden dagegen auf Werte nahe bei  $\delta$  herabgesetzt.

#### 3.4.2.2.2 PARAMETERSCHÄTZUNG MIT HILFE DER ROBUSTEN REGRESSION

Die gängige LS-Methode liefert für unabhängig normalverteilte Messfehler mit gleicher Varianz und dem Erwartungswert Null die beste Schätzung. Ein großer Nachteil der LS-Methode ist die hohe Empfindlichkeit gegenüber Ausreißern in den gemessenen Daten [BOHLE 2005]. Zur Berücksichtigung dieses Problems wird neben der LS-Regression eine robuste Regression vorgeschlagen.

Das robuste Regressionsverfahren gewichtet die Messfehler anders als die LS-Regression. Dadurch können zum einen Ausreißer als solche eher erkannt werden und zum anderen können gegenüber Ausreißern oder Abweichungen von der Normalverteilung unempfindlichere Parameterschätzungen erzielt werden [BOHLE 2005; FRITZEN und BOHLE 2006; MONTGOMERY *et al.* 2006]. In dieser Arbeit wird zur Berechnung der robusten Regression die Funktion „robustfit.m“ von Matlab verwendet. Hierbei wird eine Klasse robuster *Maximum-Likelihood*-Schätzer (M-Schätzer) definiert, die eine häufig nichtlineare Funktion  $\rho$  nutzen, um den Messfehler  $\varepsilon$  in Abhängigkeit der wahren Lösung  $\Delta\mathbf{p}_w$  zu minimieren:

$$\min_{\Delta\mathbf{p}_w} \sum_i \rho\left(\frac{\varepsilon_i}{\sigma_r}\right) = \min_{\Delta\mathbf{p}_w} \sum_i \rho\left(\frac{\mathbf{r}_i - \mathbf{s}_i \cdot \Delta\mathbf{p}_w}{\sigma_r}\right). \quad (3.85)$$

Dabei ist  $\mathbf{s}_i$  eine Zeile der Sensitivitätsmatrix ( $i = 1, \dots, n_\lambda + n_\lambda \cdot n$ ),  $\mathbf{r}_i$  das entsprechende gemessene Residuum und  $\sigma_r$  ein Skalierungsfaktor, der den M-Schätzer trotz der möglichen Nichtlinearität der Gewichtungsfunktion skalierungsunabhängig gestaltet. Ein gängiger, in der Literatur vorgeschlagener Wert für  $\sigma_r$  ist [MONTGOMERY *et al.* 2006]

$$\sigma_r = \frac{\text{median}|\varepsilon_i - \text{median}(\varepsilon_i)|}{0,6745}. \quad (3.86)$$

Zur Lösung der Minimierungsaufgabe werden die partiellen Ableitungen von Gl. (3.85) nach  $j = 1, \dots, n_e$  Parametern  $(\Delta\mathbf{p}_w)_j$  gebildet und gleich Null gesetzt. Dadurch entsteht ein lineares Gleichungssystem mit  $n_e$  Gleichungen:

$$\sum_i s_{ij} \psi_j \left( \frac{r_i - s_i \Delta \mathbf{p}_w}{\sigma_r} \right) = 0. \quad (3.87)$$

Dabei sind  $\psi_j(\boldsymbol{\varepsilon}_i) = \partial \rho(\boldsymbol{\varepsilon}_i) / \partial (\Delta \mathbf{p}_w)_j$  die partiellen Ableitungen von  $\rho$  nach den Schadensparametern als Funktion von  $\boldsymbol{\varepsilon}_i$  und  $s_{ij}$ . Da die Funktion  $\psi$  in der Regel nichtlinear ist, muss das Gleichungssystem (3.87) mit iterativen Verfahren gelöst werden. Die *Iteratively Reweighted Least Squares* -Methode wird in diesen Kontext häufig angewendet. Dabei wird die Gl. (3.87) zunächst wie folgt erweitert [MONTGOMERY *et al.* 2006]:

$$\sum_i s_{ij} \psi_j \left( \frac{r_i - s_i \Delta \mathbf{p}_w}{\sigma_r} \right) \frac{\sigma_r}{r_i - s_i \Delta \mathbf{p}_w} \frac{r_i - s_i \Delta \mathbf{p}_w}{\sigma_r} = 0. \quad (3.88)$$

In Gl. (3.88) führt man Gewichtungsfaktoren  $w_i$  ein, so dass man nach Kürzen aller Terme

$$\sum_i s_{ij} w_i (r_i - s_i \Delta \mathbf{p}_w) = 0 \quad (3.89)$$

erhält. Dabei lässt sich durch eine Initialschätzung  $\Delta \hat{\mathbf{p}}_0$  die Gewichtung  $(w_i)_0$  der diagonalen Gewichtungsmatrix  $\mathbf{W}$  nach der Vorschrift

$$(w_i)_0 = \begin{cases} \frac{\psi_j \sigma_r}{(r_i - s_i \Delta \hat{\mathbf{p}}_0)} & \text{für } (r_i - s_i \Delta \hat{\mathbf{p}}_0) \neq 0 \\ 1 & \text{für } r_i - s_i \Delta \hat{\mathbf{p}}_0 = 0 \text{ und } (w_i)_0 > 1 \end{cases}. \quad (3.90)$$

bestimmen. Mit dieser Berechnungsvorschrift werden in einem iterativen Prozess die Gewichtungsfaktoren und damit Gl. (3.89) optimiert. In jedem iterativen Schritt wird eine neue Parameterlösung mit Hilfe einer gewichteten LS bestimmt und damit wiederum die Gewichtungsfaktoren modifiziert bis das Verfahren konvergiert. Man erhält den Einschnitt-Schätzer durch Umformen der Gl. (3.89) in Matrixschreibweise:

$$\Delta \hat{\mathbf{p}} = (\mathbf{S}^T \mathbf{W} \mathbf{S})^{-1} \mathbf{S}^T \mathbf{W} \mathbf{r}. \quad (3.91)$$

Wenn alle Gewichtungsfaktoren in der Gewichtungsmatrix  $\mathbf{W}$  immer gleich Eins oder konstant sind, wird die Gl. (3.91) in die LS-Regression Form überführt, siehe Gl. (3.82). Man erkennt, dass das Verfahren erst dann robust wird, wenn die sog. Einflussfunktion  $\psi$  so gestaltet ist, dass die Residuen mit besonders hohen Messfehlern entsprechend niedrig gewichtet

werden. [BOHLE 2005] schlägt zwei verschiedenen Funktionstypen für diesen Zweck vor: die *Logistic*-Einflussfunktion, die asymptotisch gegen Null geht, und die *Bisquare*-Einflussfunktion, die ab einer bestimmten Schranke die Gewichtung auf Null reduziert (vgl. Abbildung 3.32, links).

Die Auswirkung der robusten Regression auf Daten mit Ausreißern, wird beispielhaft in Abbildung 3.32, rechts, dargestellt. Hier wird deutlich, dass das einfache LS-Verfahren die Ausreißer zur Berechnung der Regressionsgerade als gleichwertige Datenpunkte einbindet. Im Gegensatz dazu wird bei einer Gewichtung der Daten mit einer *Logistic*-Einflussfunktion der Einfluss der Ausreißer auf die Regressionsgerade minimiert.

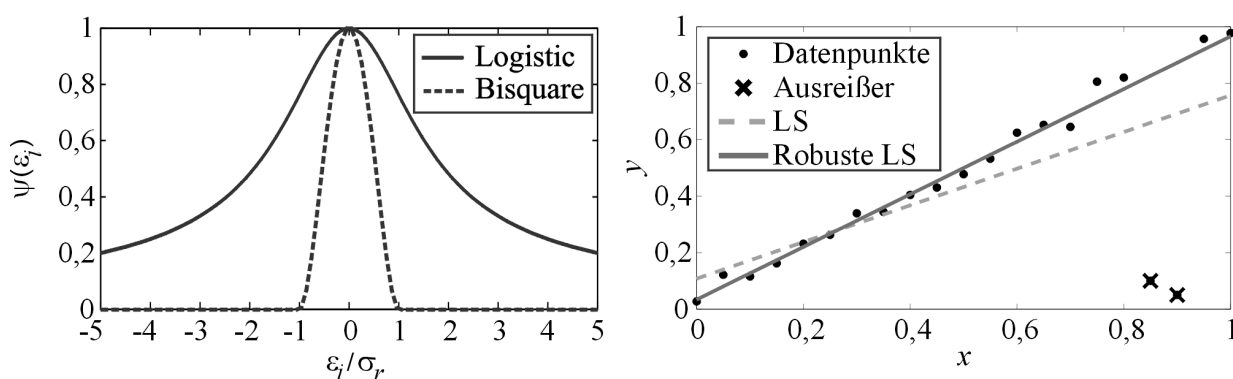


Abbildung 3.32: *Logistic*- und *Bisquare*-Einflussfunktion (links); Beispielhafte Regression mit LS und robuster LS (rechts)

#### 3.4.2.2.3 PARAMETERSCHÄTZUNG MIT ROBUSTER RIDGE-REGRESSION

In der Praxis liegen oft beide angesprochene Probleme bei der Parameterschätzung mit LS vor. Diese werden einerseits durch die Gestaltung der Sensitivitätsmatrix und andererseits durch Messungenauigkeiten verursacht. Das robuste Regressionsverfahren führt ohne weitere Maßnahmen durch vorhandene Multikollinearität zu stark schwankenden Schätzergebnissen. Folglich ist die Schätzung der Schadensparameter oft instabil, wenn die Sensitivitätsmatrix schlecht gestellt ist [BOHLE 2005]. Deshalb werden robuste Regressionsverfahren kombiniert mit Regularisierungsverfahren angewendet, so dass gleichzeitig das „Ausreißerproblem“ als auch das schlecht gestellte Problem bei der Lösung des Gleichungssystems behoben wird. Um die bereits vorgestellte Ridge-Regression für die robuste Regression zu verwenden, wird Gl. (3.84) nach dem Vorschlag von [HOGG 1979] und [MONTGOMERY *et al.* 2006] wie folgt umgeformt:

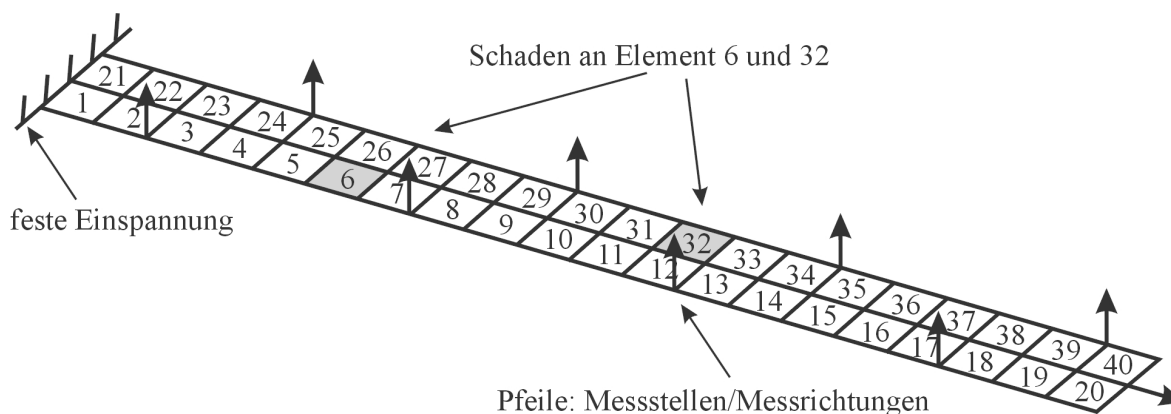
$$\begin{pmatrix} \mathbf{S} \\ \sqrt{\delta \mathbf{I}} \end{pmatrix} \Delta \mathbf{p} = \begin{pmatrix} \mathbf{r} \\ \mathbf{0} \end{pmatrix}. \quad (3.92)$$

### 3.4.2.3 Parameter-Vorselektion

Schäden treten in der Regel lokal begrenzt an Orten, die *a priori* nicht bekannt sind, auf. Geht man davon aus, dass jedes finite Element eine potentielle Schadensstelle darstellt, so erhält man gerade bei komplexen Strukturen, wie z.B. OWEAs, eine hohe Anzahl unbekannter Parameter  $\Delta \mathbf{p}$ . Dies führt oft zu einer hohen Multikollinearität der Sensitivitätsmatrix und verursacht das obengenannte Problem der schlechten Konditionierung. Ausreißer, aber auch geringfügige Fehler in den Messdaten, führen zu einer hohen Varianz der Parameterschätzung und können damit die Ergebnisse der Lokalisation stark verfälschen.

Im Folgenden werden zwei Strategien zur Reduktion der Varianz in der Parameterschätzung vorgestellt. In diesen Kontext soll der hohen Dimensionalität des Parameterraums eine besondere Aufmerksamkeit gewidmet werden. Die Dimension des Parameterraums muss so reduziert werden, dass der reduzierte Raum ausschließlich die dominierenden Parameter im Bereich des Schadens beinhaltet.

**Simulationsbeispiel 2:** Zur Verdeutlichung der in den nächsten Abschnitten vorgestellten Methoden zur Parameterraumselektion wird das Simulationsmodell aus Abbildung 3.33 verwendet. Dabei handelt es sich um einen einseitig fest eingespannten Balken aus Schalenelementen dessen geometrische Abmessungen und Materialeigenschaften für die bevorstehende Betrachtung eine untergeordnete Rolle spielen. Das FE-Modell besteht aus 40 vierknotigen Schalenelementen mit insgesamt 378 Freiheitsgraden. Zwei gleichzeitige Schäden werden durch eine Steifigkeitsreduktion der Elemente 6 und 32 um 20% simuliert. Die Pfeile in Abbildung 3.33 stellen die „Messrichtungen“ der simulierten uniaxialen Sensoren an den entsprechenden Stellen auf der Struktur dar. Die Sensitivitätsmatrix und Residuen werden mit den ersten vier Biegemoden und der ersten Torsionsmode aufgebaut.



**Abbildung 3.33: Einseitig fest eingespanntes Simulationsmodell mit „Messrichtungen“ und simulierten Schäden an den Elementen 6 und 32**

### 3.4.2.3.1 VORSELEKTION DER PARAMETER MIT HILFE DES BOOTSTRAPVERFAHRENS

Das erste Verfahren, entwickelt von [EFRON und TIBSHIRANI 1993], basiert auf der *Bootstrap*-Statistik. Diese schätzt die Bedeutsamkeit der einzelnen Parameter für die Lösung des linearen Gleichungssystems. Für eine Parameterselktion mit Hilfe des *Bootstrap*-Verfahrens wird das in Gl. (3.80) gebildete Gleichungssystem durch eine gleichwahrscheinliche Zufallsauswahl z.B.  $n_B$  mal neu zusammengestellt. Durch  $n_B$ -fache Lösung der  $n_B$  neu angeordneten Gleichungssysteme erhält man  $n_B$  Schätzungen für jeden der  $n_e$  Schadensparameter:

$$\Delta \hat{\mathbf{p}}_B = \begin{bmatrix} \Delta \hat{p}_{1,1} & \cdots & \Delta \hat{p}_{1,n_B} \\ \vdots & \ddots & \vdots \\ \Delta \hat{p}_{n_e,1} & \cdots & \Delta \hat{p}_{n_e,n_B} \end{bmatrix}. \quad (3.93)$$

Die gewünschten statistischen Eigenschaften der geschätzten Schadensparameter kann man durch Analysen der Matrix  $\Delta \hat{\mathbf{p}}_B$  aus Gl. (3.93) erhalten. Die Mittelwerte  $\Delta \bar{\mathbf{p}}_B$  und die Standardabweichungen  $\sigma(\Delta \mathbf{p}_B)$  der Parameterschätzungen werden zur Bildung der Vertrauensintervalle nach der *Bootstrap-t*-Methode genutzt [EFRON und TIBSHIRANI 1993]. Dazu wird zuerst die Prüfgröße


$$T_B = \frac{(\Delta \mathbf{p}_{B,j} - \Delta \bar{\mathbf{p}}_B)}{\sigma(\Delta \mathbf{p}_B)} \quad (3.94)$$

ermittelt, die annähernd *t*-verteilt ist. Die Vertrauensintervalle erhält man durch die Bestimmung der  $\alpha/2$ -Perzentile  $T_{B,\alpha/2}$  und  $T_{B,1-\alpha/2}$ . Die Prüfgröße der Verteilung ergibt sich somit zu:



$$\Delta\bar{p}_B - T_{B,\alpha/2} \cdot \sigma(\Delta p_B) \leq \Delta\bar{p}_B \leq \Delta\bar{p}_B + T_{B,1-\alpha/2} \cdot \sigma(\Delta p_B). \quad (3.95)$$

Zur Bildung der Vertrauensintervalle soll  $n_B > 1000$  sein, damit die Extremen der geschätzten Verteilungsfunktion  $T_B$  ausreichend bekannt sind. Abbildung 3.34, links, stellt das Histogramm des Schadensparameters 6 (aus Simulationsbeispiel 2) nach 1000 *Bootstrap*-Abläufen dar. Der Schätzwert ist annähernd normalverteilt mit  $\Delta\bar{p}_{B,6} = 17,04\%$  und  $\sigma(\Delta p_{B,6}) = 2,01\%$ . Bei der Vorselektion der Parameter sollen nur diejenigen Parameter ausgewählt werden, die sich signifikant von Null unterscheiden und deren Standardfehler gering sind, also diejenigen mit stabiler und signifikanter Vorhersagekraft.



**Abbildung 3.34: Histogramm des Schädigungsparameter für Element 6 nach 1000 Bootstrapabläufen (links); Vorselektion der Parameter (rechts)**

Eine mögliche Auswahl der signifikanten Parameter kann durch die Einführung einer frei definierbaren Obergrenze  $\varepsilon_{\Delta p_{th}}$  erreicht werden [BOHLE 2005]. Dadurch werden Parameter mit relativ geringen Werten aus dem Gleichungssystem entfernt:

$$\Delta p_j = 0, \quad \text{falls} \quad \Delta \hat{p}_j \leq \varepsilon_{\Delta p_{th}}. \quad (3.96)$$

Abbildung 3.34 (rechts) zeigt die Mittelwerte und Standardabweichungen aller 40 Schadensparameter der Schalenelemente. Nach dem Einsatz des Bootstrapverfahrens werden nur die Parameter Nr. 6, 32, 33, 5 und 7 als signifikant eingeschätzt. Alle weiteren Parameter die unterhalb des Schwellenwertes  $\varepsilon_{\Delta p_{th}} = 1\%$  liegen, werden somit herausgefiltert.

### 3.4.2.3.2 PARAMETERSELEKTION MIT HILFE DER SCHRITTWEISEN REGRESSION

Eine weitere Reduktion des verfügbaren Datensatzes an potentiellen „Schadenkandidaten“ auf den tatsächlich erforderlichen Umfang lässt sich mit Hilfe eines Verfahrens zur schrittweisen Parameterselektion erreichen. In dieser Arbeit wird dazu die Matlab-Funktion „stepwisefit.m“ verwendet [DRAPER und SMITH 1998].

Im Allgemeinen lassen sich die Selektionsverfahren in drei Gruppen einteilen: Vorwärtsselektion, Rückwärtselimination und Schrittweise-Regression. Die schrittweise Regression kombiniert die ersten beiden Selektionsverfahren und basiert auf einem statistischen Signifikanztest für die jeweiligen Schadensparameter mit der Nullhypothese:

$$H_0 : \Delta p_j = 0, \quad (\text{Schadensparameter ist nicht signifikant}) \quad (3.97)$$

bzw.:

$$H_1 : \Delta p_j \neq 0, \quad (\text{Schadensparameter ist signifikant}) \quad (3.98)$$

Die Test-Statistik der Hypothese ist

$$t_{0,j} = \frac{\Delta \hat{p}_j}{\sigma(\Delta \hat{p}_j)}. \quad (3.99)$$

Diese ist annähernd  $t$ -verteilt mit dem Standardfehler  $\sigma(\Delta \hat{p}_j)$ , siehe [MONTGOMERY *et al.* 2006]. Die Signifikanztests lassen sich über die sogenannten  $P$ -Werte durchführen. Der  $P$ -Wert ist definiert als die Wahrscheinlichkeit unter der  $H_0$ -Hypothese den beobachteten Prüfgrößenwert  $t_{0,j}$  zu erhalten. Ist der  $P$ -Wert kleiner als das vorgegebene Signifikanzniveau, so wird  $H_0$  abgelehnt. Ansonsten behält man  $H_0$  bei. Da die  $P$ -Werte Wahrscheinlichkeiten sind, nehmen sie stets Werte  $0 \leq P \leq 1$  an [FAHRMEIR *et al.* 2007].

Der Algorithmus besteht hauptsächlich aus zwei Prozeduren: Vorwärtsselektion und Rückwärtselimination. Für die Vorwärtsselektion wird ein entsprechendes Signifikanzniveau  $P_{ein}$  und für die Rückwärtselimination ein entsprechendes Signifikanzniveau  $P_{aus}$  vorgegeben, siehe auch [DRAPER und SMITH 1998].

Die Schritte des Algorithmus sind:

1. Initialisierung: Der Prozess beginnt ohne Parameter im Gleichungssystem.
2. Vorwärtsselektion: Sollten die nicht im Gleichungssystem enthaltenen Parameter kleinere  $P$ -Werte als  $P_{ein}$  haben<sup>1</sup>, wird der Parameter in das Gleichungssystem eingefügt, der den kleinsten  $P$ -Wert besitzt. Dieser Schritt wiederholt sich für alle signifikanten Parameter. Andernfalls geht es weiter zu Schritt 3.
3. Rückwärtselimination: Sollten die im Gleichungssystem enthaltenen Parameter größere  $P$ -Werte als  $P_{aus}$  haben<sup>2</sup>, wird der Parameter aus dem Gleichungssystem eliminiert, welcher den größten  $P$ -Wert hat. Der Algorithmus schaltet zu Schritt 2 zurück. Andernfalls endet der Prozess.

Für die Auswahl von  $P_{ein}$  und  $P_{aus}$  soll gelten  $P_{ein} < P_{aus}$ , ansonsten könnte der Selektionsprozess in einen unendlichen Zyklus geraten.

Um diesen Vorgang zu verdeutlichen, wird die schrittweise Regression für das Simulationsbeispiel 2 am Anfang des Abschnitts 3.4.2.3 durchgeführt. Die zunächst verfügbaren Parameter nach dem Bootstrapverfahren sind Nr. 6, 32, 33, 5 und 7.

Die Tabelle 3.1 beschreibt den kompletten Selektionsprozess der schrittweisen Regression für das obengenannte Beispiel. Durch Überprüfungen der  $P$ -Werte lassen sich die Schadensparameter Nr. 5, 6 und 32 nach drei Iterationen in das Gleichungssystem hineinnehmen. Iteration drei zeigt aber, dass Parameter 5 wahrscheinlich nicht signifikant ist, was zu einer Entfernung dieses Parameters aus dem Gleichungssystem der signifikanten Parameter führt. Die vierte Iteration zeigt eindeutig, dass die Parameter 6 und 32 signifikant und die anderen nicht signifikant sind.

---

<sup>1</sup> Das bedeutet, dass es unter  $H_0$  sehr unwahrscheinlich ist, den Prüfgrößenwert zu beobachten. Dies spricht dafür, dass  $H_0$  eher falsch ist und die entsprechenden Parameter eigentlich signifikant sind.

<sup>2</sup> Das bedeutet, dass es sehr unwahrscheinlich ist, dass die Nullhypothese  $H_0$  abgelehnt wird und die Parameter eigentlich nicht signifikant sind.

Iteration	Param. in GS <sup>1</sup>	P-Werte	Param. außer GS <sup>2</sup>	P-Werte
0	/	/	6	1,49E-13
	/	/	32	7,12E-14
	/	/	33	3,18E-9
	/	/	5	<b>8,43E-17</b>
	/	/	7	0,0027
1	/	/	6	0,62
	/	/	32	<b>0,075</b>
	/	/	33	0,19
	5	8,43E-17	/	/
	/	/	7	0,88
2	/	/	6	<b>0,025</b>
	32	0,075	/	/
	/	/	33	0,31
	5	5,89E-5	/	/
	/	/	7	0,14
3	6	0,025	/	/
	32	0,005	/	/
	/	/	33	0,95
	5	<b>0,78</b>	/	/
	/	/	7	0,32
4	6	4,12E-6	/	/
	32	1,97E-6	/	/
	/	/	33	0,93
	/	/	5	0,78
	/	/	7	0,504

**Tabelle 3.1: Schrittweise-Regression für das Simulationsbeispiel 2, mit den zunächst verfügbaren Parametern Nr. 6, 32, 33, 5 und 7,  $P_{ein} = 0,1$  und  $P_{aus} = 0,2$**

In der Regel können die Vorwärtsselektion und die Rückwärtselimination auch individuell durchgeführt werden um ein reduziertes Gleichungssystem zu erhalten. Bei der ausschließlichen Vorwärtsselektion beginnt die Berechnung ohne Parameter im Gleichungssystem. Bei der ausschließlichen Rückwärtselimination beginnt die Berechnung mit allen verfügbaren Parametern im Gleichungssystem. Tabelle 3.2 zeigt das endgültige Gleichungssystem mit verschiedenen Selektionsverfahren für das Simulationsbeispiel 2. Die Vorwärtsselektion beteiligt den Parameter Nr. 5 am Gleichungssystem, der jedoch nach dem Eintritt des Parameters Nr. 6 nicht mehr benötigt wird. Dies ist ein generelles Problem bei der reinen Vorwärtsselektion: sobald ein Parameter im Gleichungssystem aufgenommen ist, lässt sich dieser nicht mehr aus dem System entfernen, auch wenn er in den nachfolgenden Schritten

<sup>1</sup> Parameter innerhalb des Gleichungssystems.

<sup>2</sup> Parameter außerhalb des Gleichungssystems.

nur noch einen unwesentlichen Einfluss auf die Gleichungslösung hat. Umgekehrt bei der Rückwärtsselektion, wenn ein Parameter aus dem System entfernt wurde, kann dieser später nicht wieder aufgenommen werden.

Typ	Parameter im endgültigen Gleichungssystem
Vorwärtsselektion	6, 32, und 5
Rückwärtselimination	6 und 32
Schrittweise-Regression	6 und 32

**Tabelle 3.2: Lösung des Gleichungssystems mit verschiedenen Selektionsverfahren**

Die Lösungen der Gleichungssysteme sind bedingt durch Anwendung der unterschiedlichen Selektionsverfahren nicht identisch. Die Ergebnisse sind von der Reihenfolge und der Korrelation der Ein- und Austrittsparameter abhängig. Abbildung 3.35, links, stellt die *Root Mean Squared Error* (RMSE) Werte für die drei Selektionsverfahren und für jeden entsprechenden Schritt dar. Der RMSE-Wert kann hier als Indikator der „Schätzungsqualität“ interpretiert werden. Dieser ist wie folgt definiert [DRAPER und SMITH 1998]:

$$RMSE = \sqrt{\frac{(\mathbf{r} - \mathbf{S}\Delta\hat{\mathbf{p}})^T (\mathbf{r} - \mathbf{S}\Delta\hat{\mathbf{p}})}{(n_\lambda + n_\lambda \cdot n) - n_e - 1}}. \quad (3.100)$$

wobei  $n_\lambda + n_\lambda \cdot n$  die Anzahl der Gleichungen und  $n_e$  die Anzahl der Parameter ist. Die Rückwärtselimination und die Schrittweise-Regression erreichen für dieses Beispiel das globale Optimum in drei bzw. vier Rechenschritten. Die Vorwärtsselektion ohne Rückwärtselimination endet in Schritt 3 und hat keine Chance mehr, das Modell weiter zu verbessern, da der wenig signifikante Parameter 5 nicht aus dem System eliminiert werden kann (vgl. auch Tabelle 3.1 und Tabelle 3.2).

Das Schadenslokalisierungsergebnis für das gewählte Beispiel zeigt schließlich unter Anwendung der LS mit einem Regularisierungsfaktor  $\delta = 10^{-6}$  eine Reduktion der Steifigkeit um 18,9% und 18,4% für das Element 6 bzw. 32 (simuliert wurde 20% Steifigkeitsreduktion für beide Elemente). Sollten größere Schäden entstehen, dann ergeben sich Linearisierungsfehler bei der Approximation des Residuums mit der Eigenwert- und Eigenvektorsensitivitätsmatrix. In diesen Fall werden die Schadensorte immer noch richtig identifiziert aber das Schadensausmaß wird fehlerhaft interpretiert. Dieses Verhalten ist in Abbildung 3.35, rechts, für unterschiedliche simulierte und identifizierte Schadensausmaße dargestellt. Hier sieht

man, dass nur die Ausmaße „kleiner“ Schäden am Element 6 durch eine lineare Approximation korrekt identifiziert werden können.




Abbildung 3.35: RMSE für verschiedenen Selektionsverfahren (links), Einfluss der Linearisierung auf das identifizierte Schadensausmaß am Element 6 (rechts)

#### 3.4.2.3.3 PARAMETERSCHÄTZUNG MIT HILFE VON MODELLOPTIMIERUNGSTECHNIKEN

Die Schätzung des Schadensausmaßes erfolgt mit Hilfe von Optimierungsverfahren. Dabei wird das Modell (Index  $mod$ ), anhand der schon bei der Schadenslokalisierung identifizierten Parameter, in mehreren Schritte an die Modaldaten angepasst. Der Optimierungsvorgang verändert die ausgewählten Parameter iterativ, bis die Zielfunktion

$$J = \frac{1}{n_\lambda} \sum_{i=1}^{n_\lambda} (\varepsilon_e)_i \frac{|(f_g)_i - (f_{mod})_i|}{(f_{mod})_i} + \frac{1}{\varepsilon_e} \sum_{i=1}^{n_\lambda} [1 - (\varepsilon_e)_i MAC_i] \quad (3.101)$$

mit

$$\varepsilon_e = \sum_{i=1}^{n_\lambda} (\varepsilon_e)_i \quad (3.102)$$

minimiert wird [DDS 2008].  $(\varepsilon_e)_i$  aus Gl. (3.101) bezeichnet die erwarteten Modellabweichungen von den entsprechenden Modaldaten.

Als Model-*Updating*-Verfahren [DASCOTTE *et al.* 1995] bietet der hier angewendete LS-Ansatz eine gleichzeitige Gewichtung der Parameteränderung und des Residuums an. Dabei werden die Abweichungen zwischen den Modaldaten des FE-Modells und den gemessenen Modaldaten  $\mathbf{r}_m$

$$\boldsymbol{\varepsilon}_m = \mathbf{r}_m^T \mathbf{W}_r \mathbf{r}_m + \Delta \mathbf{p}^T \mathbf{W}_p \Delta \mathbf{p} \quad (3.103)$$

berechnet und der Fehler  $\partial \boldsymbol{\varepsilon}_m / \partial p_j$  minimiert.  $\mathbf{W}_r$  und  $\mathbf{W}_p$  sind Gewichtungsmatrizen ( $\mathbf{W}_r = E[\mathbf{r}_m \mathbf{r}_m^T]$  und  $\mathbf{W}_p = E[\Delta \mathbf{p} \Delta \mathbf{p}^T]$ ) für das Residuum bzw. für die Parameteränderungen. Die Minimierung erfolgt, indem der Vektor mit den *update*-Parameter  $\mathbf{p}_u$  für die nächste Iteration aus den Parametern des aktuellen Rechenschrittes  $\mathbf{p}_0$

$$\mathbf{p}_u = \mathbf{p}_0 + \mathbf{G}(-\mathbf{r}_m) \quad (3.104)$$

und aus den mit der Verstärkungsmatrix  $\mathbf{G}$  gewichteten Residuen berechnet wird

$$\mathbf{G} = \mathbf{W}_p^{-1} \mathbf{S}^T (\mathbf{W}_r^{-1} + \mathbf{S} \mathbf{W}_p^{-1} \mathbf{S}^T)^{-1}. \quad (3.105)$$

Die Optimierungsschleife wird abgebrochen, wenn die Zielfunktion  $J$  kleiner als ein voreingestellter Wert ist oder wenn die im Voraus angegebene maximale Iterationszahl erreicht ist.

Die modellgestützte Schadenslokalisierung führt Änderungen in den gemessenen Modaldaten auf Veränderungen der Modellparameter zurück. Die Methode kann für lineare und zeitinvariante Systeme angewendet werden. Um gleichzeitig dynamische Änderungen der Struktur, verursacht durch veränderliche EOCs, zu berücksichtigen, müssen die experimentellen Modaldaten unter gleichen Bedingungen aufgenommen und die auf die Struktur einwirkenden EOCs bei dem Modellaufbau einbezogen werden.

### 3.5 SENSORFEHLERIDENTIFIKATION

Eine Schadensidentifikation kann nur dann zuverlässig erfolgen, wenn die auf der Struktur applizierten Sensoren korrekt funktionieren. Besonders bei Schadensidentifikationsmethoden, die Korrelationen mehrerer Sensoren gleichzeitig betrachten, wie es auch in dieser Arbeit der Fall ist, siehe Gl. (3.14), (3.13) und (2.43), hat ein Sensorschaden eine ähnliche Wirkung auf die Schädigungsindikatoren, wie ein tatsächlicher Strukturschaden. Dadurch kann eine Struktur als geschädigt eingestuft werden, obwohl sie es eigentlich nicht ist.

Sensoren eingesetzt an OWEAs, sind besonders rauen Bedingungen ausgesetzt und ihre Lebensdauer liegt in den meisten Fällen unter der Lebenserwartung der Anlage von 20 Jahren. Aus diesen Gründen wird in dieser Arbeit auch eine Fernüberwachung der Sensoren mit geeigneten Algorithmen angestrebt, die zur Steigerung der Zuverlässigkeit der Schadensidentifikationsergebnisse führen soll.

Nach [DUNIA *et al.* 1996] und [KULLAA 2006b] werden Sensorfehler wie folgt klassifiziert: Bias, Totalausfall, Drift und Präzisionsverminderung (eng. *precision degradation*). Andere Autoren [KERSCHEN *et al.* 2004] haben auch Hardwarefehler, wie z.B. Veränderungen in den Verstärkungsfaktoren der gemessenen Signale betrachtet. Wie bei der Schadensdetektion existieren auch hier mehrere Stufen der Sensorfehlerdiagnose [KRAEMER und FRITZEN 2008b]:

- Niveau 1: Sensorfehlerdetektion.
- Niveau 2: Isolation des fehlerhaften Sensors.
- Niveau 3: Signalrekonstruktion.

Im Folgenden werden einige Methoden, die sich zu einer autonomen<sup>1</sup> Sensorfehleridentifikation in linearen Systemen ohne direkte Kenntnisse über die Systemeingangssignale eignen, sowie deren Eigenschaften erläutert. Hierbei handelt sich zum einen um bewährte Verfahren aus der Literatur, die sich zur Überwachung der Sensoren von Windenergieanlagen eignen und zum anderen um zwei Verfahren zur Sensorfehlerdetektion, -isolation und Signalrekonstruktion, welche im Rahmen dieser Arbeit für Beschleunigungssignale entwickelt worden sind: Die *Mutual Information* wird zur Sensorfehlerdetektion und -isolation und ein auf dem Kalman-Filter basiertes Verfahren wird zur Rekonstruktion fehlerhafter Signale verwendet.

### 3.5.1 Beschreibung bisher existierender Methoden

#### *Hauptkomponentenanalyse (PCA)*

Die Strategie zur Entdeckung der Sensorfehler basiert auf der Theorie aus Abschnitt 2.4.2. und wurde u.a. in [KERSCHEN *et al.* 2005] zur Sensorfehleridentifikation genutzt. Für die Sensorfehlerdetektion wird zuerst ein Unterraum (Hauptkomponenten)  $U$  für jeden der  $N_D$  Datensätze berechnet, siehe Gl. (2.104). Der Unterraum eines Datensatzes ohne Sensorfehler wird als  $U_{ref}$  bezeichnet. Der Sensorfehlerindikator ( $SFI^{PCA}$ ) lässt sich als Vergleich zwischen den Unterräumen des Referenzdatensatzes und des aktuellen Datensatzes  $n_m$  ermitteln:

$$SFI_{n_m}^{PCA} = \beta_U = \arccos(U_{ref}^T \cdot U_{n_m}), \quad 1 < n_m < N_D. \quad (3.106)$$

$\beta_U = 0$  kennzeichnet eine perfekte lineare Abhängigkeit zwischen den betrachteten Unterräumen. Ist  $\beta_U = \pm\pi/2$ , dann sind die Unterräume orthogonal zueinander und damit

---

<sup>1</sup> Es sind keine visuellen Inspektionen der Signale notwendig



die dazugehörigen Signale linear unabhängig. Die Veränderung der Abhängigkeit zwischen den Signalen kann somit auf einen Sensorschaden zurückgeführt werden. Die Gewissheit, dass ein Sensorfehler vorliegt und die Isolation des beschädigten Sensors erreicht man, indem jeder Sensor in sukzessiver Reihenfolge aus der Berechnung der Gl. (3.106) herausgenommen wird. Wenn gerade der beschädigte Sensor nicht an der Berechnung teilnimmt, wird sich der Winkel zwischen den Unterräumen nicht wesentlich verändern. Dieser Ansatz wird im weiteren Verlauf der Arbeit als „Prinzip des fehlenden Sensors“ bezeichnet.

Die Rekonstruktion des fehlenden Signals wird mit Hilfe des reduzierten Referenzuntertraumes nach Gl. (2.105) durchgeführt. Diese Gleichung ermöglicht die optimale Rekonstruktion aller Signale (dadurch auch des Signals des beschädigten Sensors) durch die Minimierung des Residuums zwischen den gemessenen und den geschätzten Signalen:

$$\varepsilon = \|\mathbf{y} - \hat{\mathbf{y}}\|^2.$$

Ein Autoassoziatives Neuronales Netz (AANN), das eine nicht-lineare Hauptkomponenten-Analyse darstellt, wurde bereits zur Sensorfehleridentifikation verwendet [WORDEN 2003]. Die Methode basiert auf der Beschreibung in Abschnitt 2.4.2. Für diese Anwendung lassen sich die gemessenen Zeitdaten wie in Abbildung 2.4 dargestellt in das Netz einspeisen. Das AANN muss in der Lernphase mit Messdaten von einem gut funktionierenden Messsystem trainiert werden. In der Online-Phase rekonstruiert das Netz dann die Messdaten. Sollten bei einem Messkanal große Abweichungen zwischen den gemessenen und den geschätzten Daten entstehen, wird der zuständige Sensor als fehlerhaft eingestuft. Die Rekonstruktion durch das AANN gilt als das zu erwartende Signal.

Die Vorteile dieser Methode liegen in der Möglichkeit nicht-lineare Korrelationen zwischen den Zeitdaten zu identifizieren und zu berücksichtigen. Allerdings ist sie aus Rechenzeitgründen nur für Systeme mit geringer Anzahl an Sensoren und gemessenen Datenpunkten geeignet. Oft wird die Methode nur auf Merkmale der Zeitdaten verwendet, wie z.B. zur Überwachung von Driftfehlern oder unterschiedlichen Größen z.B. in der Nuklearanlagenüberwachung [HINES und UHRIG 1998].

#### *Methoden der Prozessüberwachung*

[KULLAA 2006b; KULLAA 2007] nutzt für die Sensorfehlerdetektion Methoden zur Prozessüberwachung wie z.B. Überwachung der Prozessstandardabweichung (eng. *s-chart*) und Hotelling's  $T^2$ -Statistik (statistisches Maß eines multivariaten Abstands jeder Beobachtung zu dem Datenzentrum, siehe [MONTGOMERY 1997]).

Besonders der  $T^2$  *Control Chart* wird angewendet zur Kontrolle des gesamten Sensornetzwerkes. Dieses Prozessüberwachungsverfahren ist wie folgt definiert:

$$T_{n_m}^2 = n_t (\bar{\mathbf{y}}_{n_m}^T \boldsymbol{\Sigma}_{n_m}^{-1} \bar{\mathbf{y}}_{n_m}), \quad 1 < n_m < N_D. \quad (3.107)$$

Dabei ist  $n_t$  die Anzahl der Datenpunkte pro Sensor und Datensatz,  $\bar{\mathbf{y}}$  der mittelwertfreie multivariate gemessene Datensatz.  $\boldsymbol{\Sigma}$  ist Kovarianzmatrix des entsprechenden Datensatzes. Der Vorteil der Methode liegt in den günstigen Rechenzeiten. Da sich die statistischen Signaleigenschaften mit den EOCs ändern, ist die Methode jedoch nicht zur Überwachung von Sensorsystemen geeignet, die veränderlichen Umgebungseinflüssen ausgesetzt sind.

#### *Missing Data Analyse (MD)*

Die Strategie zur Entdeckung von Sensorfehlern basiert auf der gleichen Theorie beschrieben durch die Gl.(3.8)-(3.10), siehe auch [KULLAA 2006b; KULLAA 2007]. Der Unterschied besteht darin, dass hier direkt die gemessenen Zeitreihen  $\mathbf{y}$  und nicht die extrahierten Merkmale  $\boldsymbol{\theta}$  verwendet werden.

Zur Isolation eines fehlerhaften Sensors in einem Datensatz  $n_m$  wird der Effektivwert  $RMS(\boldsymbol{\varepsilon}_{n_m})$  der Residuen  $\boldsymbol{\varepsilon} = \mathbf{y} - \hat{\mathbf{y}}$  auf den Effektivwert der Referenzresiduen  $RMS(\boldsymbol{\varepsilon}_{ref})$  (kein Sensor ist beschädigt) normiert:

$$SFI_{n_m}^{MD} = \frac{RMS(\boldsymbol{\varepsilon}_{n_m})}{RMS(\boldsymbol{\varepsilon}_{ref})}. \quad (3.108)$$

Eine Zunahme dieser Verhältnisse kann auf einen Sensorfehler hindeuten. Um den verantwortlichen Sensor auffindig zu machen, wird jeder Sensor in sukzessiver Reihenfolge aus der Berechnung herausgelassen. Wenn der fehlerhafte Sensor nicht an der Berechnung teilnimmt, dann ändert sich auch das RMS-Verhältnis nicht.

#### *Beobachter-basierte Ansätze*

Beobachter-basierte Ansätze nutzen die sog. Residuen-Erzeugung (eng. *residual generation*) zur Fehleridentifikation in elektronischen Schaltungen und dynamischen Systemen. Wenn der Systemeingang unbekannt ist, wird ein *Unknown Input Observer* (UIO) oder das Paritätsraum (eng. *parity space*) [ABDELGHANI und FRISWELL 2001; WANG *et al.* 2010] für das Erzeugen der Residuen verwendet. Die Grundidee dieser Methode ist in [DING *et al.* 2002; GERTLER 1998; GUSTAFSSON 2005; ODGAARD und STOUSTRUP 2010; SUNDARAM und HADJICOSTIS

2005] und [WÜNNENBERG 1990] vorgestellt. Für diesen Ansatz benötigt man die Zeitdaten und den Zustandsraum des Systems. Hierbei werden neben den klassischen Zustandsraummatrizen eines linearen Systems auch weitere Matrizen zur Modellierung von Sensorfehlern, Aktorfehlern und Systemrauschen verwendet. Durch geschickte Umstellung der Zustandsmatrizen mit Hilfe deren Multiplikation mit unterschiedlichen Nullräumen und Annihilatoren werden Residuen für jeden Sensor separat bereitgestellt. Diese Residuen sind sensitiv gegenüber Sensorfehlern, die sich als additive Fehler des Systems erweisen.

Beispielhaft für diese Klasse von Beobachtern stellen [SUNDARAM und HADJICOSTIS 2005] eine Zustands- und Messgleichung vor, welche Sensorfehler  $\tilde{\mathbf{f}}$  und weitere Systemstörungen  $\mathbf{d}$  mitberücksichtigt:

$$\begin{aligned} \mathbf{z}_{k+1} &= \mathbf{A}\mathbf{z}_k + \mathbf{B}_d\mathbf{d}_k + \mathbf{B}_f\tilde{\mathbf{f}}_k \\ \mathbf{y}_k &= \mathbf{C}\mathbf{z}_k + \mathbf{D}_d\mathbf{d}_k + \mathbf{D}_f\tilde{\mathbf{f}}_k \end{aligned} \quad (3.109)$$

Aus der Gl. (3.109) ergibt sich der Systemausgang bei  $L+1$  Zeitinkrementen:

$$\mathbf{y}_{k:k+L} = \mathbf{O}_L\mathbf{z}_k + \mathbf{g}_L^d\mathbf{d}_{k:k+L} + \mathbf{g}_L^f\tilde{\mathbf{f}}_{k:k+L}, \quad (3.110)$$

wobei die in der Gl. (3.110) noch unbekanntten Matrizen wie folgt definiert sind:

$$\mathbf{g}_L^d = \begin{bmatrix} \mathbf{D}_d & 0 \\ \mathbf{O}_{L-1}\mathbf{B}_d & \mathbf{g}_{L-1}^d \end{bmatrix} \text{ und } \mathbf{O}_L = \begin{bmatrix} \mathbf{O}_{L-1} \\ \mathbf{C}\mathbf{A}^L \end{bmatrix}. \quad (3.111)$$

Das Ziel des Modellaufbaus ist die Entkopplung der Störterme, damit das System nur von den Fehlertermen abhängig ist. Dafür wird ein UIO mit der folgenden Zustandschätzung aufgebaut:

$$\hat{\mathbf{z}}_{k+1} = \mathbf{E}\hat{\mathbf{z}}_k + \mathbf{F}\mathbf{y}_{k:k+L}. \quad (3.112)$$

Die Matrizen  $\mathbf{E}$  und  $\mathbf{F}$  aus Gl. (3.112) müssen so ausgewählt werden, dass sich für das fehlerfreie System  $\tilde{\mathbf{f}}_k = 0$  das folgenden Residuum ergibt:  $\mathbf{e}_k = \hat{\mathbf{z}}_k - \mathbf{z}_k \rightarrow 0$ . Dies lässt sich aus der Formulierung des folgenden Zustandsresiduums herleiten:

$$\begin{aligned} \mathbf{e}_{k+1} &= \hat{\mathbf{z}}_{k+1} - \mathbf{z}_{k+1} \\ &= \mathbf{E}\hat{\mathbf{z}}_k + \mathbf{F}\mathbf{y}_{k:k+L} - \mathbf{A}\mathbf{z}_k - \mathbf{B}_d\mathbf{d}_k - \mathbf{B}_f\tilde{\mathbf{f}}_k \\ &= \mathbf{E}\mathbf{e}_k + \mathbf{F}\mathbf{y}_{k:k+L} + (\mathbf{E} - \mathbf{A})\mathbf{z}_k - \mathbf{B}_d\mathbf{d}_k - \mathbf{B}_f\tilde{\mathbf{f}}_k \\ &= \mathbf{E}\mathbf{e}_k + (\mathbf{E} - \mathbf{A} + \mathbf{F}\mathbf{O}_L)\mathbf{z}_k + \mathbf{F}\mathbf{g}_L^d\mathbf{d}_{k:k+L} - \mathbf{B}_d\mathbf{d}_k + \mathbf{F}\mathbf{g}_L^f\tilde{\mathbf{f}}_{k:k+L} - \mathbf{B}_f\tilde{\mathbf{f}}_k. \end{aligned} \quad (3.113)$$

Wenn das System  $(A, B_d, C, D_d)$  „detektierbar“ ist [SUNDARAM und HADJICOSTIS 2005], dann kann  $E$  und  $F$  so ausgewählt werden, dass  $F\mathbf{g}_L^d = [B_d \ 0 \ \dots \ 0]$  und  $E = A - F\mathbf{O}_L$  ergibt. Dies führt zu:

$$\mathbf{e}_{k+1} = (A - F\mathbf{O}_L)\mathbf{e}_k + F\mathbf{g}_L^f \tilde{\mathbf{f}}_{k:k+L} - B_f \tilde{\mathbf{f}}_k, \quad (3.114)$$

wobei  $\mathbf{e}_k \rightarrow 0$  für alle  $\tilde{\mathbf{f}}_k = 0$ . Das Residuum des UIOs wird dann wie folgt definiert:

$$\mathbf{r}_k = \tilde{\mathbf{H}}_1 \hat{\mathbf{z}}_k + \tilde{\mathbf{H}}_2 \mathbf{y}_{k:k+L}, \quad (3.115)$$

wobei hier  $\mathbf{e}_k \rightarrow 0$  und  $\mathbf{r}_k \rightarrow 0$  für alle  $\tilde{\mathbf{f}}_k = 0$ . Unter der Bedingung  $\tilde{\mathbf{f}}_k = 0$  lässt sich  $\tilde{\mathbf{H}}_1 = -\tilde{\mathbf{H}}_2 \mathbf{O}_L$  berechnen.  $\tilde{\mathbf{H}}_2$  ist eine Matrix, deren Zeilen den linken Nullraum von  $\mathbf{g}_L^d$  darstellen. Das Residuum lässt sich nun als

$$\mathbf{r}_k = \tilde{\mathbf{H}}_1 \mathbf{e}_k + \tilde{\mathbf{H}}_2 \mathbf{g}_L^f \tilde{\mathbf{f}}_{k:k+L} \quad (3.116)$$

darstellen. Der somit entstandene Echtzeit-Residuumsgenerator besteht aus den folgenden Gleichungen:

$$\begin{aligned} \hat{\mathbf{z}}_{k+1} &= \mathbf{E} \hat{\mathbf{z}}_k + \mathbf{F} \mathbf{y}_{k:k+L} \\ \mathbf{r}_k &= \tilde{\mathbf{H}}_1 \hat{\mathbf{z}}_k + \tilde{\mathbf{H}}_2 \mathbf{y}_{k:k+L}. \end{aligned} \quad (3.117)$$

Nach der Festlegung der Matrizen  $E$  und  $F$  können auch die noch unbekanntes Eingangssignale  $\mathbf{u}$  (äußere Kräfte in Gl. (2.29)) aus den geschätzten Zuständen berechnet werden:

$$\hat{\mathbf{u}}_k = \tilde{\mathbf{G}} \begin{bmatrix} \hat{\mathbf{z}}_{k+1} - \mathbf{A} \hat{\mathbf{z}}_k \\ \mathbf{y}_k - \mathbf{C} \hat{\mathbf{z}}_k \end{bmatrix}. \quad (3.118)$$

$\hat{\mathbf{u}}_k$  nähert sich an die tatsächliche Systemanregung für  $k \rightarrow \infty$  und  $\mathbf{r}_k \rightarrow 0$ . Die Matrix  $\tilde{\mathbf{G}}$  lässt sich aus  $\tilde{\mathbf{G}} [\mathbf{B} \ \mathbf{D}]^T = \mathbf{I}_{n_u}$  ermitteln, wobei  $\mathbf{I}_{n_u}$  eine Einheitsmatrix darstellt, deren Dimension von der Anzahl der Anregungsstellen  $n_u$  abhängig ist.

Dieser umständliche Weg des Beobachteraufbaus kann vermieden werden, indem nach der Aufstellung von Gl. (3.110) diese von links mit einer Matrix  $V$  multipliziert wird, deren Zeilen den linken Nullraum von  $[\mathbf{O}_L \ \mathbf{g}_L^d]$  darstellen. Daraus folgt:


$$V\mathbf{y}_{k:k+L} = V\mathbf{O}_L \mathbf{z}_k + V\mathbf{g}_L^d \mathbf{d}_{k:k+L} + V\mathbf{g}_L^f \tilde{\mathbf{f}}_{k:k+L}. \quad (3.119)$$

Durch diese Umstellung werden die ersten zwei Terme des rechten Teils der Gl. (3.119) zu Null und das Residuum des Systems ist folglich:

$$\mathbf{r}_k = \mathbf{V}\mathbf{y}_{k:k+L} = \mathbf{V}\mathbf{g}_L^f \tilde{\mathbf{f}}_{k:k+L}. \quad (3.120)$$

Dadurch ergibt sich, dass ein fehlerfreies System ( $\tilde{\mathbf{f}}_k = 0$ ) keine signifikanten Residuen generiert ( $\mathbf{r}_k = 0$ ). Die Matrix  $\mathbf{V}$  ist auch als Paritätsraum der Gl. (3.120) bekannt.

Um die Vorgehensweise zu illustrieren, wird im Folgenden der Balken aus Simulationsbeispiel 1 auf Seite 80 genutzt. Das System wird mit einer stochastischen Kraft angeregt, siehe Abbildung 3.18, welche aber nicht mit in die Berechnung einfließt. Der Systemausgang besteht aus zehn Beschleunigungszeitreihen. Die Zustandsraummatrizen werden mit Hilfe einer *output-only* Modalanalyse mit Hilfe von ARV-Modellen bereitgestellt, siehe Gl. (2.22)-(2.25) und Gl. (3.61)-(3.65). Sollten keine Sensorfehler in dem System vorhanden sein, dann kann die Anregungskraft, Gl. (3.118), korrekt geschätzt werden. In diesem Fall zeigen alle zehn Residuen, berechnet nach Gl. (3.117), Werte nahe bei Null an. Die Kraftschätzung und das Residuum des Sensors 3 sind in Abbildung 3.36 dargestellt.



**Abbildung 3.36: Geschätzte Kraft und Residuum des Sensors 3 bei fehlerfreiem System**

Sollte ein Sensorfehler auftreten, dann kann die auf das System einwirkende Kraft nicht mehr korrekt identifiziert werden und die Residuen der Sensoren zeigen Abweichungen von Null im Fehlerbereich. Abbildung 3.37 zeigt beispielhaft Ergebnisse einer Sensorfehlerdetektion bei einem reinen Bias-Fehler (Verschiebung des Mittelwertes des Sensors 3 um  $10 \text{ m/s}^2$  im Bereich 1-2s). Der Anstieg des Residuums im fehlerhaften Bereich macht den Fehler deutlich sichtbar.





Abbildung 3.37: Signal und Residuum des Sensors 3 bei einem Bias-Fehler

Im Weiteren werden die während dieser Arbeit für die Sensorfehlererkennung an Offshore-Windenergieanlagen entwickelten Methoden und deren Eigenschaften vorgestellt. Bei dieser Entwicklung wird besonders beachtet, dass die Methoden robust gegenüber Einflüssen aus der Umgebung sind und die Veränderungen der entsprechenden Indikatoren von Veränderungen infolge Strukturschäden getrennt werden können.

### 3.5.2 Sensorfehlerdetektion und –isolation mit Hilfe des Mutual Information Konzepts

Die MI-Methode zur Detektion von Sensorfehlern [KRAEMER und FRITZEN 2007b] basiert auf dem Konzept der gegenseitigen Information (eng. *Mutual Information*, MI) zwischen zwei unterschiedlichen diskreten Datenquellen  $X$  und  $Z$  (z.B. zwei Sensoren), vgl. Abschnitt 2.4.3. Hierbei wird der Informationsgehalt der Daten des Sensors  $X$  über den Sensor  $Z$  berechnet. Wenn ein Sensorfehler auftritt, dann ändert sich die  $MI$ , weil dieser Fehler nicht als Information in den anderen Signalen erfasst ist.

Wenn die Signale  $x(t)$  und  $z(t)$  von Sensor  $X$  und respektive Sensor  $Z$  unabhängig voneinander sind, dann ist die Verbundwahrscheinlichkeitsdichte  $p(x, z) = p(x)p(z)$  und dadurch die  $MI$  gleich Null, siehe Gl. (2.122). Abbildung 3.38 stellt beispielhaft unterschiedliche statistische Abhängigkeiten zwischen den Signalen  $x$  und  $z$  anhand einer Draufsicht auf die Verbundwahrscheinlichkeitsdichten grafisch dar. Der linke Teil der Abbildung 3.38 zeigt die Verbundwahrscheinlichkeitsdichte  $p(x, z)$  zweier identischer Signale. Die in der Mitte dargestellte  $p(x, z)$  zeigt die Abhängigkeit zweier identischer Signale, die aber geringfügig von Rauschen überlagert wurden und der rechte Teil des Bildes veranschaulicht die Verbundwahrscheinlichkeitsdichte zweier komplett unabhängiger Rauschsignale.



**Abbildung 3.38: Veranschaulichung der statistischen Abhängigkeit zweier Signale mit Hilfe von Verbundwahrscheinlichkeiten**

Ein direkter Ansatz zur Lösung der Gl. (2.122) ist das Zerlegen der Zeitreihen  $x$  und  $z$  in finite Intervalle (eng. *bins*) mit Hilfe eines Histogramm-Ansatzes. Das Zählen der Anzahl der Paare  $(x_i, z_i)$ ,  $i = 1, \dots, N$ , die in diese sog. *bins* fallen, ermöglicht eine empirische Approximation der Wahrscheinlichkeiten. Dadurch wird die *MI* wie folgt berechnet:

$$MI(X; Z) = \sum_j \sum_i p_{xz}(i, j) \log_2 \frac{p_{xz}(i, j)}{p_x(i) p_z(j)}. \quad (3.121)$$

$p_x(i) \approx n_x(i)/N$  und  $p_z(i) \approx n_z(i)/N$  geben die Wahrscheinlichkeiten an, dass die Anzahl der Punkte  $n_x(i)$  und  $n_z(i)$  in das  $i$ -te Intervall von  $x$  und  $j$ -te Intervall von  $z$  fallen. Die Verbundwahrscheinlichkeit  $p_{xz}(i, j) \approx n(i, j)/N$  basiert auf der Anzahl  $n(i, j)$ , der in die *bins*  $i$  und  $j$  fallenden Punkte. Die *MI* ist immer positiv und symmetrisch:  $MI(X; Z) = MI(Z; X) \geq 0$ . Eine mögliche Auswahl für die Anzahl der *bins*  $b$  errechnet sich für nicht Gauss-verteilte Messdaten nach der STURGES-Regel [STURGES 1926; TOURASSI *et al.* 2001]

$$b = \log_2(n_t) + 1 + \log_2(1 + \kappa_y \sqrt{n_t/6}), \quad (3.122)$$

wobei  $\kappa_y$  die Kurtosis der Daten repräsentiert, siehe auch Gl. (2.131). Für Gauss-verteilte Daten ergibt sich damit:  $b = \log_2(n_t) + 1$ . Neben dem erläuterten Ansatz werden in der Literatur weitere Methoden zur Schätzung der Verteilungsdichtefunktionen angegeben [WALTERS-WILLIAMS und LI 2009]. Diese basieren zum Beispiel auf adaptiven Histogrammen oder auf *Kernel*-Dichte Schätzungen.

Mögliche Normierungen der *MI* mit Hilfe der in den meisten Fällen ungleichen Entropien (auch als Unsicherheitskoeffizienten bezeichnet) sind in [WITTEN und FRANK 2005]

beschrieben, siehe auch Gl. (2.115), (2.118) und (2.121). Besonders sinnvoll ist die Anwendung der Redundanz  $R$ :

$$MI^N(X;Z) = 2R = 2 \frac{MI(X;Z)}{H(X)+H(Z)} = 2 \frac{MI(X;Z)}{MI(X;Z)+H(X,Z)}. \quad (3.123)$$

Wenn  $MI^N(X;Z) = 1$ , dann weisen  $X$  und  $Z$  eine perfekte statistische Abhängigkeit auf. Für unabhängige Signale gilt  $MI^N(X;Z) \rightarrow 0$ .

Um Sensorfehler in  $m$ -variaten Zeitreihen  $\mathbf{y}$  zu identifizieren wird die Berechnung der  $MI$  paarweise für alle möglichen Kombinationen der Sensorsignale  $\mathbf{y}_s(t)$  und  $\mathbf{y}_l(t)$  durchgeführt. Diese führen zu einer  $MI$ -Matrix. Die  $MI$  ändert sich, wenn ein Sensorfehler  $\tilde{\mathbf{f}}_s$  im Kanal  $s$  vorhanden ist:

$$\tilde{\mathbf{y}}_s = \mathbf{y}_s + \tilde{\mathbf{f}}_s. \quad (3.124)$$

Die Änderung der  $MI$  bei einem fehlerhaften Sensor  $s$  macht sich bemerkbar, indem in allen Kombinationen mit dem Index  $s$  aus der  $MI$ -Matrix eine Reduktion der gegenseitigen Information zu sehen ist.

Speziell für die Sensorfehlerdetektion und -isolation werden, elementweise für alle  $m$  Sensoren, die relativen Differenzen zwischen der Referenz- $MI$ -Matrix ( $\mathbf{MI}_{ref}$ ) und alle anderen  $MI$ -Matrizen stammend von den nachkommenden  $n_m$  Messdatensätzen wie folgt berechnet:

$$MI^{rel}(i,j) = \frac{|MI_{n_m}(i,j) - MI_{ref}(i,j)|}{MI_{n_m}(i,j)} \quad \text{mit } 1 \leq i \leq m \text{ und } 1 \leq j \leq m. \quad (3.125)$$

Die  $\mathbf{MI}_{ref}$  kann eine einzige Referenz- $MI$ -Matrix sein, oder eine gemittelte Matrix aus mehreren  $MI$ -Matrizen, berechnet unter die Annahme, dass kein Sensorfehler vorhanden ist.

Die Berechnung von  $\mathbf{MI}^{rel}$  anhand der normierten  $MI$ -Matrizen  $\mathbf{MI}^N$  (auch als Redundanzwerte bekannt, siehe Gl. (3.123)) führt dazu, dass alle Einträge in der Hauptdiagonalen der  $\mathbf{MI}^{rel}$  gleich Null sind.

Bei der Anwendung der  $MI$  auf Schwingungssignale, die aus einer stochastischen Anregung von linearen Strukturen entstanden sind, muss beachtet werden, dass sich diese aus mehreren Schwingungsmoden zusammensetzen. D.h., dass mit steigender Anzahl der Schwingungsmoden die Redundanz zwischen den Signalen stammend von unterschiedlichen Sensoren sinkt. Um die Redundanz zwischen den Sensorsignalen zu gewährleisten, müssen diese so



gefiltert werden, dass die Anzahl der Moden in den Signalen kleiner ist als die betrachtete Anzahl der Sensoren.

Abbildung 3.39 zeigt die, anhand von Entropien normierten, MI-Matrizen, siehe Gl. (3.123), für den Balken aus Simulationsbeispiel 1 in Abbildung 3.18. Im linken Teil des Bildes sind die berechneten Redundanzen zwischen allen zehn Sensoren, wenn sich nur eine Schwingungsmode an der Signalentstehung beteiligt, illustriert. Dass die Information zwischen allen Sensoren redundant ist, kann sehr gut mit Abbildung 3.29 begründet werden, da bei der alleinigen Beteiligung der ersten Mode alle zehn Sensorsignale die gleiche Information erhalten. Bei der Beteiligung von zwei Moden (Abbildung 3.39, Mitte) ist zu beobachten, dass die Information zwischen den Sensoren acht und neun und allen anderen geringer ist. Dieser Informationsverlust kann anhand des Schwingungsknotens der zweiten Mode in der Nähe der Sensoren acht und neun erklärt werden, vgl. Abbildung 3.29. Wenn die Anzahl der Moden gleich oder größer als die Anzahl der Sensoren ist, liefert die redundante Information zwischen den Sensoren den Wert Null, siehe Abbildung 3.39, rechts.




Abbildung 3.39:  $MI$  zwischen den Sensorsignalen in Abhängigkeit der Modenanzahl

Wenn z.B. ein Sensorfehler  $\tilde{f}_3$  die Ergebnisse des Messkanals drei negativ beeinflusst, werden diese Änderungen in der Matrix  $MI^{rel}$  sichtbar, siehe z.B. Abbildung 3.40. Hier wurde der Fehler durch ein zusätzliches Rauschen, simuliert. Das Verhältnis zwischen dem ursprünglichen Signal vor der Filterung und dem verrauschten Signals lässt sich hier durch das Signal-zu-Rauschen-Verhältnis ( $SNR$ ) definieren. Dieses berücksichtigt das Verhältnis der Effektivwerte ( $RMS$ ) des Signals und des Rauschanteils im Signal und ist wie folgt eingestellt:

$$SNR = RMS(y_3) / RMS(\tilde{f}_3) = 2.$$

Der Effektivwert für ein Sensorsignal  $y_s$  der Länge  $n_t$  ist:

$$RMS(\mathbf{y}_s) = \sqrt{\frac{\mathbf{y}_s^T \mathbf{y}_s}{n_t}}. \quad (3.126)$$

Die Berechnung der  $MI^{rel}$  anhand der gefilterten Signale, kann den nicht zu erwartenden tieffrequenten Anteil des Rauschens auf dem Signal drei als Sensorfehler einstufen. Inwiefern hochfrequentes Rauschen in einem Signal identifiziert werden kann, hängt stark von dem Ausmaß des Fehlers, der Anzahl der Sensoren und deren Redundanz bei der betrachteten Eigenmode ab. Wie aus Abbildung 3.40 (rechts), hervorgeht sind die etwas höherfrequenten Anteile des Rauschens (z.B. auf der Mode eins und Mode zwei) immer noch zufriedenstellend zu identifizieren.




Abbildung 3.40: MI-Veränderung bei verrauschten Sensor 3

Nicht nur tieffrequentes Rauschen sondern auch Drift in den Sensorsignalen kann mit der Methode gut identifiziert werden. In Abbildung 3.41 wird das verrauschte ( $SNR = 5$ ) und abgedriftete Signal des Sensors drei gezeigt.





Abbildung 3.41: Ursprüngliches und fehlerhaftes Signal des Sensors drei (links); Vergrößerung des Plots im Bereich 2,55-2,75 s (rechts)

Die Auswirkung der Rausch- und Driftanteile auf die relative Veränderung der  $MI$  ist in Abbildung 3.42 dargestellt.



**Abbildung 3.42: Gleichzeitige Rauschen und Driften des Sensors drei**

Der Algorithmus ist in der Lage mehrere Sensorfehler gleichzeitig zu identifizieren, ohne dass sich der Berechnungsaufwand erhöht oder dass weitere Einstellungen für die „Suche“ nach mehreren Fehlern notwendig sind. Ein Beispiel dafür ist in [KRAEMER und FRITZEN 2008b] gezeigt. Je nach Datenvorbereitungsstrategie sind auch reine Biasfehler oder Fehler in den Vergrößerungsfaktoren prinzipiell identifizierbar. Hierbei ist allerdings zu beachten, dass solche Fehler bei einer Datennormierung des Typs

$$\mathbf{y}^N = \frac{\mathbf{y} - \mu_y}{\sigma_y}, \quad (3.127)$$

welche sich oft in der Datenanalyse zur Reduktion der Einflüsse der Anregungsleistung auf die Systemantwort nützlich erweist, ausgeglichen werden können und danach nicht mehr identifizierbar sind.

### 3.5.2.1 Der Algorithmus zur Langzeitüberwachung

Bedingt durch seine Gestaltung ist der Algorithmus insensitiv gegenüber lokalen Steifigkeitsveränderungen verursacht durch Schäden und globale Steifigkeitsveränderungen (z.B. als Folge von Temperaturänderungen). Der Grund für dieses Verhalten liegt darin, dass Schäden i.d.R. am deutlichsten in den Veränderungen der höheren Eigenfrequenzen zu beobachten sind. Gerade diese Frequenzen werden bei der Anwendung der  $MI$ -Methode gefiltert. Globale und lokale Systemveränderungen, die sichtbar in Veränderungen der tiefen Moden sind, werden i.d.R. gleichzeitig von allen Sensoren registriert, so dass die redundante Information zwischen den Sensoren theoretisch unverändert bleibt.

Um den Einfluss der veränderlichen EOCs auf die relative Änderung der MI zu verdeutlichen wird die globale Steifigkeit des Balkens aus dem Simulationsbeispiel 1 um 10% reduziert, was eine Veränderung der ersten Eigenfrequenz um ca. 5% bewirkt. Dadurch lässt sich ein sehr starker Temperatureinfluss auf die Struktursteifigkeit simulieren. Veränderliche Energien in der Anregung, die in der Realität z.B. durch veränderliche Windgeschwindigkeiten auftreten, werden durch eine Erhöhung um das Zehnfache der Energie im Anregungssignal erreicht. Der Einfluss eines Schadens in der Nähe des Sensors 3 erreichte man mit Hilfe einer lokalen Steifigkeitsreduktion um 30% des entsprechenden Elementes, was eine Veränderung der ersten Eigenfrequenz um ca. 2% verursacht. Im Vergleich zu Abbildung 3.42, zeigt sich die  $MI$  in Abbildung 3.43 wesentlich insensitive gegenüber veränderlichen EOCs oder Schäden als gegenüber Sensorfehlern. Die veränderlichen EOCs oder Schäden bewirken nur eine unwesentliche und relativ gleichmäßige Änderung aller Komponenten der MI-Matrix.




Abbildung 3.43: Einfluss von EOCs und Schäden auf die relativen MI-Werte

Für die Langzeitüberwachung wird die Symmetrie der MI-Matrizen verwendet, um einen einzigen Fehlerindikator für jeden Sensor  $s$  separat zu erhalten. Wenn  $i$  und  $j$  Indizes von  $MI^{rel}(i, j)$  sind, dann kann der Sensorfehlerindikator ( $SFI$ ) für jeden Sensor  $s$  wie folgt geschrieben werden:

$$SFI_s = \frac{1}{m-1} \sum_i MI^{rel}(i, j). \quad (3.128)$$

Grenzwerte für den Gesamtzustand der Sensoren können mit Hilfe eines  $\chi^2$ -Test für die Varianzen  $s^2(\mathbf{SFI})$  mit  $\mathbf{SFI} = [SFI_1 \ \dots \ SFI_m]^T$  aufgestellt werden [SACHS und HEDDERICH 2006]. Dabei sollen die Einzelvarianzen  $s^2(\mathbf{SFI})_{n_m}$  jeder einzelnen Messung  $n_m$  bezogen auf die Varianz der Grundgesamtheit  $\hat{\sigma}^2$  den zu erwartenden Schwellenwert  $(\chi^2)_{1-\alpha, f, \chi^2}^{-1}$  in der angegebenen Konfidenzgrenze  $1-\alpha$  nicht überschreiten. Die Varianz

$\hat{\sigma}^2$  wird aus dem Mittelwert einiger Referenzeinzelvarianzen  $s^2$ , die für die unbeschädigten Zustand der Sensoren repräsentativ sind, geschätzt.

$$H_0 : T_{SFI_{n_m}} = \frac{(f_{\chi^2} - 1)s^2(\mathbf{SFI})_{n_m}}{\hat{\sigma}^2} < (\chi^2)_{1-\alpha, f_{\chi^2}}^{-1}. \quad (3.129)$$

Ausgewählte Quantile (Signifikanzschranken) der  $\chi^2$ -Verteilung mit  $f_{\chi^2}$  Freiheitsgraden werden aus der inversen  $\chi^2$ -Summenhäufigkeitsverteilung berechnet, siehe [SACHS und HEDDERICH 2006]. Wird der Schwellenwert unzulässig überschritten, deutet dies auf eine Änderung der Varianz der *SFI* hin und die  $H_0$ -Hypothese wird verworfen. Dieses Verhalten lässt sich in den meisten Fällen auf einen oder mehrere gleichzeitige Sensorfehler zurückführen. Analog zu Gl. (3.129) haben Testverfahren aus der statistischen Prozessüberwachung wie. z.B. der *s-chart*-Test [MONTGOMERY 1991] gleichwertige Ergebnisse zur Aufstellung des Schwellenwertes geliefert.

Für die Veranschaulichung der Vorgehensweise, beschrieben in Gl. (3.128) und (3.129), werden 550 Messdatensätze mit Hilfe des Balkenmodells aus Simulationsbeispiel 1 erstellt. Um realistische Messergebnisse zu simulieren lassen sich in den ersten 500 Datensätzen das Anregungssignal und seine Leistung für jeden Datensatz verändern. In den letzten 50 Datensätzen ist das Signal des Sensors 3 zusätzlich verrauscht ( $SNR = 5$ ). Die Ergebnisse der Detektion sind in Abbildung 3.44 für  $\alpha = 0,01$  dargestellt<sup>1</sup>. Nun kann die Isolation des fehlerhaften Sensors durch die Betrachtung der relativen Redundanzveränderungen in Gl. (3.125) erfolgen.

---

<sup>1</sup> Erwartungsgemäß kommen innerhalb von 500 *SFI* der unbeschädigten Sensoren 5 Ausreißer vor.




Abbildung 3.44: Beispielhafte Sensorfehlerdetektion für 550 Messdatensätze

### 3.5.3 Rekonstruktion von Signalen fehlerhafter Sensoren

Die Rekonstruktion fehlerhafter Signale, kann von großem Interesse hinsichtlich der Feststellung der Fehlerursache sein. Dadurch kann aus dem rekonstruierten und gemessenen Signal geschätzt werden, ob Fehler in den Verstärkungsfaktoren der Messeinheit, Abdriftung des Signals infolge schlechter Kopplung des Sensors an die Struktur, oder andere Fehlerursachen vorliegen.

Eine weitere interessante Anwendung, welche die Signalrekonstruktion mit Hilfe von Kalman-Filtern bietet, ist die Schätzung von Systemantworten an unerreichbaren oder schwer zugänglichen Stellen, z.B. auf der Tripodstruktur einer OWEA unterhalb der Wasseroberfläche. Ein Beispiel dafür befindet sich in [PAPADIMITRIOU *et al.* 2009]. Hier wurden einaxiale Spannungen an mehrere Stellen in einer Struktur mit einem einzigen Sensor und einem Strukturmodell geschätzt. Daraus ließ sich der Ermüdungszustand der Struktur berechnen.

#### 3.5.3.1 Rekonstruktion von Signalen mit Hilfe eines Kalman-Filters

Die Rekonstruktion fehlerhafter Signale oder die Schätzung nicht vorhandener Systemzustände (Simulation von Signalen virtueller Sensoren) wird modellgestützt oder mit Hilfe gemessener Modaldaten anhand des in Abschnitt 2.2.3 beschriebenen Kalman-Filters (KF) durchgeführt. Hierfür wird die optimale Kalman-Verstärkermatrix aus der stationären Fehlerkovarianzmatrix  $\mathbf{P}_\infty$  aus Gl. (2.67) berechnet:

$$\mathbf{K}_\infty = \mathbf{P}_\infty \mathbf{C}_y^T (\mathbf{C}_y \mathbf{P}_\infty \mathbf{C}_y^T + \mathbf{R}_v)^{-1}. \quad (3.130)$$

Mit Hilfe dieser Gleichung lassen sich die Zustände des Systems für jeden diskreten Zeitpunkt  $k$  schätzen:

$$\hat{\mathbf{z}}_k = \hat{\mathbf{z}}_k^- + \mathbf{K}_\infty (\mathbf{y}_k - \mathbf{C}_y \hat{\mathbf{z}}_k^- - \mathbf{D} \mathbf{u}_k). \quad (3.131)$$

Der geschätzte Zustand wird zur „Voraussage“ der Messergebnisse genutzt:

$$\hat{\mathbf{y}}_k = \mathbf{C}_y \hat{\mathbf{z}}_k + \mathbf{D} \mathbf{u}_k + \mathbf{v}_k. \quad (3.132)$$

Wenn das Anregungssignal nicht bekannt ist, dann kann  $\mathbf{u} = 0$  gesetzt werden. Das führt zu der Annahme, dass das System ausschließlich über den Rauschprozess  $\mathbf{w}$  mit der Kovarianz  $\mathbf{Q}_w$  an den in der Matrix  $\mathbf{G} = \mathbf{B}_d$  beschriebenen Anregungsstellen gesteuert wird. Die Zustandsgleichungen dieses Systems berechnen sich nach Gl. (2.62):

$$\begin{aligned} \hat{\mathbf{z}}_k &= \mathbf{A}_d \hat{\mathbf{z}}_{k-1} + \mathbf{G} \mathbf{w}_{k-1} \\ \hat{\mathbf{y}}_k &= \mathbf{C}_y \hat{\mathbf{z}}_k + \mathbf{v}_k \end{aligned} \quad (3.133)$$

Die für die Schätzung der Antwort notwendigen Zustandsmatrizen können mit Hilfe eines Finite-Elemente-Modells oder gemessener Modaldaten aufgestellt werden, siehe Gl. (2.9)-(2.14).

Im Falle der Anwendung komplexer FE-Modelle mit einer großen Anzahl an Freiheitsgraden ist eine Transformation der Freiheitsgrade auf modale Koordinaten notwendig, siehe Gl. (2.15)-(2.25). Die modale Transformation führt u.a. zu einer erheblichen Verbesserung der Rechenzeiten [GAWRONSKI 2004]. Ein weiterer wesentlicher Vorteil ist die gezielte Auswahl der Moden, die an der Schätzung der Zeitdaten beteiligt sind. Die Auswahl der Moden in einem Signal ist wichtig, da die Redundanz zwischen den Signalen mit steigender Anzahl der Moden bei gleichbleibender Anzahl von Sensoren sinkt, siehe auch Abschnitt 3.5.2.

Für die Anwendung der gemessenen Modaldaten zur Schätzung der Zustandsmatrizen werden die Matrizen  $\mathbf{\Omega}$ ,  $\mathbf{Z}$  und  $\mathbf{\Phi}$  in Gl. (2.22)-(2.25) aus den Eigenfrequenzen des ungedämpften Systems, den modalen Dämpfungen und den Eigenschwingungsformen, siehe Abschnitt 3.4.1, aufgebaut. Die für die Berechnung der Matrizen  $\mathbf{B}_m$  und  $\mathbf{D}_m$  verwendete Diagonalmatrix  $\mathbf{M}_m$  stellt in diesem Kontext die an den Messstellen konzentrierten Massen dar.

Für die Anwendung der Zustandsraumdarstellung im Zusammenhang mit dem Kalman-Filter werden die Zustandsmatrizen im diskreten Zeitbereich mit Hilfe der Gl. (2.26)-(2.29) überführt. Die einzigen noch unbekanntenen Größen des KFs, die aus weiteren Schätzungen gewonnen werden sollen, sind die Kovarianzen des Mess- und Prozessrauschens  $\mathbf{R}_v$  bzw.  $\mathbf{Q}_w$ . Da beim beschriebenen Kalman-Filter von unabhängigem Rauschen auf den Sensor-

signalen und in der Anregung ausgegangen wird, sind nur die Diagonalelemente der Kovarianzmatrix des Messrauschens  $\mathbf{R}_v$  besetzt. Die Größe dieser Varianzen gibt Auskunft, wie viel Rauschen auf dem entsprechenden Messkanal erwartet wird und dadurch auch Informationen über die vorhandene „Qualität“ eines Sensors. Je größer die Varianz des Messrauschens eines Sensors ist, umso kleiner ist das „Vertrauen“ in die Messdaten dieses Sensors. Das Grundrauschverhalten der Sensoren und somit die Kovarianzmatrix des Messrauschens kann *a priori* durch Angaben vom Hersteller oder durch Algorithmen zur Berechnung des Rauschanteils in den Signalen [STARK und WOODS 2002] festgelegt werden. Die Kovarianzmatrix des Prozessrauschens für eine optimale Schätzung der Signale, kann durch die Minimierung der Zielfunktion

$$J(\mathbf{Q}_w) = \left\| \text{diag}(E[\boldsymbol{\varepsilon}_k \boldsymbol{\varepsilon}_k^T]) - \text{diag}(E[\mathbf{v}_k \mathbf{v}_k^T]) \right\|^2 \quad \text{mit} \quad \boldsymbol{\varepsilon}_k = \mathbf{y}_k - \hat{\mathbf{y}}_k \quad (3.134)$$

für unterschiedliche Startwerte von  $\mathbf{Q}_w$  erfolgen. Diese Bedingung führt dazu, dass die Fehlerkovarianzmatrix  $\mathbf{P}_\infty$  optimal zur Schätzung der Systemzustände angepasst wird. Dadurch lassen sich Schätzfehler, die z.B. durch die Vernachlässigung der Durchgangsmatrix in der Messgleichung bei gemessenen Beschleunigungen entstehen, kompensieren. Im Fall von Windenergieanlagen wird die Anregungskraft aus dem Wind über den Turmkopf in den Turm eingeleitet. Dadurch können gute Startwerte für  $\mathbf{Q}_w$  aus der erwarteten Windanregungskraft  $\hat{\mathbf{F}}_w$ , die in der Regel als tieffrequentes, unkorreliertes, weibullverteiltes Rauschsignal betrachtet wird, zunächst mit Hilfe der Betz-Theorie geschätzt werden:

$$\hat{\mathbf{F}}_w = \frac{1}{2} c_w \rho v_w^2 A_R \quad (3.135)$$

In Gl. (3.135) stellt  $c_w$  den aerodynamischen Widerstand,  $v_w$  die Windgeschwindigkeit<sup>1</sup>,  $\rho$  die Luftdichte und  $A_R$  die Rotorfläche dar.

*Die Hauptidee der Signalrekonstruktion* [KRAEMER und FRITZEN 2008b]:

Wenn mindestens ein fehlerhafter Sensor identifiziert wurde (z.B. mit der MI-Methode), lässt sich der KF zur Rekonstruktion dieses Signals nutzen, indem die Varianz des Messrauschens dieses Sensors erhöht wird. Dadurch sinkt das „Vertrauen“ in dieses Signal und die Kalman-

---

<sup>1</sup> Die Windrichtung wird als orthogonal zur Rotorfläche angenommen.



Verstärkungsmatrix nimmt für den fehlerhaften Sensor kleinere Werte an<sup>1</sup>, als für die nicht geschädigten Sensorsignale. Anschließend lässt sich das Signal des fehlerhaften Sensors mit Hilfe des Modells und der anderen Sensoren schätzen. Der Algorithmus besteht im Prinzip aus fünf Rechenschritten:

Schritt 1: Isolation der geschädigten Sensoren mit Hilfe der MI-Methode.

Schritt 2: Aufbau des Zustandsraummodells aus gemessenen Modaldaten oder mit Hilfe eines FE-Modells der zu untersuchenden Struktur.

Schritt 3: Festlegung der Kovarianzmatrizen des Mess- und des Prozessrauschens.

Schritt 4: Erhöhen der Werte der Kovarianzmatrix des Messrauschens für die fehlerhaften Sensoren.

Schritt 5: Berechnung der Bewegungsgleichung mit dem geschätzten Zustandsraumvektor  $\hat{z}_k$  (das Kalman-Filter nutzt den Eingangsvektor  $\mathbf{u} = \mathbf{0}$  und die gemessene Signale  $\mathbf{y}$ ).

Ein Schema für die Signalrekonstruktion ist in Abbildung 3.45 dargestellt.

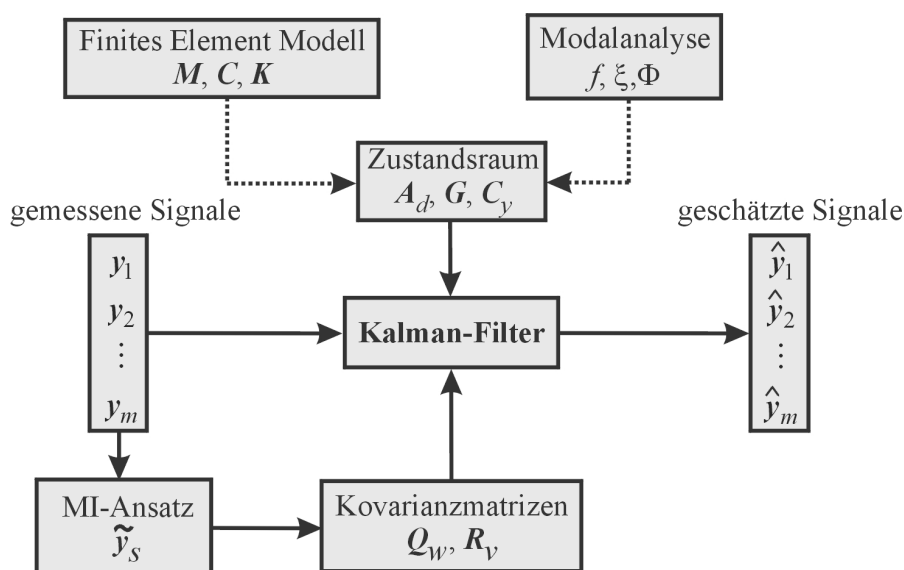



Abbildung 3.45: Signalrekonstruktion mit Kalman-Filter

Als Beispiel zur Signalrekonstruktion wird der Balken aus dem Simulationsbeispiel 1 mit dem gleichen Sensorfehler wie in Abbildung 3.41 genutzt (Signal von Sensor drei driftet ab und weist ein Signal-zu-Rauschen-Verhältnis  $SNR = 5$  auf). Im linken Teil der Abbildung 3.46 ist das gemessene (fehlerhafte), das erwartete (fehlerfreie) und das mit Hilfe des KF geschätzte Sensorsignal dargestellt. Die „Güte“ der Signalrekonstruktion kann visuell im rechten Teil der

<sup>1</sup> Das fehlerhafte Signal kann auch durch das Nullsetzen des für den Sensor entsprechenden Werts in der Kalman-Verstärkungsmatrix geschätzt werden.

Abbildung besser betrachtet werden, siehe auch die Tabelle 3.3 auf Seite 143. Hier sind im vergrößerten Bereich nahezu keine Unterschiede zwischen dem erwarteten und dem geschätzten Signal sichtbar.



**Abbildung 3.46: Rekonstruktion fehlerhaften Signalen mit Kalman-Filter (links: gesamter Signalbereich; rechts: Vergrößerung im Bereich 31-31.3 s)**

Die Ergebnisse der Signalschätzung sind abhängig von der Modell- oder Modalanalysegüte, der Qualität der gemessenen Signale und der Anzahl der betrachteten Moden. Diese Einflüsse können mit Hilfe von Parameterstudien für jede Struktur und jedes Messsystem separat bewertet werden.

### 3.5.3.2 Residuen des Kalman Filters zur Sensorfehlerdetektion und -isolation

Die in Abschnitt 3.5.3.1 dargestellte Vorgehensweise zur Rekonstruktion fehlerhafter Signale erlaubt gleichzeitig eine Sensorfehlerisolation ohne dass Referenzdaten von unbeschädigten Sensoren (wie z.B. bei der MI-, MD- oder PCA-Methode) erforderlich sind. In diesem Kontext wird der Ansatz des fehlenden Sensors genutzt. Dabei lassen sich die Schritte drei bis fünf aus dem Abschnitt 3.5.3.1 für alle als fehlend gesetzten Sensoren mehrmals durchführen. Wenn das Signal des fehlerhaften Sensors nicht an der Rekonstruktion der anderen Signale teilnimmt, dann lassen sich die anderen Signale korrekt schätzen. Die „Qualität“ eines Sensors  $s$  kann unter diesen Umständen z.B. mit Hilfe einer symmetrischen Form des Kullback-Leibler-Abstands definiert werden:

$$KL(\mathbf{y}_s, \hat{\mathbf{y}}_s) = D[p(\mathbf{y}_s) || p(\hat{\mathbf{y}}_s)] = \frac{1}{2} \sum [p(\mathbf{y}_s) - p(\hat{\mathbf{y}}_s)] \log \frac{p(\mathbf{y}_s)}{p(\hat{\mathbf{y}}_s)}. \quad (3.136)$$

Gl. (3.136) berechnet die Abstände zwischen den Verteilungsdichtefunktionen des gemessenen  $p(\mathbf{y}_s)$  und des rekonstruierten/geschätzten Signal  $p(\hat{\mathbf{y}}_s)$ . Eine weitere mögliche

Vorgehensweise bei der Überprüfung der Qualität der Schätzung bieten die Rekonstruktionsfehlervarianzen  $E[\varepsilon_s^2]$  mit  $\varepsilon_s = \mathbf{y}_s - \hat{\mathbf{y}}_s$ .

Die praktische Implementierung der Gl. (3.136) erfolgt analog zur Implementierung der MI-Berechnung in Gl. (3.121)

$$KL(\mathbf{y}_s, \hat{\mathbf{y}}_s) = \frac{1}{2} \sum_i \left[ p_{y_s}(i) - p_{\hat{y}_s}(i) \right] \log \frac{p_{y_s}(i)}{p_{\hat{y}_s}(i)}. \quad (3.137)$$

Hierbei werden die Wahrscheinlichkeitsdichten in mehrere Bereiche (sog. *bins*)  $i$  unterteilt.  $p_{y_s}(i) \approx n_{y_s}(i)/N$  und  $p_{\hat{y}_s}(i) \approx n_{\hat{y}_s}(i)/N$  geben die Wahrscheinlichkeiten an, dass die Anzahl der Punkte  $n_{y_s}(i)$  und  $n_{\hat{y}_s}(i)$  in das  $i$ -te *bin* von  $\mathbf{y}_s$  respektive  $\hat{\mathbf{y}}_s$  fallen, wobei  $N$  die Gesamtanzahl der *bins* repräsentiert.

Der Sensorfehlerindikator  $SFI_s^{KLKF}$  für jeden Sensor  $s$  in einem System mit  $m$  Sensoren, ist wie folgt definiert:

$$SFI_s^{KLKF} = \frac{1}{m-1} \sum_{s=1}^m KL(\mathbf{y}_s, \hat{\mathbf{y}}_s), \quad 1 < s < m. \quad (3.138)$$

Wenn der fehlerhafte Sensor nicht zur Schätzung der  $m$ -Signale einbezogen wird, dann ergibt Gl. (3.138):  $SFI_s^{KLKF} \rightarrow 0$ . Sollte das fehlerhafte Signal in die Berechnung der KL-Abstände eingehen, erhöht sich der Fehlerindikator des geschädigten Sensors. Ein Schema des Algorithmus ist in Abbildung 3.47 dargestellt.

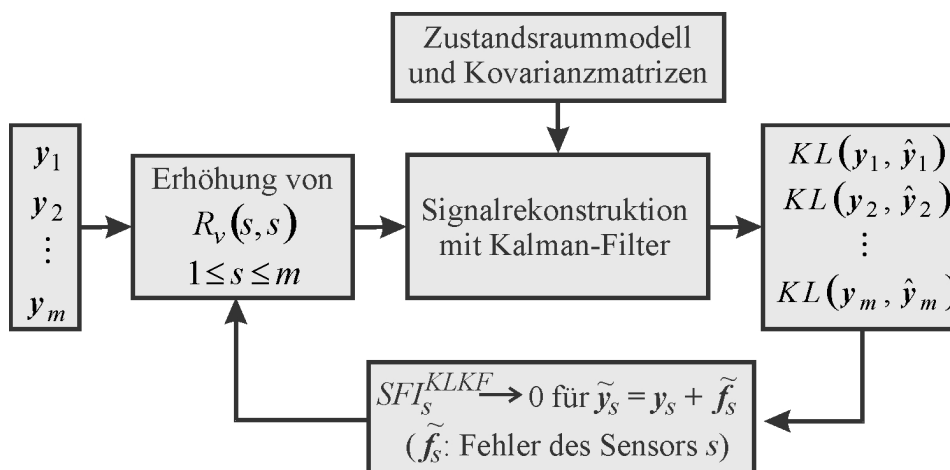


Abbildung 3.47: Schema des Algorithmus zur Sensorfehlerisolierung mit dem Kalman-Filter unter Verwendung des Kullback-Leibler-Abstands

Die Methode soll auch hier beispielhaft mit Signalen, die aus dem Simulationsbeispiel 1 des Abschnitts 3.4.1 generiert sind, erläutert werden. Das gemessene, fehlerhafte Signal  $\tilde{y}_3$  ist in Abbildung 3.46 aus Abschnitt 3.5.3.1 dargestellt. Abbildung 3.48 (links) zeigt die Unterschiede in den Verteilungsdichtefunktionen (PDF)  $p(y_3)$  und  $p(\hat{y}_3)$  der erwarteten und der geschätzten Signale des dritten Sensors unter Beteiligung des fehlerhaften Sensors drei. Abbildung 3.48 (rechts) zeigt deutlich, dass ohne das fehlerhafte Signal des dritten Sensors alle zehn Sensorsignale am besten rekonstruiert werden können.

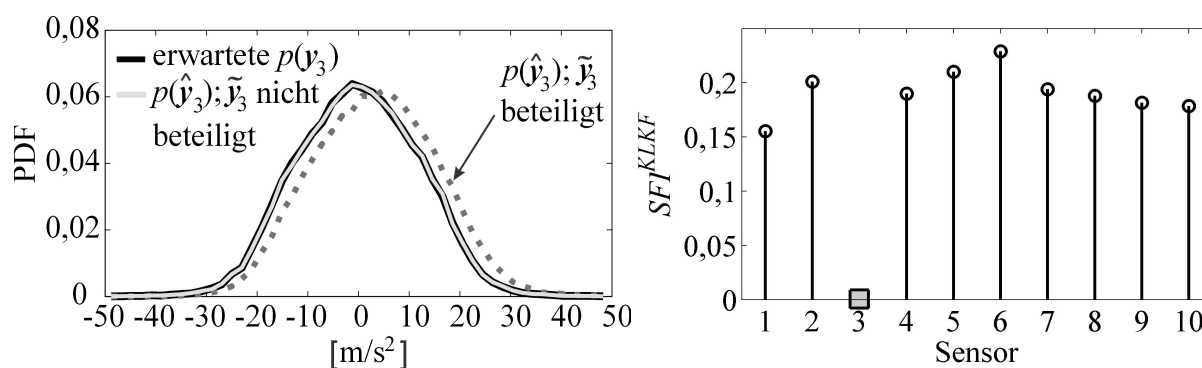


Abbildung 3.48: Verteilungsdichtefunktionen mit und ohne Berücksichtigung des Signals des fehlerhaften Sensors (links); Sensorfehlerisolation mit Kalman-Filter und Kullback-Leibler-Abstand (rechts)

### 3.5.4 Vergleich unterschiedlicher Methoden zur Sensorfehlererkennung

Wie schon angedeutet, nutzen die in der Literatur beschriebenen Methoden (PCA und MD), siehe Abschnitt 3.5.1, aber auch die MI implizit die Kovarianzmatrix der Messdaten zur Identifikation der Veränderungen durch einen Sensorfehler. Der Unterschied besteht hierbei in der Verwendung von Wahrscheinlichkeitsdichtefunktionen der Messdaten für die MI-, rohen Messdaten für die MD- und komprimierten Daten für die PCA-Methode, sowie in der Betrachtung aller Sensorkanäle gleichzeitig (MD und PCA) oder paarweise (MI).

Die Kovarianzmatrix ist bei der MI-Methode präsent in dem Korrelationsfaktor  $\rho_{xz}$  aus Gl. (3.139). Für Vergleichszwecke wird hier beispielhaft die Verbundwahrscheinlichkeitsdichte zweier normalverteilter Signale  $x$  und  $z$  mit  $N(\mu_x, \sigma_x^2)$  bzw.  $N(\mu_z, \sigma_z^2)$

$$p(x, z) = \frac{1}{2\pi\sigma_x\sigma_z\sqrt{1-\rho_{xz}}} e^{-\frac{1}{2(1-\rho_{xz}^2)} \left[ \left( \frac{x-\mu_x}{\sigma_x} \right)^2 - 2\rho_{xy} \frac{(x-\mu_x)(z-\mu_z)}{\sigma_x\sigma_z} + \left( \frac{z-\mu_z}{\sigma_z} \right)^2 \right]} \quad (3.139)$$

dargestellt. Die Beziehungen zwischen dem Korrelationsfaktor und der Kovarianzmatrix  $\Sigma_{xz}$

$$\Sigma_{xz} = \begin{bmatrix} \sigma_x^2 & \rho_{xz}\sigma_x\sigma_z \\ \rho_{xz}\sigma_x\sigma_z & \sigma_z^2 \end{bmatrix} \quad (3.140)$$

zeigen, dass sich für  $\rho_{xz} = 0$ ,  $p(x, z) = p(x)p(z)$  ergibt, da diese nur von der Varianz einzelner Signale abhängig ist. Das führt zu einer achsenorthogonalen Gauss-Verteilung von  $p(x, z)$ , siehe auch Abbildung 3.38, rechts. Durch  $|\rho_{xz}| > 0$  werden auch die Nebendiagonalen der Kovarianzmatrix besetzt, was auf eine gewisse Abhängigkeit zwischen den beiden Signalen hinweist, siehe auch Abbildung 3.38, Mitte und links.

Der Vorteil der Mutual Information gegenüber PCA und MD besteht in der paarweisen Betrachtung der Messsignale. Dadurch können ohne zusätzlichen Aufwand mehrere Sensorfehler gleichzeitig identifiziert werden. Im Gegensatz dazu kann das Prinzip des fehlenden Sensors aus Abschnitt 3.5.1, welches für die Anwendung von PCA- und MD-Methode unabdingbar ist, prinzipiell für die Identifikation eines einzelnen Sensorfehlers genutzt werden. Die Vorgehensweise ist jedoch sehr rechenzeitintensiv und nicht mehr anwendbar, wenn die Anzahl der „bekannten/intakten“ Sensoren gleich der Anzahl der Moden in den Schwingungssignalen ist.

Der Vorteil des Kalman-Filter-Ansatzes gegenüber den anderen Methoden ist, dass im Fall einer Anwendung eines geeigneten FE-Modells keine Referenzdaten mehr benötigt werden.

Weitere Ergebnisse, basierend auf dem Simulationsbeispiel 1 von Seite 80, sind in Abbildung 3.49 dargestellt. Diese zeigen für die PCA-Methode, dass der kleinste Winkel zwischen den Unterräumen der Kovarianzmatrix sich dann einstellt, wenn der geschädigte Sensor nicht an der Berechnung teilnimmt. Analog dazu zeigt die MD-Methode, dass die beste Rekonstruktion des Signals nur dann gelingt, wenn der fehlerhafte Sensor nicht zur Bildung der Kovarianzmatrix herangezogen wird, siehe Abbildung 3.49, rechts.





Abbildung 3.49: Sensorfehlerisolation mit PCA (links) und MD (rechts)

Ein großer Vorteil der PCA- und MD-Methode ist, dass beide Ansätze die Sensorsignale rein datenbasiert rekonstruieren. In Abbildung 3.50, oben, ist ein Ausschnitt aus dem gestörten Signal des Sensors drei aus der Abbildung 3.46, aufgebaut aus vier Moden, dargestellt. Die Qualität der Rekonstruktion ist für die PCA-Methode unter Beteiligung von vier Hauptkomponenten in Abbildung 3.50, unten links, und für die MD-Methode in Abbildung 3.50, unten rechts, dargestellt, siehe auch die Tabelle 3.3. Ein Vorteil der MD- gegenüber der PCA-Methode ist, dass MD keine Einstellungen weiterer Parameter (z.B. Anzahl an beteiligten Hauptkomponenten) benötigt und sich aus dieser Sicht besser zur automatischen Überwachung von Sensoren eignet.



**Abbildung 3.50: Rekonstruktion fehlerhafter Messsignale mit PCA (links unten) und MD (rechts unten)**

Beide Methoden zeigen, dass prinzipiell eine Rekonstruktion des fehlerhaften Signals möglich ist, jedoch können diese nicht die „Qualität“ der auf KF-Verfahren basierten Rekonstruktion, unter Voraussetzung eines guten Modells oder eines guten Modalanalyseergebnisses, nicht erreichen.

Tabelle 3.3 zeigt die Fehlerreduktion durch Signalrekonstruktion für das angegebene Beispiel. Hierbei wird die Varianz des Rekonstruktionsfehlers  $E[\varepsilon_3^2]$  mit  $\varepsilon_s = \mathbf{y}_s - \hat{\mathbf{y}}_s$  auf die Varianz des Fehlers  $E[\mathbf{f}_3^2]$  im Signal  $\tilde{\mathbf{y}}_3$  wie folgt bezogen:  $100\% - E[\varepsilon_3^2]/E[\mathbf{f}_3^2] \cdot 100\%$ .

Methode	Fehlerreduktion [%]
Kalman-Filter	99,99%
PCA	92%
<i>Missing Data</i> (MD)	79%

**Tabelle 3.3: Beispielhafte Signalrekonstruktionsfehler mit unterschiedlichen Methoden**

Bzgl. der Sensorüberwachung an WEAs wird in dieser Arbeit ein besonderer Akzent auf die Sensorfehlerdetektion und –isolation mit Hilfe der *Mutual Information* gesetzt, was sich durch folgende Eigenschaften dieser Methode begründen lässt: sie kann mehrere fehlerhafte Sensoren gleichzeitig und ohne zusätzlichen Rechenaufwand isolieren, zeigt sich wenig sensitiv gegenüber Änderungen in den EOCs sowie Strukturschäden und ist leicht automatisierbar. Da die Methoden zur Signalrekonstruktion nur den Fehlertyp und vielleicht die möglichen Fehlerursachen offenbaren, wurden diese nur für eine ausgedehnte *offline*-Signaluntersuchung und noch nicht in einem automatischen System zur Sensorfehlerüberwachung implementiert, siehe auch Abbildung 5.12.

## 4 SCHADENSDIAGNOSE AN MASCHINENKOMPONENTEN

Die in Kapitel 4 vorgestellten Methoden zur Zustandsüberwachung von TriebstrangkompONENTEN in WEAs wie Lagern, Zahnrädern und Planetengetrieben, sollen die bisher angewendeten und von [GLWIND 2007] vorgeschlagenen Methoden zur Schadensfrüherkennung ergänzen. Die bisher verwendeten Kennzahlen und Analysen basieren meist auf Kurtosis-Werten, Krest-Faktoren, Frequenz-, Hüllkurvenspektren und Cepstren. Die Grundlagen dieser Methoden wurden bereits in Abschnitt 2.5 beschrieben. Auch aus der Überwachung des Ölzustandes können wichtige Informationen über den „Gesundheitszustand“ der Maschinenkomponenten gewonnen werden, allerdings erst in einem fortgeschrittenen Schädigungsstadium.

Im ersten Abschnitt dieses Kapitels wird die Zyklkohärenz-Methode und deren Vorteile für den Einsatz an langsam rotierenden Maschinen bei der Präsenz eines hohen Rauschniveaus erläutert. In einem nächsten Schritt wird eine Verbesserung der Ergebnisse der Zyklkohärenz mit Hilfe von Kurtogrammen vorgeschlagen. Diese Vorgehensweise offenbart, in welchem Frequenzanteil des Signals die Schädigungssignatur am deutlichsten vorkommt. In einem abschließenden Abschnitt wird die Zyklkohärenz-Methode für den Einsatz an drehzahlvariablen rotierenden Maschinen mit Hilfe der Ordnungsanalyse erweitert [KRAEMER *et al.* 2008].

### 4.1 ANWENDUNG DER ZYKLISCHEN KOHÄRENZ ZUR SCHADENSERKENNUNG

Die Zyklkohärenz-Methode in Kombination mit Signalvorverarbeitungsverfahren wird hier speziell für den Einsatz an Windenergieanlagen angepasst. Sie eignet sich hervorragend für die Identifikation von zyklisch auftretenden Stoßimpulsen infolge von Schäden bei den für den Betrieb von Windenergieanlagen spezifischen Bedingungen:

- Schlechtes Signal-zu-Rauschen-Verhältnis durch lange Übertragungswege zwischen den Sensoren und den zu überwachenden Maschinenkomponenten,
- Schlechte Anregung der überwachten Komponenten durch langsam rotierende Maschinenteile,
- Variation der Drehzahl der rotierenden Teile durch die Pitch-Steuerung.

Die in der Zyklkohärenz verwendeten Schadensmerkmale sind die gleichen, die bei den klassischen Methoden genutzt werden. Hierbei wird davon ausgegangen, dass sich Schäden als Stoßimpulse bemerkbar machen und diese im Frequenzbereich als Überrollfrequenzen



(Lager) oder Zahneingriffsfrequenzen (Zahnräder im Getriebe) auftreten. Durch den Vergleich der Peaks mit charakteristischen Schadensfrequenzen einzelner Komponenten einer Maschine kann daher eine Aussage über einen möglichen Schaden getroffen werden.

Die Zuordnung verschiedener Schwingungskomponenten eines Signals zu den charakteristischen Frequenzen der Maschinenkomponenten setzt die Kenntnis der Kinematik dieser zu überwachenden Komponenten voraus. Im Anhang A1.2 und A1.3 wird die Kinematik der Getriebekomponenten durch deren Geometrien und Drehfrequenzen bestimmt und die für die Zustandsüberwachung wichtigsten Zusammenhänge der einzelnen Maschinenteile erläutert.

Zyklostationäre Schwingungen weisen, wie der Name schon sagt, zyklisches Verhalten auf. Sie können als Unterklasse instationärer Signale angesehen werden. Allerdings werden manchmal auch zyklische, stationäre Signale als zyklostationär angesehen. Im strengen Sinne sind zyklostationäre Signale jedoch nicht stationär, obwohl die statistischen Kennwerte für Vielfache der Periodendauer jeweils gleich sind. Dies gilt für den Vergleich einzelner „Perioden“ jedoch nicht, da die statistischen Kennwerte zyklostationärer Signale hierbei variieren können. Allerdings können zyklostationäre Prozesse auch als eine Anreihung in geringem Maße unterschiedlicher, stationärer Prozesse gedeutet werden. Ein typisches Beispiel für ein zyklostationäres Signal sind Schwingungssignale von Maschinen, die einen Wälzlagerschaden aufweisen und dadurch immer wieder zyklische Impulse erzeugen. Dabei variieren die Impulsamplituden und die Zeit zwischen den Impulsen geringfügig.

Das zyklische Leistungsspektrum wird in dieser Arbeit zur Identifikation kleiner Lager- und Zahnradschäden bei langsam rotierenden Maschinen in WEAs und bei schlechtem Signal-zu-Rauschen-Verhältnis verwendet. Diese Methode nutzt die statistische Korrelation zwischen den Frequenzkomponenten des Signals [ANTONI 2007b], die um die Frequenz  $\alpha \neq 0$  verschoben werden. Um dieses Spektrum zu erhalten wird zuerst das zeitdiskrete Signal  $y$  fouriertransformiert und um die Frequenz  $\alpha$  verschoben:

$$Y_{n_t} \left( f \pm \frac{\alpha}{2} \right) = \sum_{k=1}^{n_t} y_k \cdot e^{\pm j\pi\alpha k / f_s} e^{-j2\pi f k / f_s} . \quad (4.1)$$

Berechnet man von diesen Fouriertransformierten die Autokorrelation über die Länge  $n_t$  des Signals [Antoni und Randall 2002], so erhält man nach dem Normieren mit dem Faktor  $1/n_t$  das so genannte zyklische Leistungsspektrum (Einheit: Signal-Einheit<sup>2</sup>/Hz) [ANTONI 2007b]:

$$S_{yy}(f; \alpha) = \lim_{n_t \rightarrow \infty} \frac{1}{n_t} E \left\{ Y_{n_t} \left( f + \frac{\alpha}{2} \right) \cdot Y_{n_t} \left( f - \frac{\alpha}{2} \right)^* \right\}. \quad (4.2)$$

Wird das zyklische Leistungsspektrum mit der Leistung des Signals normiert, so folgt daraus das zyklische Autokohärenzspektrum. Dieses wird im Weiteren der Einfachheit halber nur als zyklische Kohärenz bezeichnet:


$$|\gamma_{yy}(f; \alpha)|^2 = \frac{|S_{yy}(f; \alpha)|^2}{S_{yy} \left( f + \frac{\alpha}{2} \right) S_{yy} \left( f - \frac{\alpha}{2} \right)}. \quad (4.3)$$

Für zyklstationäre Signale nimmt die zyklische Kohärenz entlang der  $f$ -Achse immer einen kontinuierlichen Verlauf an, entlang der zyklischen Frequenz  $\alpha$  hingegen eine sprunghafte Form. Diese zyklische Kohärenz verhält sich wie ein Korrelationskoeffizient zwischen den spektralen Komponenten bei den Frequenzen  $f + \alpha/2$  und  $f - \alpha/2$ . Die Ergebnisse nehmen Werte zwischen 0 (keine spektrale Korrelation) und 1 (perfekter linearer Zusammenhang zwischen zwei spektralen Komponenten) an.

Aus [ANTONI 2007b] geht hervor, dass das Ergebnis der zyklischen Kohärenz eines schadensbehafteten Signals, wie es in Abbildung 4.1 dargestellt ist, auf folgende zwei Arten gedeutet werden kann:

- wenn man es als Funktion der Frequenz  $f$  liest, zeigt die zyklische Kohärenz auf, in welchem Frequenzbereich der Schaden am deutlichsten auftritt bzw. welche Strukturresonanzfrequenzen durch den Schaden angeregt werden.
- wenn man es als Funktion der zyklischen Frequenz  $\alpha$  liest, beschreibt die zyklische Kohärenz die Signatur des Schadens. Bei Kenntnis der Kinematik kann der Schaden so identifiziert werden.

Der Schaden geht also hierbei nicht aus dem  $f$ -Frequenzbereich hervor, sondern aus der  $\alpha$ -Frequenzdomäne. Die Höhe des Ausschlags gibt den Schadensfortschritt an, wobei dieser auch von anderen Faktoren abhängt, wie beispielsweise der Last, der Drehzahl und dem Einfluss anderer Maschinenkomponenten.



**Abbildung 4.1:** Zyklische Kohärenz am Beispiel eines Wälzlageraußenringschadens, nach [ANTONI 2007b]

Der Implementierung der zyklischen Kohärenz kommt eine wichtige Rolle zu. Die Schwierigkeit besteht darin, das zyklische Leistungsspektrum  $S(f; \alpha)$  eines Signals  $y$  der Länge  $n_t$ , das mit der Frequenz  $f_s$  abgetastet wurde genau genug abzuschätzen. Das abgeschätzte zyklische Leistungsspektrum wird  $\hat{S}^{(n_t)}(f; \alpha)$  genannt. Nach [ANTONI 2007b] lässt sich dieses über eine Zerlegung bzw. Fensterung des Signals  $y$  in mehrere kleine Segmente bestimmen. Die einzelnen Segmente sollten dabei überlappen. Dies ist eine in der Praxis häufig angewendete und effiziente Methode, die auch unter dem Namen Periodogramm bekannt ist. Über diese Methode erhält man die folgende Formel für das abgeschätzte/gemittelte zyklische Leistungsspektrum [ANTONI 2007b]:

$$\hat{S}^{(n_t)}(f; \alpha) = \frac{1}{K_w f_s \|w\|^2} \sum_{q=0}^{K_w-1} Y_{N_w}^{(q)}\left(f + \frac{\alpha}{2}\right) \cdot Y_{N_w}^{(q)*}\left(f - \frac{\alpha}{2}\right) \quad (4.4)$$

mit der  $q$ -ten diskreten Fouriertransformierten


$$Y_{N_w}^{(q)}\left(f \pm \frac{\alpha}{2}\right) = \sum_{k=qR}^{qR+N_w-1} (w_q)_k \cdot y_k \cdot e^{\pm j\pi\alpha k/f_s} e^{-j2\pi f k/f_s} \quad (4.5)$$

Dabei beschreibt  $w$  eine positive,  $N_w$  lange Fensterfunktion und  $(w_q)_k = w_{k-qR}$  entsprechend deren um  $R$  Abtast Schritte verschobene Variante. Dadurch wird mit dem Produkt  $(w_q)_k \cdot y_k$  jeweils das  $(qR), \dots, (qR+N_w-1)$ -te Segment von  $y$  gewählt. Das Inkrement  $R$  nimmt dabei Werte zwischen 1 und  $N_w$  an, so dass auch Überlappungen der Fenster möglich sind. Gl. (4.4) berücksichtigt bei der Mittelwertbildung aus den Teilspektren auch die vorgenommenen

Fensterfunktionen durch dem Effektivwert der Fensterfunktion  $\|w\|^2$ . Die Gesamtzahl an Fenstern und dadurch auch die Anzahl an gewählten Segmenten von  $y$  wird folgendermaßen bestimmt:

$$K_w = [(n_t - N_w) / R] + 1. \quad (4.6)$$

Der Ausdruck in den eckigen Klammern in Gl. (4.6) beschreibt die größte ganze Zahl kleiner oder gleich  $(n_t - N_w) / R$ . Die Fensterung des Signals wird in der Abbildung 4.2 verdeutlicht.



**Abbildung 4.2:** Vorgehensweise bei der numerischen Implementierung des zyklischen Leistungsdichtespektrums [ANTONI 2007b]

Dabei muss die folgende Forderung für die Fensterfunktion erfüllt sein:

$$\sum_{k=-\infty}^{+\infty} (w_q)_k^2 = C. \quad (4.7)$$

Die Fenster müssen quadriert und addiert eine Konstante  $C$  ergeben. Daher müssen Fensterfunktion und insbesondere die notwendige Überlappung entsprechend ausgewählt

werden, vgl. Abbildung 4.2. Wird diese Forderung nicht erfüllt, kann es passieren, dass die Schätzungsfunktion  $\hat{S}^{(n_t)}(f; \alpha)$  für nicht-zyklische Frequenzen Werte ungleich Null wiedergibt. Diesen Effekt bezeichnet man als zyklische Leckage. Typische Konfigurationen, die diese Forderung sicherstellen, sind [ANTONI 2007b]:

- Hann-Fenster, welche zu 2/3 überlappen,
- halbe Sinusfenster, die zur Hälfte überlappen.

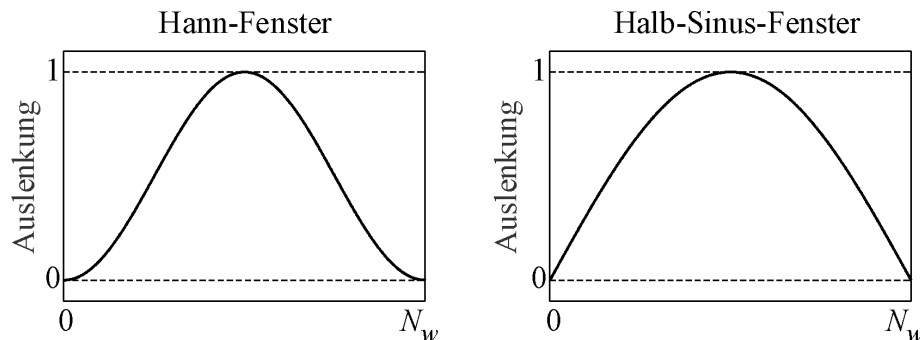


Abbildung 4.3: Fensterfunktionen

Je kleiner das Fenster gewählt wird und folglich das Ausgangssignal in mehr Segmente zerteilt wird, umso größer wird die Frequenzauflösung  $\Delta f$  auf der  $f$ -Achse:

$$\Delta f = \frac{\sum_{k=0}^{N_w-1} w_k^2}{\left| \sum_{k=0}^{N_w-1} w_k \right|^2} f_s. \quad (4.8)$$

Eine grobe Auflösung ist nach [ANTONI 2007b] aus zwei Gründen sinnvoll:

- das Verhältnis der Auflösung der  $\alpha$ -Achse zur Auflösung der  $f$ -Achse sollte möglichst klein sein ( $\Delta \alpha \ll \Delta f$ ), so dass die zyklischen Leistungsdichten auf der  $\alpha$ -Achse sprunghaft erscheinen,
- um den Rechenaufwand so gering wie möglich zu halten.

Üblicherweise sollte ein Verhältnis der Auflösungen  $\Delta f / \Delta \alpha \approx 100$  gewählt werden [ANTONI 2007b]. Die Auflösung der  $\alpha$ -Frequenz sollte dabei laut [ANTONI 2007a] nicht größer sein als:

$$\Delta \alpha = \frac{f_s}{n_t}. \quad (4.9)$$

Ansonsten können zyklische Informationen verloren gehen. Die Auflösung der  $\alpha$ -Frequenz ist also in hohem Maße von der gewählten Länge  $n_t$  des Signals abhängig.

## 4.2 VERBESSERUNG DER ERGEBNISSE DER ZYKLISCHEN KOHÄRENZ MIT HILFE VON KURTOGRAMMEN

Deutlich vorkommende Schäden sind in dem zyklischen Kohärenzspektrum entlang der kompletten  $\alpha$ -Frequenz-Achse gut sichtbar. Sind die Schadensimpulse relativ klein im Vergleich zu den gemessenen Signalen, sollten aus der  $\alpha$ -Perspektive die Schadensfrequenzen in demjenigen  $f$ -Frequenz-Bereich betrachtet werden, in dem diese am besten zum Vorschein kommen (z.B. in der Nähe von Resonanzfrequenzen der Maschine).

Um den Frequenzbereich zu finden, in dem gerade eine Schadensfrequenz am deutlichsten vorkommt, wird von der spektralen Kurtosis ( $SK$ ) Gebrauch gemacht, siehe Abschnitt 2.5.4. Zuerst wird die Kurtosis einzelner Frequenzkomponenten in folgender Form abgeschätzt [VRABIE *et al.* 2003]:

$$\hat{K}_y(f) = \frac{K_w}{K_w - 1} \left[ \frac{(K_w + 1) \sum_{i=1}^{K_w} |Y_i(f)|^4}{\left( \sum_{i=1}^{K_w} |Y_i(f)|^2 \right)^2} - 2 \right]. \quad (4.10)$$

Dabei beschreibt  $K_w$  die Anzahl der Fenster. Ein weiterer Schritt der Vorgehensweise in [ANTONI und RANDALL 2004a] und [ANTONI und RANDALL 2004b] ist die Unterteilung des Zeitsignals in unterschiedlich große Fenster (wie bei der zyklischen Kohärenz, siehe Abschnitt 4.1) und die Berechnung der spektralen Kurtosis über diese Fenster. Die Vorgehensweise lässt sich für eine einzige Fensterlänge in den folgenden Schritten zusammenfassen:

- Anwendung des Fensters auf das Signal (Fensterung),
- Berechnung der Fouriertransformierten jedes Fensters,
- Ermittlung von  $|Y_i(f)|^2$  und  $|Y_i(f)|^4$  für jedes Fenster  $i$ ,
- Berechnung der spektralen Kurtosiswerte einzelner Frequenzkomponenten und Normierung der  $SK$  mit der Anzahl der Fenster.

Als Fenstertyp wird ein Hann-Fenster verwendet, wobei sich die Fenster um 75 % überlappen sollten. Das Resultat dieser Vorgehensweise ist die spektrale Kurtosis mit einer Frequenzauflösung entsprechend der Länge der Fenster. Je größer das Fenster gewählt wird, desto genauer wird auch die Auflösung der spektralen Kurtosis. Dabei sollte jedoch beachtet werden, dass die Fenstergröße in Abhängigkeit des Signals gewählt werden sollte:

- ist das Fenster zu lang, verschwimmt die spektrale Kurtosis aufgrund der Instationarität des Signals,
- ist die Fensterlänge hingegen zu kurz, ist die Frequenzauflösung sehr schlecht.

Aus diesem Grund wird in [ANTONI und RANDALL 2004a] vorgeschlagen, die spektrale Kurtosis mit mehreren verschiedenen Fensterlängen systematisch zu berechnen und die Ergebnisse über der Frequenz in einem sogenannten Kurtogramm darzustellen (vgl. Abbildung 4.4). Hieraus wird deutlich, bei welcher Fensterlänge und Frequenz die höchste spektrale Kurtosis aus dem Signal hervorgeht. Daraus kann man schließen, dass bei dieser Konfiguration die Spitzhaltigkeit des Signals am besten deutlich wird und damit die Stoßimpulse, z.B. durch einen Schaden, optimal zum Vorschein treten.

Der Frequenzbereich mit der höchsten spektralen Kurtosis kann jetzt als  $f$ -Frequenz-Bereich für die Betrachtung der zyklischen Kohärenz verwendet werden, um die Schadensfrequenzen besser beobachten zu können.

Die Werte für Frequenz und Fensterlänge können auch benutzt werden um das Signal mit einem Bandpass zu filtern, um dieses anschließend mit den klassischen Methoden, wie z.B. dem Leistungsdichtespektrum, zu analysieren. Die Mittenfrequenz des Bandpasses und dessen optimale Breite, die über die Fensterlänge berechnet werden kann, werden vom Maximum des Kurtogramms abgelesen. Der Bandpassfilter wird dann mit einem normierten Hann-Fenster (vgl. Abbildung 4.3) mit der ermittelten optimalen Fensterlänge entworfen [ANTONI und RANDALL 2004a]. Den empirisch gewonnenen Zusammenhang zwischen der Fensterlänge  $N_w$  und der Breite des Frequenzbandpasses  $f_{band}$  liefert Gl. (4.11):

$$f_{band} \approx \frac{4 \cdot f_s}{N_w}. \quad (4.11)$$

Ein Beispiel zur Anwendung von Kurtogrammen zur Identifikation von gut angeregten Frequenzbereichen in Signalen ist in Abbildung 4.4 dargestellt. Hier wird ein Beschleunigungssignal einer beschädigten einstufigen Stirnradverzahnung mit 20 kHz abgetastet. Die Zahneingriffsfrequenz ist 2,27 Hz, diese repräsentiert hier die Schadensfrequenz des langsam drehenden Getriebes. Eine Resonanzfrequenz des Gesamtsystems liegt bei ca. 4000Hz. In Abbildung 4.4 lässt sich erkennen, dass die Schadensfrequenz im ursprünglichen Signal durch lange Übertragungswege und ein schlechtes Signal-zu-Rauschen Verhältnis im Zeitbereich nicht sichtbar ist. Das Kurtogramm in Abbildung 4.4 zeigt den größten Peak wie erwartet um die 4000 Hz und bei einer Fensterlänge von 64 Abtastschritten. Diese Werte werden zur Bandpassfilterung angewendet. In dem so gefilterten Signal sind die Schadenspeaks deutlicher zu erkennen. Es sei hier noch angemerkt, dass die erste „Zeile“ des Kurtogramms die Kurtosis  $\kappa_y$  aus Gl. (2.131) darstellt.

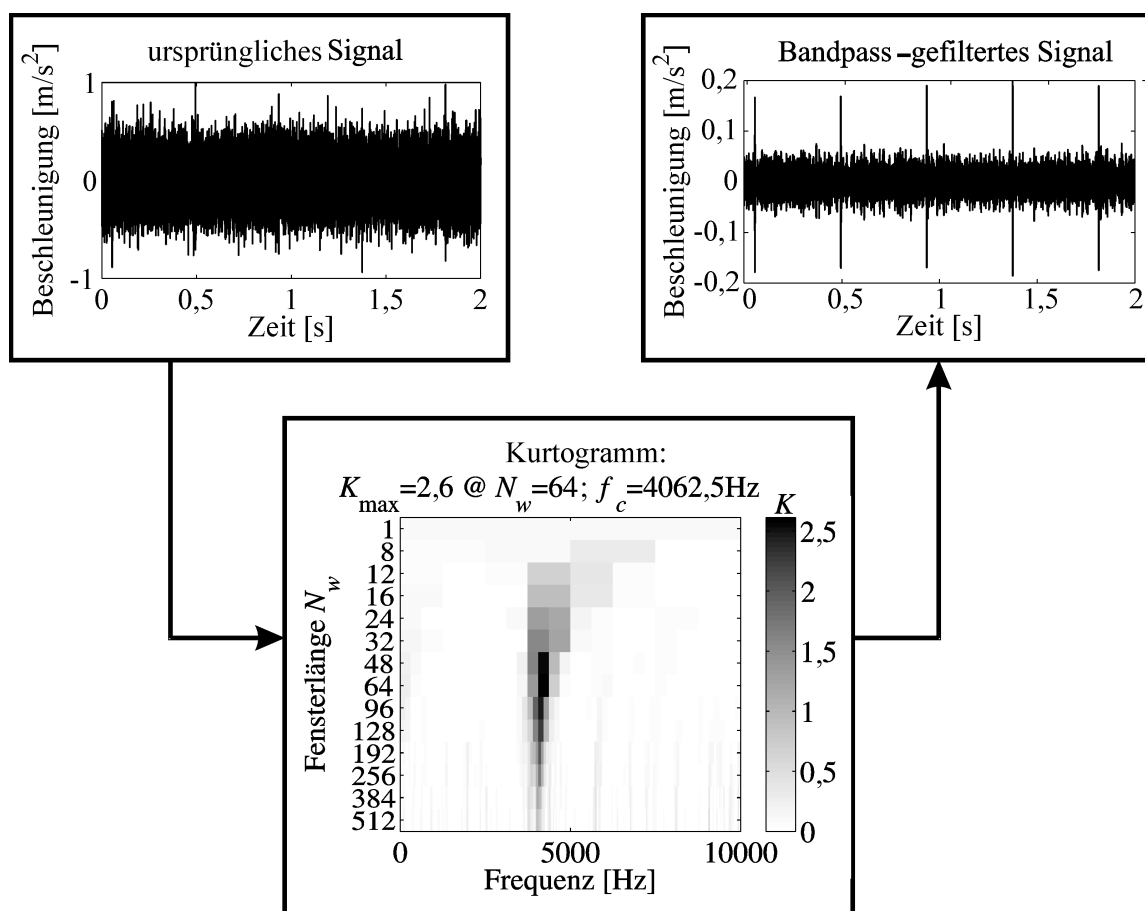


Abbildung 4.4: Beispielhafte Bandpassfilterung mittels Kurtogramm

Die Anregungsfrequenz könnte auch direkt aus der  $f$ -Achse- und die Schadenfrequenz aus der  $\alpha$ -Achse-Perspektive des Zyklkohärenzspektrums abgelesen werden, siehe Abbildung 4.5, links. Um eine automatische Verbesserung der Visualisierung des Schadens zu erzielen, kann die Aussage des Kurtogramms gezielt genutzt und dadurch nur der interessante  $f$ -Frequenz-Bereich betrachtet werden. Ein mit Hilfe des Kurtogramms der Abbildung 4.4 „bereinigtes“ Spektrum ist in Abbildung 4.5, rechts dargestellt.

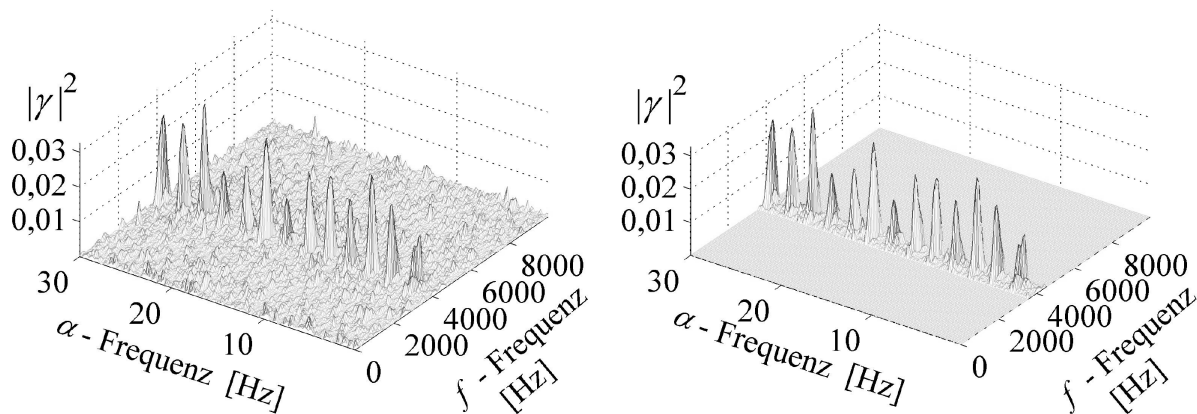


Abbildung 4.5: Zyklkohärenzspektrum (links); Verbesserung des Zyklkohärenzspektrums mittels Kurtogramm (rechts)



### 4.3 ERWEITERUNG DER ZYKLISCHEN KOHÄRENZ ZUR ANWENDUNG AN PITCHGESTEUERTEN ANLAGEN - ORDNUNGSANALYSE

Insbesondere bei moderneren Windenergieanlagen mit Pitch-Steuerung kommen oft Drehzahlschwankungen der Maschinenkomponenten vor. Dadurch variieren auch die Schadensfrequenzen, was ein „Verschmieren“ oder „Verzerren“ der Spektren zur Folge hat.

Um dies zu vermeiden und dadurch die Diagnosezuverlässigkeit trotz Drehzahlschwankungen während der Messzeit nicht zu beeinträchtigen, wird das digitale Order-Tracking eingeführt. Einzige Voraussetzung hierfür ist, dass parallel zum Beschleunigungssignal auch Drehzahlinformationen mit aufgezeichnet werden. Das aufgenommene Beschleunigungssignal wird dann rechnerisch so manipuliert, dass aus dem zeitbezogenen Signal ein neues, drehzahlbezogenes Signal entsteht (siehe Abbildung 4.6).





Abbildung 4.6: Zeitbezogenes (links) und nach Interpolation drehzahlbezogenes Signal (rechts)

Dazu wird das Signal auf die Drehwinkelinkremente anstatt auf die Zeitinkremente bezogen. Liegt ein Drehwinkelinkrement zwischen zwei Zeitinkrementen, so muss der dazugehörige Amplitudenwert über die zwei Amplitudenwerte der beiden Zeitinkremente interpoliert werden. Die Interpolation kann auf viele verschiedene Arten geschehen. In dieser Arbeit wird sie kubisch durchgeführt, da dies einen guten Kompromiss zwischen Genauigkeit und Rechenaufwand darstellt. Durch die Interpolation kann es allerdings auch passieren, dass auftretende Impulse abgeschwächt werden. Dieser Effekt kommt jedoch bei hoch abgetasteten Signalen kaum vor.

Das Order-Tracking wird anhand eines simulierten Signals verdeutlicht. Dabei handelt es sich um ein Sinussignal, dessen Frequenzinhalt mit der Zeit zwischen 75 und 85 Hz schwankt. Die Amplitude des Leistungsdichtespektrums des „drehzahlfluktuierenden“ Signals (siehe Abbildung 4.7, links) beträgt ca. ein Fünftel der Amplitude des mit dem Order-Tracking

bearbeiteten Signals (siehe Abbildung 4.7, rechts). Dieser Befund lässt sich leicht erklären: Da beide Signale dieselbe Leistung haben, wird diese bei dem drehzahlfluktuiierenden Signal auf mehrere Frequenzen verteilt, beim drehzahlkonstanten Signal hingegen erscheint die komplette Leistung bei einer einzigen Frequenz (80 Hz).



**Abbildung 4.7: Leistungsdichte eines Signals mit Drehzahlfluktuation vor (links) und nach der Order-Tracking (rechts)**

Die Vorteile der hier vorgestellten Methoden gegenüber den bisher angewendeten Ansätzen werden in Abschnitt 5.2 anhand unterschiedlicher Schadensfälle an Maschinenkomponenten von Windenergieanlagen erläutert.

## 5 ANWENDUNGSBEISPIELE

Die in den vorangegangenen Kapiteln erarbeiteten Ansätze zur Schadens- bzw. Sensorfehlerdiagnose werden getrennt mit Hilfe unterschiedlicher Beispiele für die Struktur- und Maschinenkomponenten erläutert.

### 5.1 SCHADENS- UND SENSORFEHLERERKENNUNG AN STRUKTURKOMPONENTEN

Das erste Anwendungsbeispiel befasst sich mit der Schadens- und Sensorfehlererkennung an einer Laborstruktur, die ein Modell einer OWEA darstellt. In einem nächsten Schritt werden die Methoden aus Kapitel 3 zur Überwachung des OWEA-Prototyps M5000-2 eingesetzt. Hierbei handelt es sich um die Untersuchung des Schwingungsverhaltens der Anlage mit Hilfe einer automatischen *Output-Only* modalen Analyse, Sensorfehlererkennung und Schadenserkennung anhand der gemessenen Zeitdaten oder anhand von Simulationsmodellen der Anlage. Im letzten Teil des Abschnitts 5.1 wird die modellgestützte Schadenslokalisationsmethode zur Identifikation mehrerer gleichzeitig auftretender Schäden an der sog. *Steelquake*-Struktur eingesetzt [MOLINA *et al.* 2003].

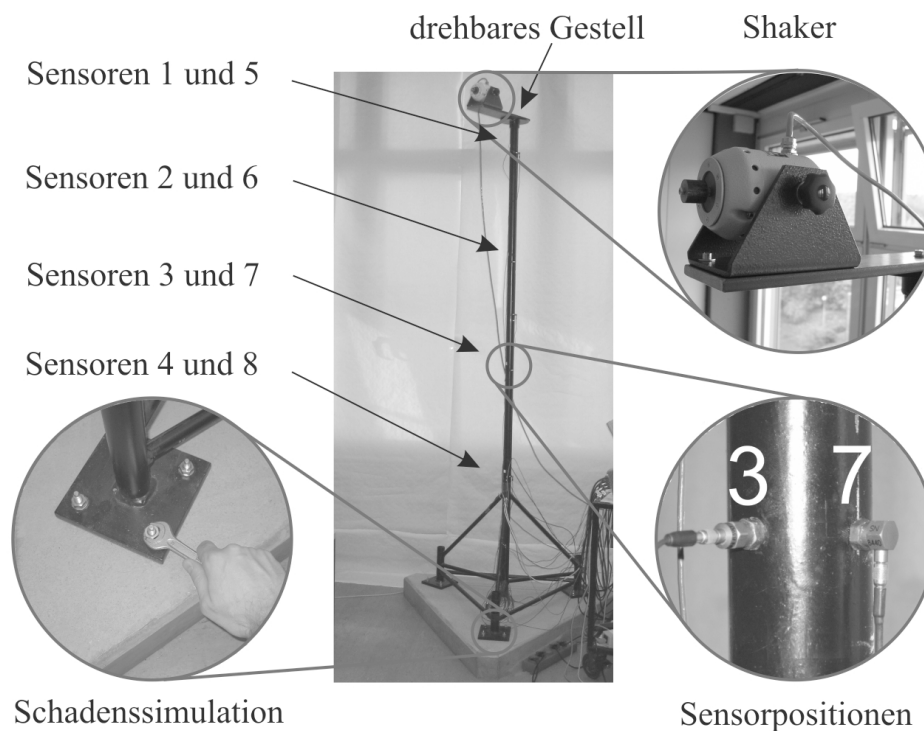
#### 5.1.1 Laborstruktur mit Tripodscha-den

Anhand der Laborstruktur aus Abbildung 5.1 werden zunächst prinzipiell die Effekte der EOC auf die Schadensindikatoren erläutert und einige in der Arbeit vorgestellte Möglichkeiten der Schadenserkennung unter Beachtung der EOC-Einflüsse dargestellt.

Die Laborstruktur ist eine 2,5 m hohe Stahlkonstruktion, die aus einem vertikalen Rohr (simuliert den Turm einer OWEA) und einem Tripod besteht. Der Tripod ist kraftschlüssig mittels Schraubverbindungen in einer Betonplatte verankert. Die Struktur wird über einen *Shaker*, der auf einem drehbaren Gestell auf dem Turmkopf sitzt, in stochastische Schwingungen versetzt. Die Anregungssignale werden bis auf 500 Hz tiefpassgefiltert.

##### 5.1.1.1 Schadensdetektion

Die Strukturantwort wird mit Hilfe von acht Beschleunigungsaufnehmern aufgenommen, die jeweils paarweise an vier Stellen auf dem Turm positioniert sind. Jede Messstelle besteht aus zwei Sensoren, die orthogonal zueinander stehen. Die Messdaten werden simultan bei einer Abtastrate von 4800 Hz aufgenommen. Die Messdauer für einen Datensatz beträgt 20 Sekunden. Die ersten 90 Datensätze sind an der unbeschädigten Struktur gemessen.



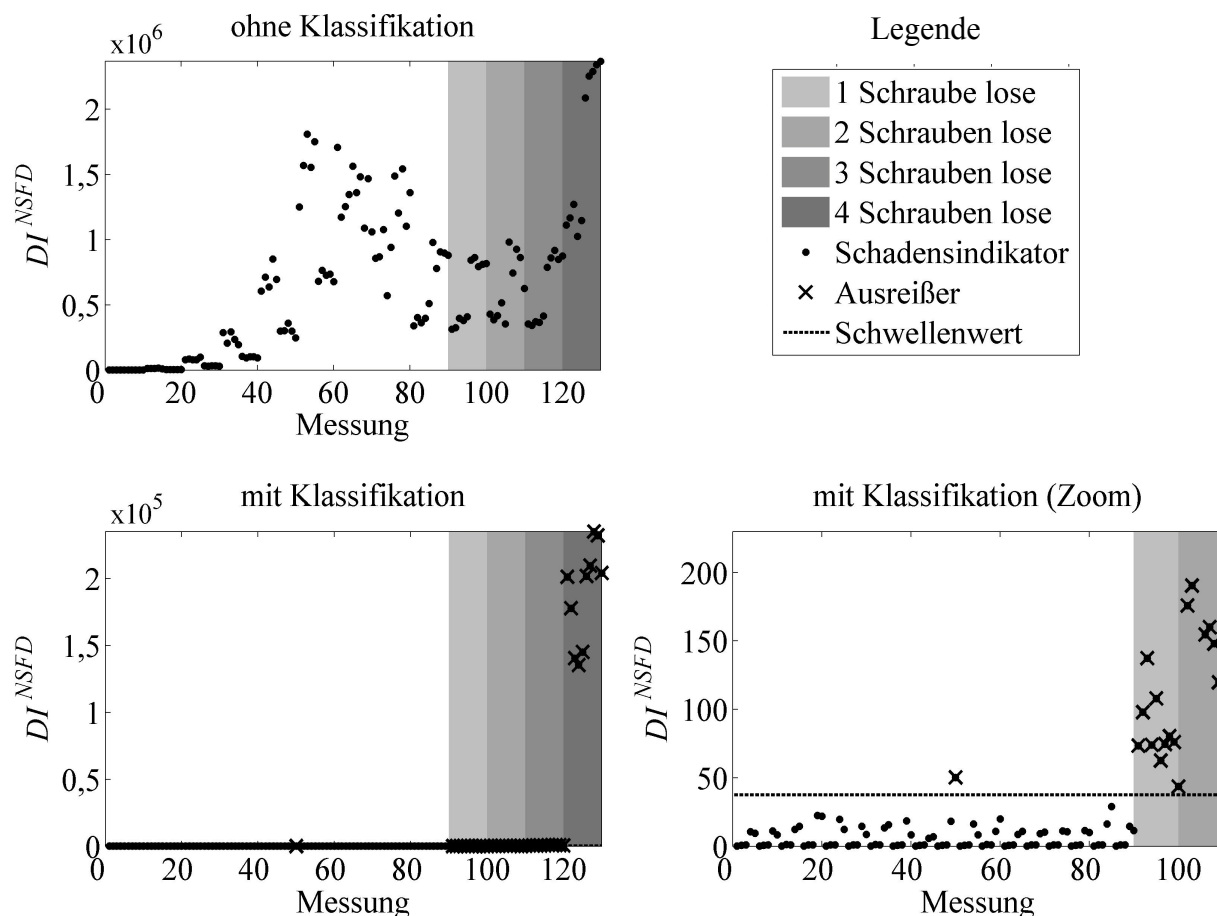
**Abbildung 5.1: Laborstruktur**

Nach jeder fünften Messung wird entweder die Position des Shakers auf dem Turm (Simulation der Gondelposition) oder die Leistung im Anregungssignal (Simulation der Kraft aus dem Wind) geändert. Insgesamt ergeben sich 18 unterschiedliche Betriebszustände<sup>1</sup>. An der geschädigten Struktur werden 40 Messungen bei gleichzeitiger Veränderung der Leistung des Anregungssignals nach jeder fünften Messung durchgeführt. Ein Schaden lässt sich durch das Lösen von einer, zwei, drei oder vier Schrauben an einem Tripodbein simulieren. Diese vier Schädigungsstufen stellen einen Steifigkeitsverlust in der Tripod-Boden-Verbindung unterhalb der Wasseroberfläche dar, wo keine Sensoren positioniert sind.

Der obere Teil der Abbildung 5.2 zeigt die Ergebnisse einer Schadensidentifikation mit Hilfe der NSFD-Methode, angewendet mit einer einzigen Referenz nach Gl. (3.14). Hierbei wird deutlich, dass unter Umständen die Effekte der EOC auf die Indikatoren viel größer als die Auswirkung von Schäden sind. Der untere Teil von Abbildung 5.2 stellt die Ergebnisse des NSFD-Ansatzes in Kombination mit Klassifikationsverfahren dar. Hierbei werden die Indikatoren mit Hilfe der dazugehörigen 18 Klassenzentren berechnet. Da in dieser Versuchsreihe die Messdaten in einer Klasse unter gleichen Bedingungen aufgenommen sind, zeigt die Anwendung der *k-means* und *fuzzy-k-means* (siehe Abschnitt 3.3.3) in Kombination mit der

<sup>1</sup> Kombination aus neun unterschiedlichen Positionen des *Shakers* und zwei unterschiedlichen Anregungssignalen.

NSFD-Methode das gleiche Ergebnis<sup>1</sup>. Die Festlegung des Schwellenwertes erfolgt durch die Anpassung einer FRECHET-Verteilung an die ersten 50 Indikatoren für ein Konfidenzintervall von  $\alpha = 0,01$ , siehe dafür auch Abschnitt 3.3.2.3. Die Ergebnisse zeigen, dass prinzipiell durch die Anwendung geeigneter Referenzen auch kleinste Schäden, wie das Lösen einer Schraube im Tripodbereich, deutlich detektiert werden können (vgl. Abbildung 5.2, unten rechts).




**Abbildung 5.2:** Einfluss der Klassifikation auf die Schädigungsindikatoren der NSFD-Methode (oben ohne Klassifikation, unten mit Klassifikation); Vergrößerung zur Visualisierung der Indikatoren für die Schadensstufe 1 und 2 (rechts)

Die Anwendung einer einzigen gemittelten Hankelmatrix aus allen EOCs der Struktur, siehe Gl. (3.16), zur Berechnung aller Schadensindikatoren zeigt erwartungsgemäß weniger gute Ergebnisse. Der Grund liegt darin, dass hier nur ein gemittelter EOC-Zustand zum Nachteil der EOC-Extremzustände verwendet wird. Diese Vorgehensweise entspricht einer *Fuzzy*-Klassifikation, in der alle Referenzen für alle Daten mit  $1/c$  gewichtet sind ( $c$  ist die Anzahl


<sup>1</sup> Die nächste Referenz zu einem Datensatz wird mit Eins und alle anderen mit Null gewichtet. Aus diesem Grund geht der *fuzzy-k-means*- in den *kmeans*-Algorithmus über.

aller Klassen). Dadurch lassen sich im vorliegenden Fall nur größere Schäden, verursacht durch drei und vier lose Schrauben, deutlich detektieren.




**Abbildung 5.3:** Berechnung der Schädigungsindikatoren der NSFD-Methode mit Hilfe einer gemittelten Hankelmatrix (links); Vergrößerung zur Visualisierung der Indikatoren für die Schadensstufe 1 bis 3 (rechts)

Die Ergebnisse der Anwendung der Residuen aus ARV-Modellen zur Schadenserkenkung auf die Messdaten der Laborstruktur zeigt Abbildung 5.4. Die Modellordnung legt das Ergebnis einer Modalanalyse mit ARV-Modellen fest, siehe Abschnitt 3.4.1, wobei eine Modellordnung von  $p = 80$  die Dynamik der Struktur gut wiedergibt. Das FPE-Kriterium aus Gl. (2.53) bestätigt auch diese Auswahl der Modellordnung. Der  $M$ -Wert von BOX wird nach Gl. (3.29) berechnet und der Schwellenwert für  $\alpha = 0,05$  *a priori* aus der Dimension der Residuen für  $g=2$  festgelegt, vgl. Gl. (3.34). Nach der Anwendung der Klassifikation in Kombination mit den Schadensindikatoren, werden alle vier Schadensstufen korrekt identifiziert.



**Abbildung 5.4:** Schädigungsindikatoren aus Residuen von ARV-Modellen (links); Vergrößerung zur Visualisierung der Indikatoren für die Schadensstufe 1 und 2 (rechts)

Für die Anwendung der PCA bzw. NLPCA werden die ersten fünf AR- und MA-Koeffizienten eines ARMA(150,150)-Modells der gemessenen Beschleunigungen als schadensensitive Merkmale genutzt, siehe Gl. (3.1) und (3.2). Die Koeffizienten und die Mahalanobis-Abstände zwischen den berechneten und den geschätzten Koeffizienten nach der Achsentransformation auf die ersten drei Hauptkomponenten (siehe auch Abbildung 5.5, rechts) lassen sich nach Gl. (3.4) für alle Sensorkanäle separat ermitteln. Der Schädigungsindikator berechnet sich nun aus den gemittelten Mahalanobis-Abständen. Die Festlegung des Schwellenwertes nach dem F-Test aus Gl. (3.60) erfolgt anhand der ersten 50 Abstände für ein Konfidenzintervall von  $\alpha = 0,05$ . Abbildung 5.5, links, zeigt die Ergebnisse der EOC-Kompensation mit Hilfe der PCA und den deutlichen Unterschied zwischen dem ungeschädigten Zustand und dem Strukturzustand bei vier losen Schrauben. Die Identifikation kleinerer Strukturveränderungen, die sich auch in Frequenzspektrum kaum zeigen, ist, wie schon im Abschnitt 3.3.2.2 angedeutet, mit wenigen ARMA-Koeffizienten nicht möglich.



**Abbildung 5.5: Schädigungsindikatoren aus ARMA Koeffizienten und Kompensation der EOC-Einflüsse mit PCA (links); Bedeutsamkeit der Hauptkomponenten (rechts)**

Die Sensitivität der hier vorgestellten Methoden zur Entdeckung kleiner Strukturschäden kann auch durch Darstellung der Leistungsdichtespektren für die dritte und vierte Schädigungsstufe in Abbildung 5.6, links bzw. rechts, erläutert werden. In Abbildung 5.6, links, ist noch keine Frequenzverschiebungen infolge einer Steifigkeitsverminderung durch drei gelöste Schrauben erkennbar.




Abbildung 5.6: Leistungsdichtespektrum des Sensors 1; Vergleich des ungeschädigten Zustandes mit dem Zustand bei drei (links) und vier gelösten Schrauben (rechts)

### 5.1.1.2 Sensorfehleridentifikation

Ein Test der Algorithmen zur Sensorfehleridentifikation und Signalrekonstruktion erfolgt mit Hilfe der Sensoren eins bis vier aus der Abbildung 5.1. Die Anregung erfolgt hier ausschließlich in Messrichtung dieser Sensoren. Gemessen werden drei Messdatensätze bei einer Messdauer von jeweils einer Minute. Der erste Datensatz repräsentiert den Referenzzustand und die anderen zwei sind Testdatensätze mit Sensorfehlern. Der erste Testdatensatz beinhaltet einen simulierten und der zweite Testdatensatz einen realen Sensorfehler. Alle Signale sind bis auf die ersten drei Eigenmoden der Struktur gefiltert.

Zur Validierung der Methode wird zuerst das Signal des Sensors 2 im zweiten Testdatensatz verrauscht ( $\text{SNR}=2$ ) und der Erwartungswert des Signals verschoben. Dadurch lässt sich eine Veränderung der Kopplung zwischen dem Sensor und der Struktur, charakterisiert durch gleichzeitigen Bias, Drift und Präzisionsverminderung, simulieren. Das so gestörte Signal von Sensor 2 ist in Abbildung 5.8 dargestellt (gemessenes Signal).

Die Abbildung 5.7, links, stellt das Ergebnis der Sensorfehlerisolierung nach dem *Mutual Information* - Ansatz in Gl. (3.125) dar. Die MI-Kombinationen zwischen dem Sensor zwei und allen anderen Sensoren zeigen eine Veränderung der gegenseitigen Information zwischen dem Referenz- und dem Testzustand. Verständlicherweise zeigt die Kombination mit dem Sensor 4 eine geringere Veränderung der *MI*. Dieses Verhalten erklärt sich durch das schlechte Signal-zu-Rauschen-Verhältnis in allen Messdatensätzen des Sensors 4, bedingt durch die Position dieses Sensors an der Einspannung des Turms in dem steifen Tripod, an dem die Beschleunigungswerte sehr gering sind.



Die Anwendung der Sensorfehleridentifikation mit dem Kalman-Filter-Ansatz ist in Abbildung 5.7, rechts, dargestellt. Hierfür werden keine Referenzmessdaten benötigt, da ein FE-Modell der Struktur als „Referenz“ dient. Die Ergebnisse zeigen, dass die beste Rekonstruktion der Signale dann möglich ist, wenn der „beschädigte“ Sensor 2 nicht an der Berechnung der Kullback-Leibler-Abstände aus Gl. (3.138) beteiligt ist.




Abbildung 5.7: Sensorfehlerisolation mit dem MI- (links) und dem Kalman-Filter-Ansatz (rechts)

Die Signalrekonstruktion für den geschädigten Sensor im Testdatensatz ist in Abbildung 5.8 dargestellt. Hierbei erkennt man, dass das rekonstruierte Signal keinen Bias und keine Drift mehr aufweist und gut mit dem ursprünglichen Signal übereinstimmt, aus dem es generiert wurde.

Wie schon erwähnt, wird in dem zweiten Testdatensatz ein realer Sensorfehler durch die Änderung der adhäsiven Verbindung zwischen dem Sensor 2 und der Struktur generiert. Die fehlerhafte Verbindung wird durch eine Klebmasse realisiert, die zusätzlich zur normalen Verbindung zwischen Sensor und Struktur eingebracht ist, siehe Abbildung 5.9.



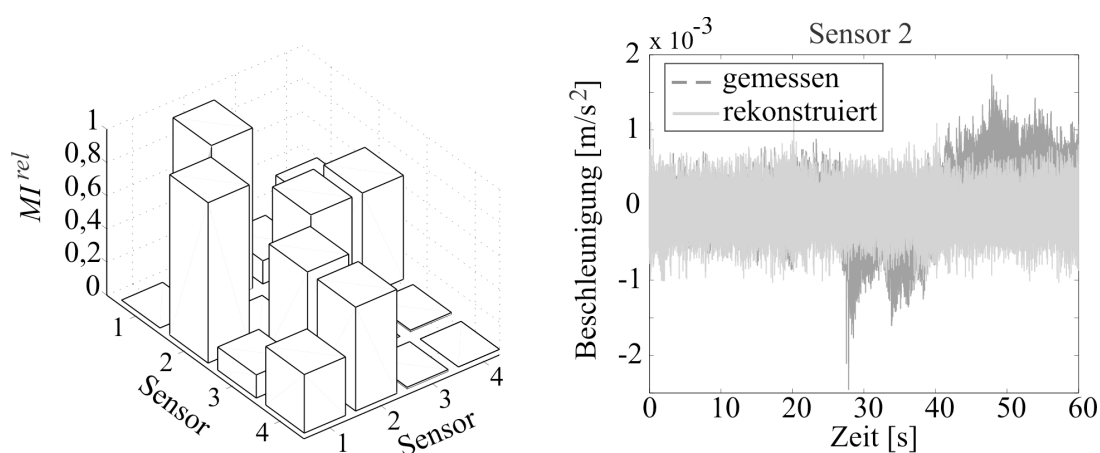


Abbildung 5.8: Anwendung von KF zur Signalkorrektur auf künstlich verrauschte Daten



**Abbildung 5.9: Veränderung der Kopplung zwischen Sensor 2 und Struktur mit Hilfe einer Klebemasse**

Die Änderung der Verbindung verursacht ein starkes Abdriften des gemessenen Signals 2. Der fehlerhafte Sensor kann, wie in Abbildung 5.10 dargestellt, mit dem MI-Ansatz isoliert werden. Das mit Hilfe des Kalman-Filters korrigierte Signal weist keinen Driftfehler mehr auf.




**Abbildung 5.10: Ergebnisse der Sensorfehlerdetektion und Signalkorrektur bei dem gemessenen Signal**

### 5.1.2 Langzeitüberwachung der OWEA M5000-2

Die in dieser Arbeit vorgestellten Techniken zur Überwachung der Strukturintegrität und Funktionalität der Sensoren wurden über ein Jahr lang an der Anlage M5000-2 der Fa. AREVA-Multibrid getestet, siehe Abbildung 5.11, links. Von insgesamt 167 Sensoren, eingesetzt zu *Monitoring* und *Design*-Zwecken der Anlage, sind insbesondere acht Beschleunigungsaufnehmer ( $y_1$  bis  $y_8$ ) zur Überwachung des Turms genutzt, siehe Abbildung 5.11, rechts. Weitere Beschleunigungsaufnehmer, positioniert auf dem Tripod und somit unterhalb der virtuellen Wasseroberfläche, werden nicht zur Überwachung verwendet. Während der gesamten Überwachungszeit zeigten diese Sensoren ein schlechtes Signal-zu-Rauschen-Verhältnis und funktionierten nicht immer zuverlässig. Zwei dieser Sensoren werden später jedoch zur Validierung der Sensorfehlererkennungsalgorithmus eingesetzt.

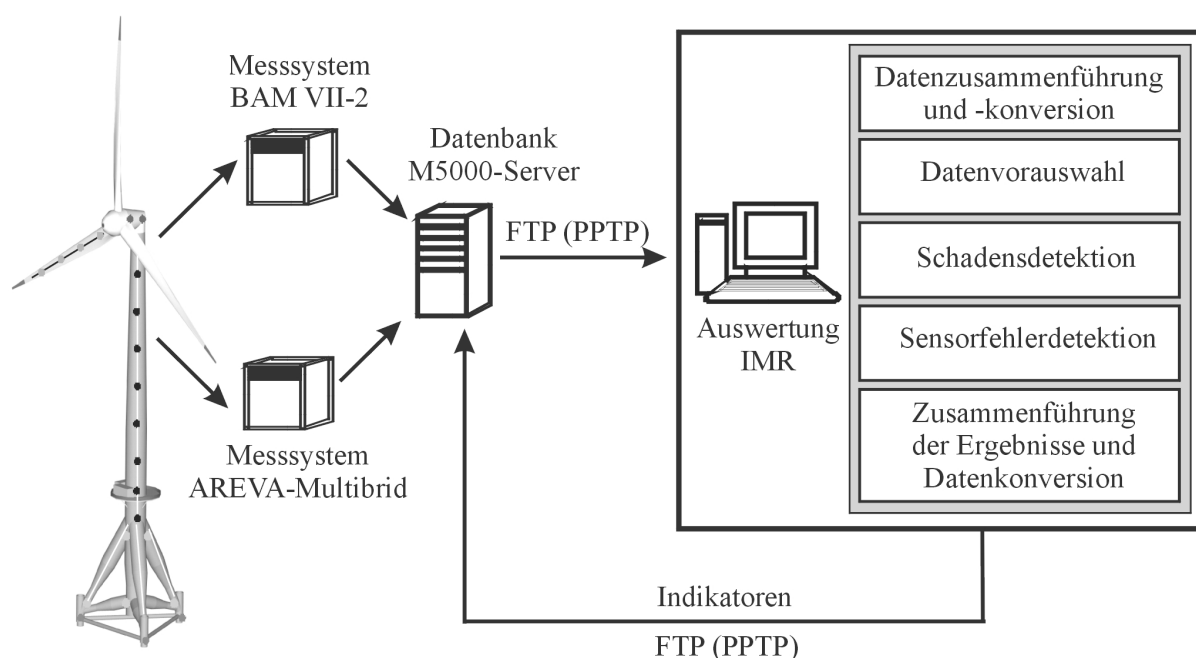
Die Beschleunigungen wurden synchron mit 50 Hz abgetastet und die Messdauer pro Datensatz betrug 10 Minuten. Die Aufzeichnung erfolgte in demjenigen Zeitraum von 10 Minuten innerhalb einer Stunde, in dem die maximale Beschleunigung auftrat. Damit hat man vermieden, dass Daten bei schlechter Anregung der Struktur gemessen werden. Parallel zu den Beschleunigungen wurde auch eine Reihe von EOCs bei einer Abtastrate von 10 Hz gemessen, wie z.B. die Rotordrehzahl, die Außentemperatur, die Windgeschwindigkeit, die relative Windrichtung zur Gondel, die Gondelposition und der Pitchwinkel. Somit ergaben sich während der Messkampagne 8759 Datensätze mit simultan gemessenen Beschleunigungen und EOCs.



**Abbildung 5.11: 5MW Prototyp OWEA M5000-2 der Fa. AREVA-Multibrid im Bremerhaven (links) und Positionen der Beschleunigungsaufnehmern (rechts)**

Die Auswertung der Daten geschah *online* in einem automatischen Modus. Hierbei wurden zuerst die gemessenen Beschleunigungen, aufgenommen von einem Messrechner der Bundesanstalt für Materialforschung und -prüfung (BAM), und die EOCs, gemessen von der Fa. AREVA-Multibrid, auf einer Datenbank der M5000-2 angelegt. In einem nächsten Schritt erfolgte der Datentransfer zum Datenauswertesystem via Internet über ein *Point-to-Point Tunneling Protokoll* (PPTP). Nach der Konversion der Daten konnten diese mit Hilfe der Ausreißeranalyse auf die Eignung zur Schadens- und Sensorfehlererkennung überprüft werden. Die Daten, die sich als geeignet herausgestellt haben, wurden zur Überwachung genutzt und die daraus entstandenen Indikatoren in einem geeigneten Format zurück zur Anlagendatenbank transferiert. Diese Indikatoren ermöglichten dem Anlagenbetreiber einen

Einblick in den Zustand der Anlage und Sensorik. Das Transfer- und Auswertungssystem ist schematisch in Abbildung 5.12 dargestellt.



**Abbildung 5.12: Online-Datenauswertungssystem**

#### 5.1.2.1 Datenvorauswahl

Die Ausreißeranalyse lässt sich rein messdatenbasiert für Signale der Sensoren 1 bis 8 nach der Methode aus Abschnitt 3.3.4 durchführen. Ein Beispiel zur Ausreißeranalyse geben die Abbildung 5.13 und die Abbildung 5.14. Die Beschleunigungen (hier der 1115. Messdatensatz) in Haupt- und quer zur Hauptwindrichtung (HWR bzw. QHWR) aus Abbildung 5.13 werden hauptsächlich durch transiente Anregungen verursacht, die durch Änderung der Gondelposition, der Windrichtung und des Pitchwinkels bei einer „geringen“ mittleren Windgeschwindigkeit von ca. 1,6 m/s entstanden sind. Die Änderungen der EOCs für diesen Messdatensatz sind in Abbildung 3.7 dargestellt. Die Auswirkungen der transienten Anregungen auf die Messsignale werden nach Gl. (3.58) und (3.60) als Ausreißer identifiziert, siehe auch Abbildung 5.14. Dadurch verletzt dieser Messdatensatz die Annahme einer stochastischen Anregung und wird für weitere Berechnungen im Kontext einer Schadensanalyse nicht mehr verwendet.

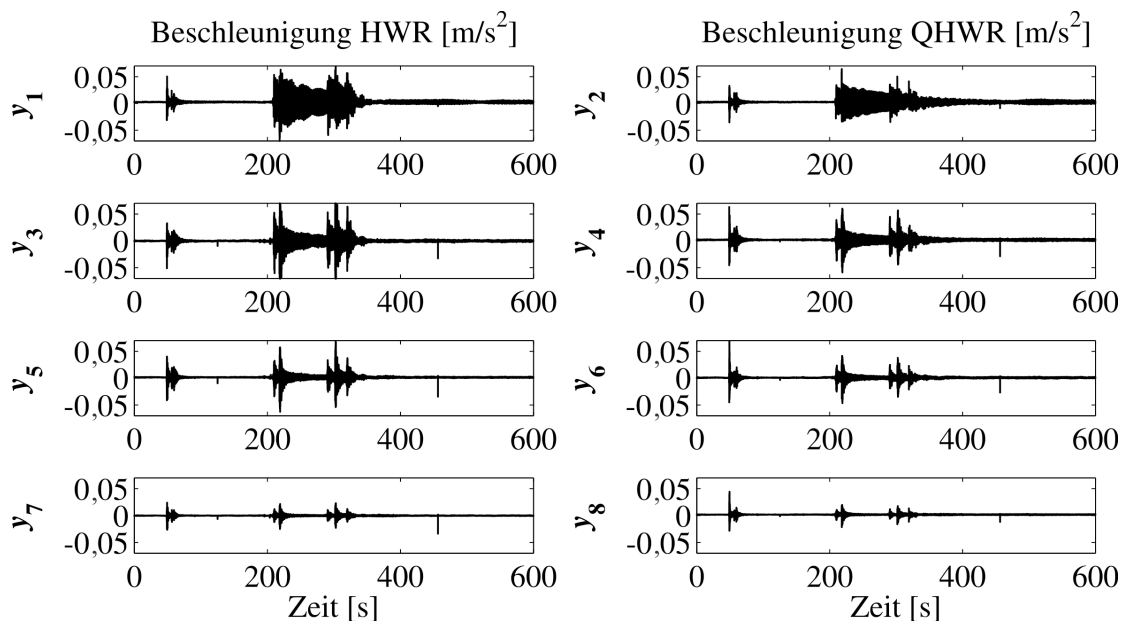


Abbildung 5.13: Beschleunigungsdaten der Messung 1115




Abbildung 5.14: Ausreißeranalyse der Beschleunigungsdaten der Messung 1115

Das Vorkommen von Ausreißern lässt sich, wie erwartet, bei fast allen Datensätzen beobachten, die bei Windgeschwindigkeiten kleiner als 6 m/s aufgenommen sind, siehe Abbildung 5.15. Aus diesem Grund werden zur weiteren Auswertung der Daten nur Messungen bei einer Windgeschwindigkeit größer als 6 m/s (vgl. weiße/grauere Bereich in Abbildung 5.15) ohne Ausreißer berücksichtigt.

Dadurch ergeben sich nach dem Datenvorauswahlverfahren 3824 von insgesamt 8759 Messdaten (44%), die zu Zwecken der Schadenserkennung geeignet sind.




Abbildung 5.15: Ergebnisse der Ausreißeranalyse auf die Messdaten der M5000-2

### 5.1.2.2 Sensorfehlerdetektion und –isolation

Zur Sensorfehlerdetektion und –isolation wird zuerst der MI-Ansatz zur Entdeckung eines gleichzeitigen Ausfalls zweier Beschleunigungsaufnehmer  $y_9$  (misst quer zur Hauptwindrichtung) und  $y_{10}$  (misst in Hauptwindrichtung) im Tripodbereich der Anlage angewendet, siehe Abbildung 5.11, rechts. Hierbei lassen sich die Signale  $y_1$  bis  $y_{10}$  nutzen, welche bis auf die ersten vier Moden des Turms gefiltert sind. Die Ausfallzeiten für diese Sensoren sind grob<sup>1</sup> aus den Varianzen der Signale  $y_9$  und  $y_{10}$  während der 3824 Messungen in den grau markierten Bereichen der Abbildung 5.16 zu ersehen. Die unterschiedlichen Varianzen ergeben sich aus einem Totalausfall der Sensoren. Während der Ausfälle haben die Sensoren nur das eigene Rauschen und nicht die Beschleunigungen aufgenommen, gleichzeitig wich der Erwartungswert der Signale bedeutend von Null ab (Bias-Fehler).

Die Ergebnisse der Sensorfehlerdetektion aus Abbildung 5.17, links, zeigen, dass sich die relativen *MI*-Werte in den grau markierten Bereichen bedeutend geändert haben, was auf einen oder mehrere Sensorfehler zurückzuführen ist. Hierbei werden die *MI*-Referenzmatrix und der Schwellenwert aus den letzten 200 Messungen berechnet. Für die Fehlerisolation wird beispielhaft der erste Datensatz benutzt.

<sup>1</sup> Hier sind nur Blöcke von Messungen dargestellt, in denen sich die Varianzen konsekutiv geändert haben. Besonders zwischen der 2000. und der 3500. Messung tauchen allerdings auch weitere „isolierte“ Ausfälle auf.




Abbildung 5.16: Varianzen der Sensorsignale  $y_9$  und  $y_{10}$

Das Isolationsergebnis aus Abbildung 5.17, rechts, identifiziert die Sensoren 9 und 10 als fehlerhaft. Dabei kann anhand der Veränderungen in den  $MI$ -Werten beobachtet werden, dass zwischen Sensoren, die in der gleichen Richtung messen, eine höhere Redundanz vorhanden ist. So verändert sich die  $MI$  zwischen dem Sensor 9 und den Sensoren 2, 4, 6 und 8 relativ stark (diese Sensoren messen quer zur Hauptwindrichtung). Für die Hauptwindrichtung ändern sich die  $MI$ -Werte zwischen den Kombinationen des Sensors 10 mit den Sensoren 1, 3, 5 und 7. Eine weitere zu erwartende Beobachtung ist eine größere Veränderung der  $MI$  zwischen benachbarten Sensoren auf Grund der höheren Redundanz. So ist  $MI(y_9; y_8) > MI(y_9; y_4)$  oder  $MI(y_{10}; y_7) > MI(y_{10}; y_3)$ .




Abbildung 5.17: Sensorfehlerdetektion (links) und -isolation (rechts) mit dem  $MI$ -Ansatz (Konfidenzintervall für Schwellenwert  $\alpha = 0,01$ )

Zur weiteren Validierung der Sensorfehlererkennung mit Hilfe des  $MI$ -Ansatzes wird hier ein anderer Sensorfehler betrachtet, der in der Veränderung der statistischen Eigenschaften der

Signale nicht mehr „sichtbar“ ist. Dafür werden nur die Signale  $y_1$  bis  $y_8$  aus Abbildung 5.11 genutzt und das Signal  $y_3$  in den letzten 500 der ausreißerfreien 3824 Datensätze verrauscht (SNR = 2). Größere Signal-zu-Rauschen-Verhältnisse führten zu weniger deutlichen Sensorfehlerdetektionsergebnissen. Die Referenz-MI-Matrix bestimmt sich aus dem Mittelwert der MI-Matrizen der ersten 100 Datensätze. Ein Ausschnitt aus dem Signal  $y_3$  in Datensatz 3359 und dessen Leistungsdichtespektrum ist in Abbildung 5.18 beispielhaft dargestellt.




Abbildung 5.18: Signalauschnitt (links) und Leistungsdichtespektren des Signals (rechts) mit und ohne Sensorfehler

Abbildung 5.19, links, zeigt, dass die Messdatensätze mit dem Sensorfehler korrekt identifiziert worden sind. Abbildung 5.19, rechts, zeigt das Ergebnis der Sensorfehlerisolation für den Messdatensatz 3359. Auch in diesem Fall lässt sich beobachten, dass Signale der Sensoren, die in der gleichen Richtung (Hauptwindrichtung) wie Sensor 3 messen (vgl. Abbildung 5.11), eine höhere Redundanz mit diesem aufweisen und dass die redundante Information in den Signalen benachbarter Sensoren größer ist, z.B.  $MI(y_3; y_1) > MI(y_3; y_7)$ .

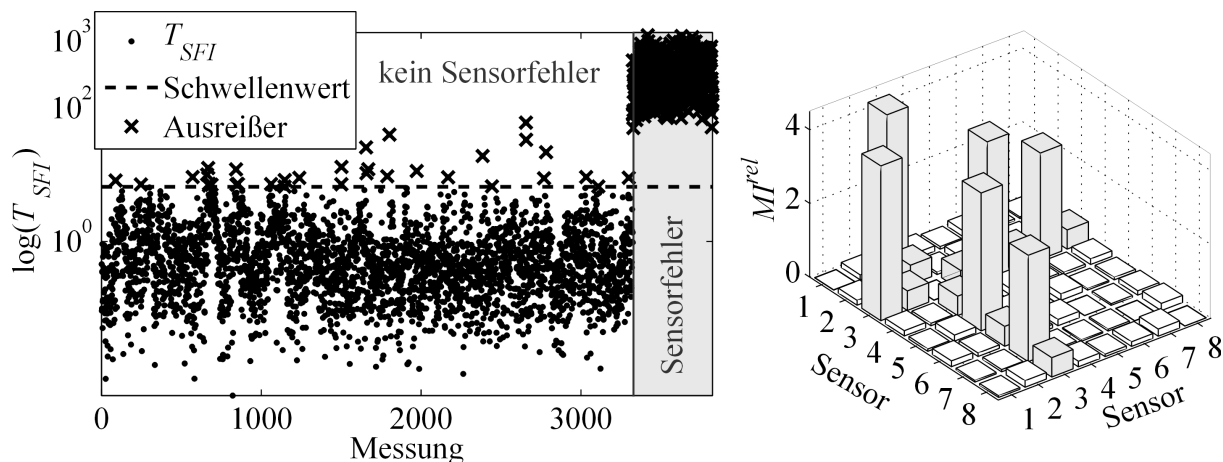


Abbildung 5.19: Sensorfehlerdetektion mit dem MI-Ansatz ( $\alpha = 0,01$ )



### 5.1.2.3 Modalanalyse und Modellaufbau

Die im Abschnitt 3.4.1 beschriebene Methode zur Modalanalyse wird auf Messdaten der Anlage M5000-2 angewendet. Dies dient der Bereitstellung von Modaldaten für die Untersuchung des Schwingungsverhaltens der Anlage und für die Schadenslokalisierung.

In Abbildung 5.20 ist der Stabilitätsplot für die Beschleunigungsaufnehmer  $y_1$  und  $y_8$  über den gemessenen Frequenzbereich dargestellt. Dieser errechnet sich aus Koeffizienten der ARV(2)- bis ARV(90)-Modellen. Die Toleranzwerte für die stabilen Pole (siehe Abschnitt 3.4.1) sind wie folgt ausgewählt:  $fTol = 0,1\%$ ,  $dTol = 5\%$  und  $MACTol = 0,995$ .

Dass diese Methode präzise Ergebnisse liefert, lässt sich besonders im Bereich der ersten Eigenfrequenz der Struktur beobachten. Eine Vergrößerung dieses Bereichs in Abbildung 5.20 zeigt, dass in einem sehr schmalen Frequenzband die erste Eigenfrequenz quer zu Gondelrichtung von der ersten Eigenfrequenz längs zur Gondelrichtung deutlich getrennt werden kann.





Abbildung 5.20: Stabilitätsplot der Modalanalyse (EOC aus Tabelle 5.1)

Die Messdaten für den Stabilitätsplot aus Abbildung 5.20 waren unter der in der Tabelle 5.1 dargestellten, nahezu konstanten EOCs aufgenommen. Hierbei regte hauptsächlich der Wind die Anlage an, die Rotorblätter waren aus dem Wind gedreht und rotierten kaum (sog. Taumelbewegung).

Rotordrehzahl [1/min]	1,32
Generatordrehzahl [1/min]	13,01
Aussentemperatur [°C]	5,60
Windgeschwindigkeit [m/s]	15,56
Relative Windrichtung [°]	-3,87
Absolute Gondelrichtung [°]	272,90
Pitchwinkel [°]	70,00

**Tabelle 5.1 Betriebs- und Umgebungsdaten für die Modalanalyse**

Wie sich die Modaldaten bei unterschiedlichen Betriebszuständen, insbesondere bei der Variation der Rotordrehzahl, verändern können, zeigt Abbildung 5.21.



**Abbildung 5.21: Stabilitätsplot (halber Frequenzbereich, nach Dezimierung) bei rotierendem Rotor**

Hier bewegt sich der Rotor mit einer mittleren Drehzahl von  $\Omega = 14,72 \text{ 1/min} = 0,25 \text{ Hz}$  (mittl. Windgeschwindigkeit =  $10,75 \text{ m/s}$ ; Pitchwinkel =  $1,03^\circ$ ). Die Drehung des Rotors bewirkt eine starke Anregung der Struktur durch den in Abschnitt 3.1 angesprochenen Turm-Blatt-Passage-Effekt. Bei einem 3-Blattrotor regt dieser Effekt Turm-Gondelschwingungen mit dreifacher Umlauffrequenz und deren Vielfachem,  $3\Omega$ ,  $6\Omega$ ,  $9\Omega$ ,  $12\Omega$ , usw. an.

Bedingt durch die geringe Anzahl vorhandener Messpunkte, können die Eigenschwingungsformen mit den dazugehörigen Eigenfrequenzen nur mit Hilfe eines FE-Modells der Anlage zugeordnet werden. Dieses wird hauptsächlich mit Hilfe von quadratischen und dreieckigen Schalenelementen mit unterschiedlichen Ansatzfunktionen aufgebaut. Unterschiedliche Balkenelemente simulieren die Rotorblätter und die Verbindungen zwischen den

Turmsegmenten. Starrkörperelemente stellen die Massen und Massenträgheit der Gondel und des Rotors dar und Federelemente geben die Kopplung zwischen dem Boden und der Struktur wieder. Hierbei werden nur isotrope Materialgesetze für Stahl und Stahl-Beton angewendet. Die Gesamtanzahl der Freiheitsgrade (FHG) des Modells beträgt ca. 140.000. Das Modell und die Anpassung an die Messdaten für den Stabilitätsplot aus Abbildung 5.20 ist in Abbildung 5.22 dargestellt. Um die Massenverteilungen und dadurch die Hauptschwingungsrichtungen (längs oder quer zur Gondelrichtung) des Modells und der realen Anlage möglichst gut darzustellen, entspricht die Gondelposition des Modells der Gondelposition aus Tabelle 5.1.




Abbildung 5.22: FE-Modell der M5000-2 OWEA für den Stabilitätsplot aus Abbildung 5.20

Eine Gegenüberstellung einiger Modaldaten aus den Messdaten (MA) und aus der FE-Berechnung (FE) zeigt die Tabelle 5.2, Abbildung 5.23 und Abbildung 5.24. Hier repräsentieren die Bezeichnungen QGR und LGR die Turmbiegemoden quer bzw. längs zur Gondelrichtung.

$f_{FE}$ [Hz]	$f_{MA}$ [Hz]	Diff [%]	MAC [%]	Schwingungsformen
0,42	0,42	0,92	99,5	1. Turm QGR + 1. Blatt Schlag <sup>1</sup>
0,43	0,43	1,69	99,3	1. Turm LGR + 1. Blatt Schwenk
1,86	1,80	3,47	99,2	2. Blatt Schlag
2,67	2,51	6,19	95,2	2. Blatt Schwenk
3,33	3,13	6,42	99,4	2. Turm QGR + 3. Blatt Schlag
3,47	3,28	5,74	97,9	2. Turm LGR + 3. Blatt Schwenk
4,16	3,86	7,60	97,6	3. Blatt Schlag
4,24	4,42	4,16	97,2	3. Blatt Schlag + 2. Turm QGR
4,83	5,04	-4,34	99,3 <sup>2</sup> (75,9)	3. Blatt Schwenk + Turmtorsion
6,86	6,69	2,41	90,5	3. Turm QGR + 4. Blatt Schlag

Tabelle 5.2 Gegenüberstellung der Modaldaten aus der FE-Berechnung und der Modalanalyse (MA)





Abbildung 5.23: Einige Schwingungsmoden der Anlage M 5000-2

<sup>1</sup> Die Schlag- und Schwenkrichtungen der Blattbiegemoden können aus Abbildung 5.22 entnommen werden.

<sup>2</sup> Berücksichtigt nur die Schwingung längs zur Gondelrichtung. Der MAC-Wert in Klammern zeigt die Korrelation der Moden in alle Richtungen für die Mode bei 4,83 Hz.



**Abbildung 5.24: Einige Schwingungsmoden der Anlage M 5000-2**

Für die Langzeitüberwachung der dynamischen Eigenschaften der Anlage werden die stabilen Pole in den angegebenen Intervallen beobachtet (siehe grau hinterlegte Bereiche in Abbildung 5.25). Der obere Teil der Abbildung 5.25 zeigt erneut den Stabilitätsplot aus Abbildung 5.20. Jeder Punkt in dem unteren Teil der Abbildung 5.25 bezieht sich auf eine Messung und stellt den Mittelwert der Eigenfrequenz, berechnet aus den stabilen Polen in dem angegebenen Intervall nach Gl. (3.66), dar. Die Abweichung der stabilen Pole zu dem Mittelwert in dem Intervall beträgt je nach Messung und betrachtete Frequenz ca. 0,1-2%. Dieser Vorgang wird für alle 3824 Messungen ohne Ausreißer durchgeführt.

Die Ergebnisse der Modalanalyse zeigen eine Variation der Eigenfrequenzen während der Überwachungszeit, je nach Schwingungsmode, von bis zu 7%. Außerdem wird festgestellt, dass je nach Anregungsbedingungen einige Moden in manchen Datensätze gar nicht angeregt worden sind. Gründe für die veränderlichen dynamischen Zustände der Anlage sind, wie schon in Abschnitt 3.1 vorgestellt, in den veränderlichen Umgebungsbedingungen (z.B. Temperatur) sowie in der Veränderung der Betriebszustände, (z.B. unterschiedliche Koppelschwingungen zwischen Blatt und Turm, verursacht durch Variation der Blattstellungen und Veränderungen der Massenverteilungen eingeleitet durch die Gondelstellungen) zu sehen.





Abbildung 5.25: Frequenzintervalle für die Langzeit-Modalanalyse

In Abbildung 5.26 a) bis c) sind einige schwache Trends für die Veränderung der ersten Eigenfrequenz der ersten Mode quer und längs zur Gondelrichtung zu sehen. Wie in [KRAEMER und FRITZEN 2010a; KRAEMER und FRITZEN 2010b; NIU *et al.* 2011; SOHN 2007] beschrieben, ist eine geringe Abnahme mit der Temperatur sowie eine leichte Zunahme mit der Rotordrehzahl (welche auch von der Windgeschwindigkeit abhängt) zu beobachten. Die Abbildung 5.26 d) zeigt, wie erwartet, dass die Eigenfrequenzen u.a. von der Position der Gondel abhängig sind (dies war am besten in der 2. Biegemode des Turmes quer zur Gondelrichtung sichtbar).



**Abbildung 5.26:** Abhängigkeit einiger Eigenfrequenzen von EOC (graue Linien: alle Datensätze; schwarze Punkte: Datensätze ohne Ausreißer und  $\alpha_{\phi_{max}} \leq 0,05$ , siehe auch Gl. (3.67))

Wie schon in Abbildung 5.20 und Abbildung 5.25 dargestellt, sind die Eigenfrequenzen der 1. Turmbiegemode quer und längs zur Gondelrichtung sehr nah beieinander. Eine gängige Methode zur Unterscheidung dieser Moden ist die Berechnung der MAC-Werte der Eigenvektoren. Dieser Ansatz erwies sich besonders für einen relativen Winkel von  $45^\circ$  zwischen Gondelposition und Sensoren als unzureichend, da hierfür die MAC-Werte zwischen den Moden längs und quer zur Gondelrichtung gleich Eins sind. Eine Unterscheidung zwischen diesen Moden ist auf Basis unterschiedlicher Dämpfungsverhältnisse für Schwingungsmoden in Wind- und quer zur Windrichtung möglich. Abbildung 5.27, rechts, zeigt, dass Moden längs zur Gondelrichtung in der Regel stärker gedämpft sind als Moden quer zur Windrichtung. Dieses Verhalten liegt in der schwingungsdämpfenden Wirkung der umgebenden Luftströmung auf die Anlage begründet.




Abbildung 5.27: Trennung zwischen 1. Biegemode quer und längs zur Gondelrichtung anhand von Eigenfrequenzen (links) und von Dämpfungskoeffizienten (rechts)

#### 5.1.2.4 Schadensdetektion

Die Schadensdetektion erfolgt mit Hilfe der NSFD-Methode in Kombination mit den Klassifikationsverfahren aus Abschnitt 3.3.3.1. Die hier betrachteten EOC sind: die Windgeschwindigkeit, die Rotordrehzahl, die Gondelposition, der Pitchwinkel, die Außentemperatur und der Turbulenzgrad des Windes. Um die Dimensionalität der Daten zu reduzieren, werden die Anzahl der Betriebszustände, die durch die Betriebsführung der Anlage in einem gewissen linearen oder nicht-linearen Verhältnis zueinander stehen, siehe auch Abbildung 3.23, mit Hilfe der NLPCA bis auf die ersten zwei nicht-linearen Hauptkomponenten „komprimiert“, siehe Abschnitt 2.4.2. Die Ergebnisse dieser Dimensionsreduktion sind in Abbildung 5.28 dargestellt. Hierbei ist die zweidimensionale Fläche repräsentativ für die 4-dimensionalen Daten, welche zu Visualisierungszwecken auf die Koordinaten der eigenen ersten drei linearen Hauptachsen dargestellt sind, siehe Gl.(2.105)-(2.106).




Abbildung 5.28: Projektion der 4-dimensionalen Betriebszustände auf die ersten zwei nicht-linearen Hauptkomponenten. Darstellung der mehrdimensionalen Daten auf die ersten drei Hauptachsen (PC)



Die Repräsentationsfähigkeit der nicht-linearen Hauptkomponenten für die obengenannten Betriebszustände ist in Abbildung 5.29 gezeigt. Hierbei wird das AANN mit den ersten 1391 EOCs angelernt (stammen aus Messdaten aufgenommen im November 2007 und April 2008) und mit den EOCs der Messdaten 1392 bis 3824 (stammen aus Messungen von März 2009 bis Februar 2010) getestet. Es hat sich gezeigt, dass die durch die NLPCA reduzierte Dimension der Betriebs- und Umgebungszustände auch für EOCs der Messungen aus der gewählten Testphase repräsentativ ist. Da die Temperatur oder der Turbulenzgrad des Windes weder linear noch nicht-linear mit weiteren EOCs korrelieren, lassen sich diese direkt zur Kompensation der EOC Einflüsse auf die Schadensindikatoren heranziehen.


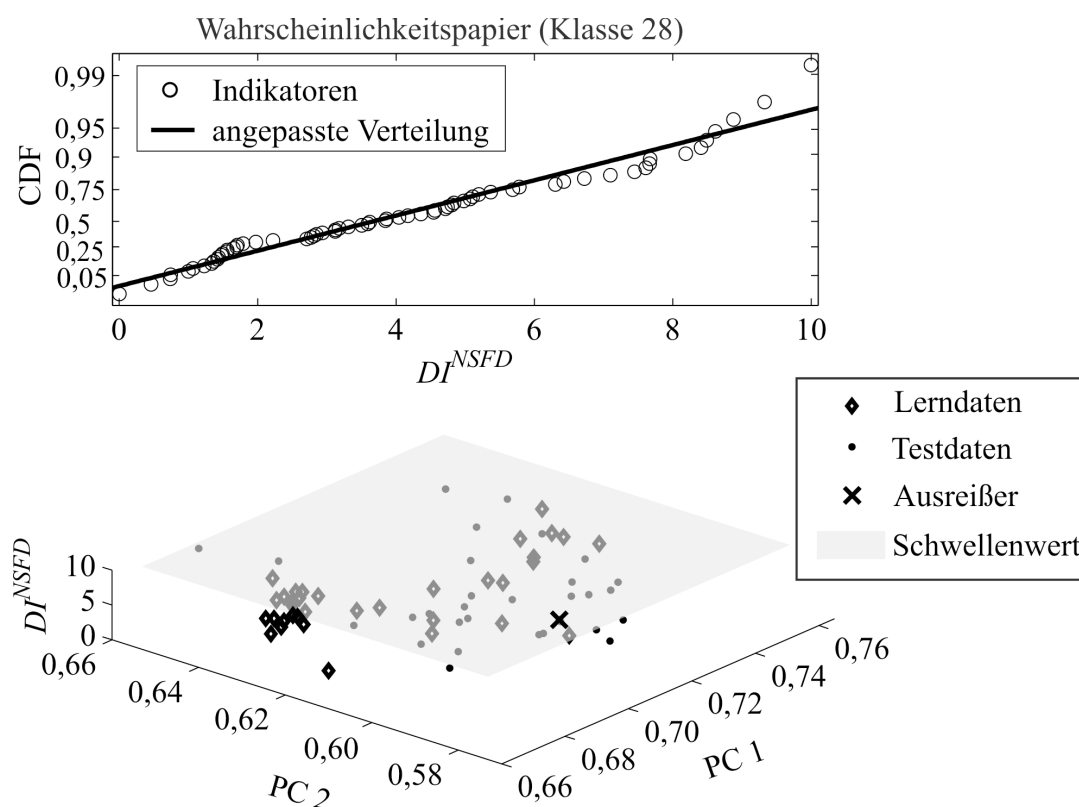


Abbildung 5.29: Betriebszustände und deren Schätzung mit Hilfe der NLPCA

Somit lassen sich bei der Berechnung der Schadensindikatoren die folgenden Einflüsse betrachten: erste und zweite nicht-lineare Hauptkomponente (repräsentativ für die Windgeschwindigkeit, Rotordrehzahl, Gondelposition und Pitchwinkel), die Temperatur und der Turbulenzgrad des Windes. Die Berechnung nutzt die ersten 1391 Messdatensätze für die Lernphase. Die Anzahl der Klassen während der Trainingsphase ist 40. Diese Klassenanzahl wird adaptiv während der Testphase durch Anlernen neuer EOCs bis auf 160 erweitert. Weder während der Lern- noch während der Testphase werden mit diesem Parameter für die

Klassifikation Schäden an der Anlage gefunden oder falsche Alarme initialisiert. Abbildung 5.30 stellt beispielhaft die Verteilung der Schädigungsindikatoren und die Schadensidentifikationsergebnisse für die Klasse 28 dar. Um eine dreidimensionale Ergebnisvisualisierung zu ermöglichen, lassen sich die Indikatoren über die auf die ersten zwei linearen Hauptachsen (PC) transformierten EOCs darstellen, siehe Gl. (2.105)-(2.106). Der Schwellenwert für einen Konfidenzintervall von  $\alpha = 0,02$  wird mit Hilfe einer an die Indikatoren angepassten FRECHET-Verteilung festgelegt. Die Ergebnisse zeigen, dass sowohl Indikatoren aus der Lernphase als auch Indikatoren aus der Testphase unterhalb des Schwellenwertes liegen. Aus insgesamt 66 Indikatoren der Klasse entsteht ein einziger Ausreißer (siehe x in Abbildung 5.30), der allerdings im Rahmen der angegebenen Konfidenzgrenzen zugelassen ist.



**Abbildung 5.30: Verteilung der Schadensindikatoren in Klasse 28 (oben); Darstellung der Schadensindikatoren mittels der ersten zwei Hauptachsen (PC) der EOCs (unten)**

Um die Möglichkeit von Strukturschadensdetektionen beim Auftreten von veränderlichen EOCs zu erläutern, wird im Folgenden von Simulationen Gebrauch gemacht. Mit Hilfe der Simulationen sollen auch der Einfluss der Klassenanzahl, die Länge der Trainingsphase und die Bedeutung der angelernten EOC-Einflüsse auf die Indikatoren und Detektionsergebnisse erläutert werden.

### 5.1.2.5 Simulationsstudie hinsichtlich der Schadensdetektion unter veränderlichen EOC

Zu Simulationszwecken wird ein FE-Balkenmodell der OWEA M5000-2 bestehend aus 68 Elementen mit linearem Verschiebungsansatz und 66 Knoten verwendet (siehe Abbildung 5.31). Die Gondel, der Rotorstern und die Blätter sind als Massenpunkte modelliert.

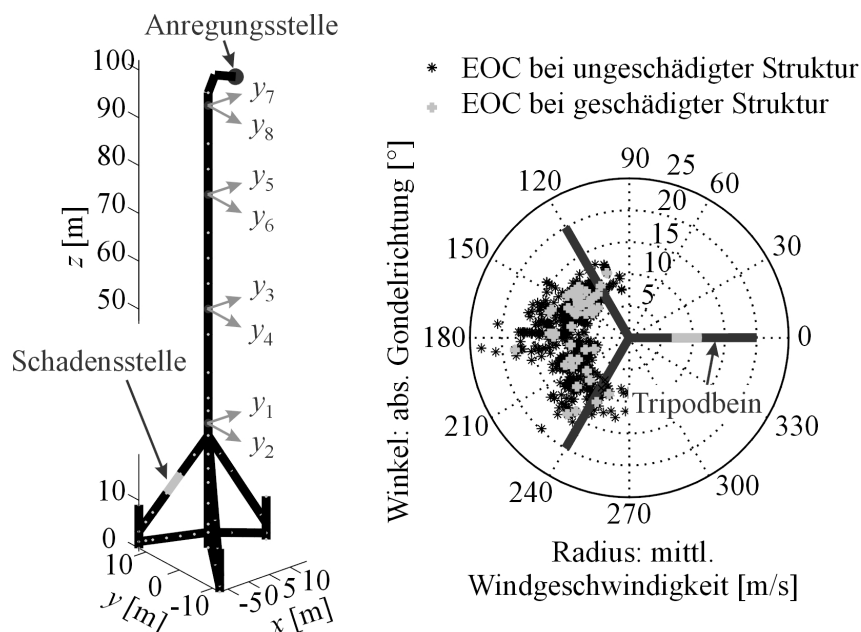


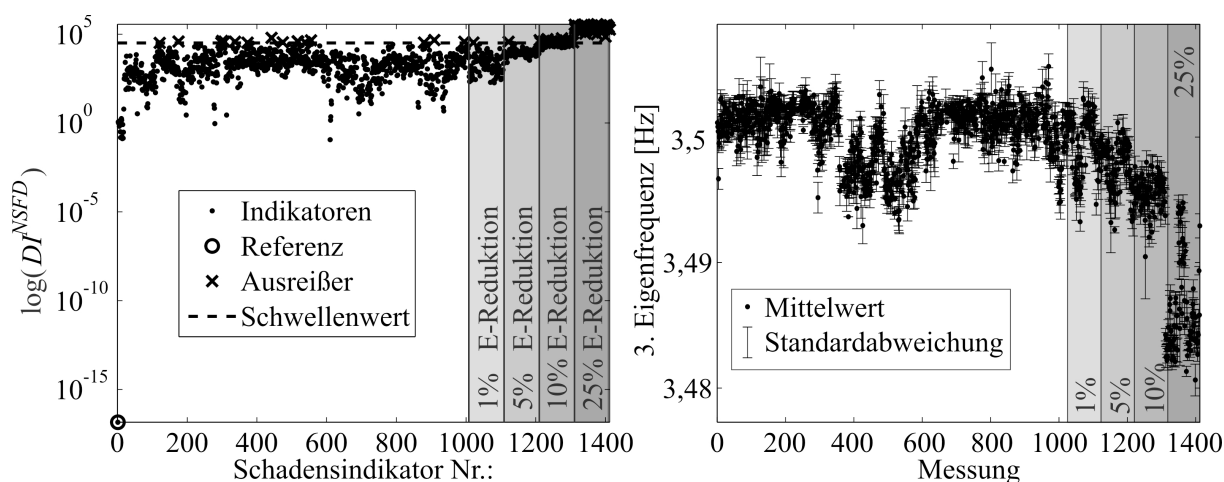
Abbildung 5.31: Simulationsmodell einer OWEA (links); betrachteten EOC (rechts)

Die Balkenquerschnitte richten sich nach den realen Querschnitten an der Anlage M5000-2. Die unsymmetrische Massenverteilung entlang des Turms, wird mit unterschiedlichen Flächenträgheitsmomenten<sup>1</sup> der Turmelemente modelliert. Die Position der acht „Sensoren“ (entsprechen der Sensorpositionen auf der Anlage M5000-2) sowie die Anregungsstelle der Struktur sind in Abbildung 5.31 (links) dargestellt. Die Beschleunigungen lassen sich mit Hilfe des reduzierten Modalmodells der Anlage nach Gl. (2.18) simulieren. Diese beinhalten die ersten acht Moden des Modells und werden zusätzlich mit 1% der Standardabweichung des Signals  $y_1$  verrauscht.

Die stochastische Anregung des Modells erfolgt durch den Wind, nach Gl. (3.135), und periodisch durch den Windströmungsabriss, verursacht durch die Turm-Blatt-Passage. Als veränderliche Betriebsbedingungen werden die Gondelposition, die Windgeschwindigkeit und die Windrichtung berücksichtigt. Hierbei handelt es sich um die an der Anlage M5000-2 gemessenen EOCs, die der Simulation zugeführt werden. Die für die Simulationen verwendeten

<sup>1</sup> Turm in  $y$ -Richtung (Hauptwindrichtung) ist um 5% steifer als in  $x$ -Richtung, siehe Abbildung 5.31.

Mittelwerte für die Position der Gondel und die Windgeschwindigkeit sind in Abbildung 5.31 (rechts) dargestellt. Insgesamt werden 1412 „Messungen“ mit einer Messdauer von je 10 Min. und einer Abtastrate von 50Hz simuliert. Bei den ersten 1008 Messungen handelt es sich um die intakte Anlage. Bei den nächsten vier Messdatenblöcken mit je 101 Messungen handelt es sich um Schwingungsdaten des geschädigten Modells, siehe Abbildung 5.31, links. Hierbei wird künstlich ein progressiver Schaden in einem Tripodbein durch die Reduktion des E-Moduls an der Schadensstelle (ein FE-Element des Tripods) um 1%, 5%, 10% und 25% erzeugt. Die Schadensindikatoren, berechnet mit der NSFD-Methode und einer einzigen Referenz nach Gl. (3.14), zeigen in Abbildung 5.32, links, ein tendenzielles Wachstum erst beim Eintreten der dritten Schädigungsstufe (10% E-Modul-Reduktion). Der Schwellenwert, aufgestellt mit Hilfe der generalisierten Extremwertverteilung, wird erst bei der letzten Schädigungsstufe (25% E-Modul-Reduktion) geringfügig und nicht in allen Fällen überschritten. Die geringe Sensitivität der Methode gegenüber kleinen Strukturschäden ist eindeutig auf die Effekte der EOC auf die Schadensindikatoren zurückzuführen. Auch die Betrachtung der dritten Eigenfrequenz<sup>1</sup> des Systems in Abbildung 5.32, rechts, die sich am sensitivsten gegenüber der Strukturveränderung durch den Schaden herausgestellt hat, deutet erst auf einen Schaden hin, sobald die Steifigkeit des Elementes um 25% reduziert ist. Die kleineren Schäden werden durch die Effekte der veränderlichen EOCs auf die Strukturdynamik überdeckt.




**Abbildung 5.32: Schadensdetektion mit einer einzigen Referenz - Konfidenzintervall für Schwellenwert der GEV:  $\alpha = 0,05$  (links); Dritte Eigenfrequenz des Modells (rechts)**

<sup>1</sup> Bedingt durch die geringe Anzahl an Sensoren zeigen die MAC-Werte zwischen den Eigenmoden der ungeschädigten und der geschädigten Struktur kaum Veränderungen. Die Modalanalyse wurde mit der ARV-Methode aus dem Abschnitt 3.4.1 durchgeführt.

Um die Effekte der EOC-Kompensation auf die Qualität der Schadensidentifikation zu verdeutlichen, werden im Folgenden die Ergebnisse der NSFD-Methode in Kombination mit den Klassifikationsverfahren aus Abschnitt 3.3.3.1 und 3.3.3.2 erläutert.


Zur Berücksichtigung der Umgebungseinflüsse lassen sich zuerst die ersten 800 Messungen für die Trainingsphase des Algorithmus auswählen. Dadurch werden die Effekte der EOC auf die Schadensindikatoren gut angelemt. Die daraus berechneten 800 Schädigungsindikatoren lassen sich mit Hilfe von Klassifikationsverfahren (hier *k-means* und *k-medoid*) nach den Eingangsparametern Windgeschwindigkeit und Position der Gondel in 15 Klassen unterteilen (siehe Abbildung 5.33). Dabei ist zu beachten, dass an den Stellen mit größerer Datendichte auch mehr Klassen entstehen. Dadurch erhöht sich die Empfindlichkeit der Identifikation an diesen Stellen.



**Abbildung 5.33: Klassifikation der Schädigungsindikatoren während der Lernphase**


Diese Schädigungsindikatoren werden für jede Klasse, bezogen auf die dazugehörigen Klassenzentren, separat neu berechnet. Die verbleibenden 612 Messungen (als Online- oder Test-Daten anzusehen) lassen sich nun ihren entsprechenden Klassen zuweisen und die Schadensindikatoren der Testphase berechnen sich anhand der dazugehörigen Referenzen. Somit kann erfasst werden, ob die Indikatoren einer Klasse den spezifischen Klassenschwellenwert überschritten haben. In Abbildung 5.34 sind beispielhaft die Ergebnisse der Klasse 8 dargestellt. Der obere Teil der Abbildung zeigt Indikatoren im Bereich A, die während der Lernphase der Klasse 8 zugewiesen wurden. Der Schwellenwert für  $\alpha = 0,02$  lässt sich mit Hilfe einer an den ersten 30 Indikatoren angepasste FRECHET-Verteilung mit den Parametern:  $\zeta = 0,59$ ,  $\mu = 0,44$  und  $\sigma = 0,45$  aufstellen. Ein Wahrscheinlichkeitspapier für diese Indikatoren und die Anpassung der Verteilung an die Indikatoren zeigt der untere Teil

der Abbildung 5.34. Im Bereich B wird der ausgewählte Schwellenwert mit Schadensindikatoren der ungeschädigten Struktur während der Testphase validiert. Im Bereich C sind Indikatoren nach dem Schadenseintritt (5% E-Modul-Reduktion) dargestellt. Diese überschreiten den vorgegebenen Schwellenwert deutlich.



**Abbildung 5.34: Beispielhafte Schadensdetektion in der Klasse 8 während der Testphase (oben); Wahrscheinlichkeitspapier der Indikatoren in Klasse 8**


Das Ergebnis in der Klasse 8 ist auch in Abbildung 5.35 unter Darstellung der berücksichtigten EOCs dargestellt. Hier lässt sich nun erkennen, dass Lerndaten und Testdaten, die von der ungeschädigten Struktur stammen, unter dem Schwellenwert liegen und alle Testdaten von der geschädigten Struktur als Ausreißer identifiziert worden sind.



**Abbildung 5.35: Dreidimensionale Darstellung der Ergebnisse aus der Abbildung 5.34**

Des Weiteren werden die Einflüsse der Anzahl der Zentren und der Anzahl der Trainingsdaten bei unterschiedlichen Schadensgrößen auf die Schadensidentifikationsmethode untersucht. Da bei einer unzulässigen Überschreitung des Schwellenwertes der Anlagenbetreiber informiert werden soll, wird dies hier kurz als Alarm bezeichnet. Die Anzahl der Alarme berechnet sich somit aus der Anzahl der unzulässigen Überschreitungen der Schwellenwerte in allen Klassen. Abbildung 5.36, links, zeigt, dass kleine Schäden, wie z.B. die Steifigkeitsreduktion eines Elementes um 1% mit einer höheren Anzahl von Referenzen besser detektierbar sind. Schäden, die aus einer Steifigkeitsreduktion von mindestens 5% resultieren, lassen sich sehr gut auch mit relativ wenigen Referenzen detektieren.

Wenn eine Trainingsphase weniger Messdaten beinhaltet und dadurch diese nicht den gesamten EOC-Bereich abdeckt, dann wirkt sich dies negativ auf die Ergebnisse der Schadensdetektion aus. Abbildung 5.36, rechts, stellt die Ergebnisse der Detektion bei einem Umfang von 500 Messdaten für die Trainingsphase<sup>1</sup> und 912 Messdaten für die Onlinephase dar. Diese zeigt, dass hier der kleinste Schaden nur mit Hilfe von 60 Klassen der Trainingsphase entdeckt werden kann.



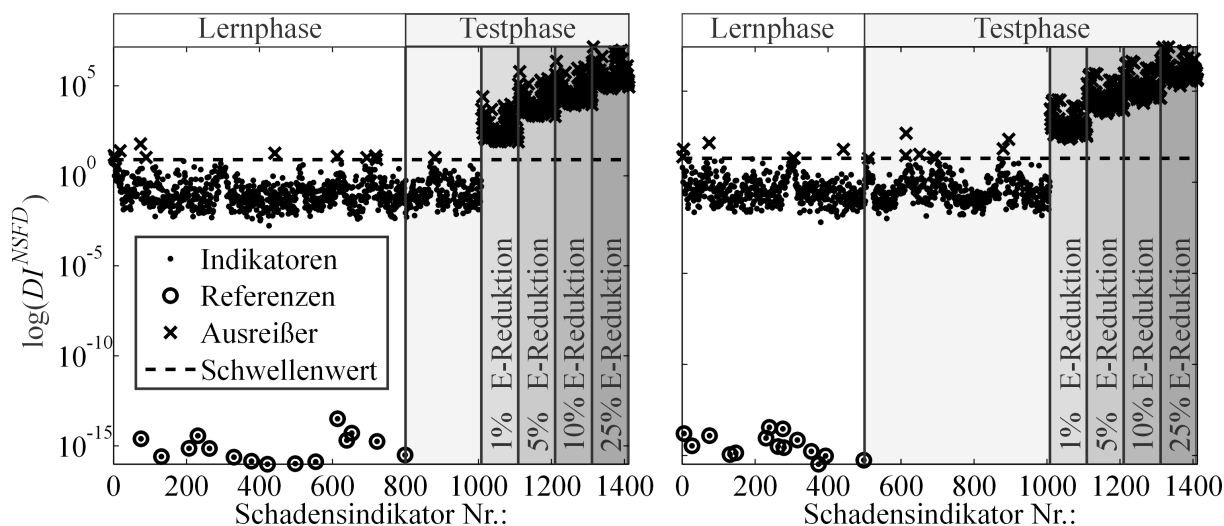
**Abbildung 5.36: Schadensdetektion in Abhängigkeit der Klassenanzahl und des Schadensausmaßes**

Dieses Verhalten wird durch die Entstehung von neuen Klassen während der Testphase begründet, deren Größe sich nach der Größe der Klassen in der Lernphase richtet, siehe Gl. (3.49). Wenn in der Lernphase aber weniger und dadurch größeren Klassen entstehen, dann werden auch die Klassen der Testphase größer und damit insensitiver gegenüber kleineren Strukturschäden. Dieses Verhalten führt aber nicht zwingend zu besseren Ergebnissen bei

<sup>1</sup> Diese Trainingsphase berücksichtigt nicht die Änderung der Gondelposition und die entsprechenden Windgeschwindigkeiten im Bereich 240-270° und einen Teil des Bereichs 180-210°, siehe auch Abbildung 5.31.

Berechnungen mit einer höheren Anzahl an Klassen. Eine hohe Klassenanzahl in der Trainingsphase kann dazu führen, dass eine nicht genügend große Anzahl an Daten zur Aufstellung und Überprüfung des Klassenschwellenwertes vorhanden sind. Diese Klassen werden, wenn überhaupt, erst während der Testphase mit weiteren Daten „gefüllt“ und sind dadurch erst „später“ oder gar nicht für Schadensdetektionszwecke brauchbar. Diese Tendenz kann bei der Betrachtung des Schadens, der durch eine Reduktion des E-Moduls um 25% verursacht wurde, beobachtet werden. Dieser „deutliche“ Schaden, der auch mit Verwendung einer Referenz erkennbar ist, lässt sich aus den obengenannten Gründen auf Basis weniger Klassen besser identifizieren als auf Basis einer Klassifikation mit mehreren Klassen.

Die Berechnung der NSFD-Indikatoren in Kombination mit *Fuzzy*-Klassifikationsverfahren nach dem Algorithmus aus Abschnitt 3.3.3.2 ist für unterschiedlich lange Lernphasen in Abbildung 5.37 dargestellt.



**Abbildung 5.37: Schadensdetektion mit Hilfe von *Fuzzy*-Klassifikation und NSFD**

Hier werden zunächst die Indikatoren nach den EOC klassifiziert, siehe Abbildung 5.33. An den Klassenzentren lassen sich die Referenzhankelmatrizen auswählen, welche individuell für die Berechnung des Indikators jedes Datensatzes nach Gl. (3.51) gewichtet werden, vgl. auch Gl. (3.50). Der Schwellenwert lässt sich hier mit Hilfe der GEV für ein Konfidenzintervall von  $\alpha = 0,02$  aus den Extremwerten (Maximum aus Blöcken von 20 Indikatoren) der Lernphase festlegen. Die Ergebnisse zeigen, dass die Berücksichtigung der EOCs mit Hilfe von Klassifikationsverfahren die Leistungsfähigkeit der NSFD-Methode entscheidend verbessert (vergleiche dazu Abbildung 5.32 mit Abbildung 5.37). Abbildung 5.37 zeigt, dass für eine relativ gute Lernphase auch kleine Schäden detektiert werden können, und die auf *Fuzzy*-



Klassifikation basierte Methode deutlichere Ergebnisse als die auf *k-means* basierte Methode zeigt. Ist die Lernphase allerdings „zu kurz“, so dass entscheidende Einflüsse von EOC auf die Indikatoren nicht angeleert werden können, dann kann die auf *Fuzzy*-Klassifikation aufbauende Methode nur noch relativ große Schäden identifizieren. Im Gegensatz dazu ist die auf *k-means* basierte Methode (siehe Abschnitt 3.3.3.1) lernfähig und weiterhin sensitiv gegenüber kleinen Strukturschäden. Ein Beispiel dazu liefert eine Trainingsphase, die nur auf den ersten 200 Messungen und 6 Klassen in der Lernphase basiert. Dadurch werden nur Effekte der Gondelpositionen zwischen 135-190° und die dazugehörigen Windgeschwindigkeiten auf die Indikatoren angeleert (siehe Abbildung 5.38, links und vergleiche mit Abbildung 5.31, rechts). Zusätzlich werden hier die Daten in höherem Maße als bisher mit 5% der Standardabweichung des Signals  $y_1$ , künstlich mit Rauschen überlagert. Dies führt dazu, dass mit Hilfe der NSFD-Methode und einer einzigen Referenz überhaupt kein Schaden mehr identifiziert werden kann, siehe Abbildung 5.38, rechts.


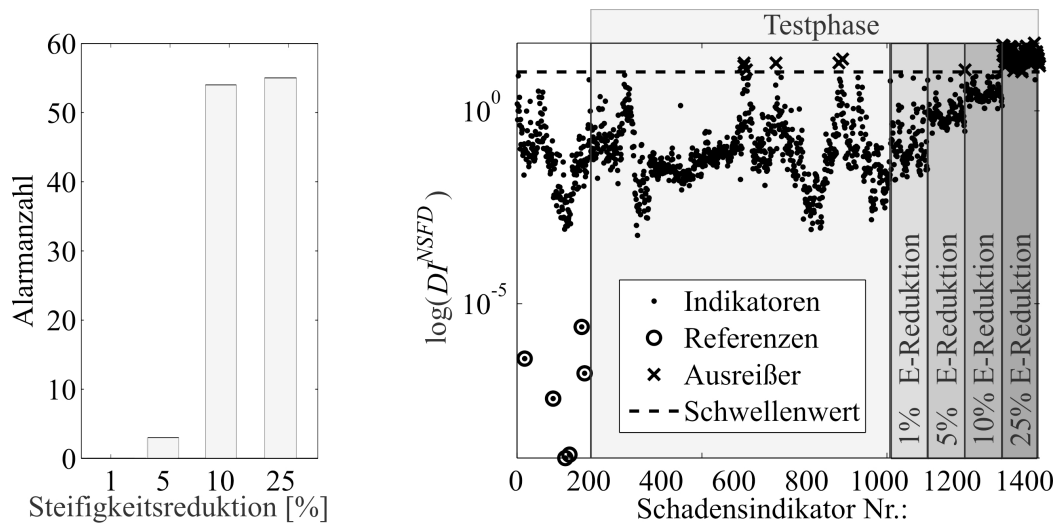



Abbildung 5.38: EOC für 200 Lerndaten (links), Schadensdetektion mit einer einzigen Referenz und verrauschten Signalen (rechts)

Die auf *k-means* basierende Methode ist weiterhin in der Lage „größere“ Schäden von 10% bis 25% E-Modul-Reduktion deutlich zu detektieren. Bedingt durch die Initialisierung des Algorithmus mit einer relativ geringen Anzahl an Klassen ist der kleinste Schaden nicht erkennbar, siehe Abbildung 5.39, links. Die auf der *Fuzzy*-Klassifikation basierende Methode kann keine neuen Zustände anlernen und dadurch nur den größten simulierten Schaden identifizieren (siehe Abbildung 5.39, rechts).



**Abbildung 5.39: Schadensdetektion mit NSFD und EOC-Kompensation bei einer schlechten Trainingsphase; Ergebnisse mit *k-means*-Klassifikation (links) und *Fuzzy*-Klassifikation (rechts)**


Die Ergebnisse der *Fuzzy*-Klassifikation lassen sich auch durch Vorgabe mehrerer Zentren in der Lernphase nicht mehr verbessern, da letztlich die gleichen EOC Einflüsse (wenn auch besser) angelernt werden. Im Gegensatz dazu führt eine Initialisierung der Klassifikation (bei der *k-means* basierten Methode) mit mehreren Zentren, bedingt durch die relativ kleinen Klassen der Lernphase, zu einer größeren Wahrscheinlichkeit, dass Online-Daten auch den neuen Klassen der Testphase zugewiesen werden. Um dies zu veranschaulichen, erfolgt die Einteilung der gleichen 200 Daten in 14 Klassen der Lernphase. Mit dem Eintritt der Testphase sind die 1212 Testdaten den alten 14 Klassen und weiteren 27 Klassen (Online entstanden) zugewiesen. Die Ergebnisse der Schadenserkennung aus der Abbildung 5.40 zeigen, dass die Klassen der Lernphase deutlich zur Verbesserung der Schadenserkennung beitragen.



**Abbildung 5.40: Schadensdetektion mit NSFD und EOC-Kompensation mit *k-means* bei einer schlechten Trainingsphase und verrauschten Signalen (Initialisierung mit 14 Zentren)**

### 5.1.2.6 Simulationsstudie hinsichtlich Schadenslokalisierung

Die Leistungsfähigkeit und die Grenzen des Schadenslokalisationsalgorithmus wird wegen der Abwesenheit eines tatsächlichen Schadens an der realen Anlage mit Hilfe einer Simulation mit dem FE-Modell aus Abbildung 5.22 erläutert. Da es hier schließlich um die Entdeckung von Strukturschäden geht, werden die Gondel und die Rotorblätter als Starrkörper modelliert. Die „gemessenen Modaldaten“ lassen sich an vier Knoten der Struktur simulieren - jeder Knoten repräsentiert dabei einen triaxialen Beschleunigungsaufnehmer - während die lokal begrenzten Schäden im Tripod und auf dem Turm durch eine E-Modul-Reduktion eingebracht wird (siehe Abbildung 5.41). Der Turmschaden soll die Auswirkung eines Schiffsaufpralls und der Tripodschaden die Auswirkung der Ermüdung an einer *hot spot*-Stelle [SCHAUMANN *et al.* 2005; THÖNS *et al.* 2008] unter der Wasseroberfläche simulieren. Das dynamische Verhalten der Anlage wurde mit Hilfe von sieben Eigenschwingungsmoden berücksichtigt, siehe Abbildung A.3 im Anhang.



**Abbildung 5.41: Modell der Anlage mit Sensorpositionen und zwei simulierten Schadensorten**

Der Modellaufbau, die Berechnung der Sensitivitätsmatrix sowie der Modellmoden und die Ergebnisvisualisierung sind mit der Berechnungsplattform FEMTools realisiert. Die Auf-

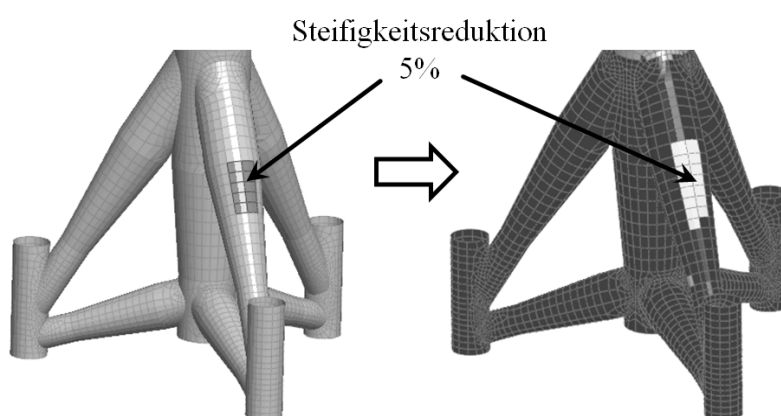
stellung der Gleichungen, die Parametervorselektion und die Lösung des inversen Problems erfolgen in Matlab.

Bei der Anwendung des Lokalisationsalgorithmus auf die OWEA-Struktur aus Abbildung 5.41, welche aus mehr als 8000 Elementen aufgebaut ist, wird eine weitere Reduktion des Parameterraums mit Hilfe einer Korrelationsanalyse vor dem Vorselektionsverfahren vorgeschlagen. Dieser Vorgang ist sinnvoll, da häufig eine Vielzahl von Parametern nur sehr geringe Korrelationen mit dem Residuum aufweisen. Hierbei werden die Korrelationskoeffizienten zwischen dem Residuum  $\mathbf{r}$  und jeder Spalte  $j$  der Sensitivitätsmatrix  $\mathbf{S}$  wie folgt berechnet:

$$\kappa_j^2 = \frac{(\mathbf{r}^T \mathbf{S}_j)^2}{(\mathbf{S}_j^T \mathbf{S}_j)(\mathbf{r}^T \mathbf{r})}. \quad (5.1)$$

Für dieses Beispiel beschränkt sich die Anzahl der möglichen relevanten Elemente für einen Schaden auf die ersten 100 Parameter, die einen Korrelationskoeffizienten größer als 0,8 aufweisen.

Wie aus Abbildung 5.42 hervorgeht, lassen sich theoretisch mit dem Ansatz aus Abschnitt 3.4.2 kleine Strukturschäden gut identifizieren. Hierbei handelt es sich um einen simulierten Schaden, dessen Ausmaß entsprechend einer Steifigkeitsreduktion durch eine E-Modul-Verringerung um 5 % ausgedrückt werden kann, siehe Abbildung 5.42, links. Der rechte Teil der Abbildung 5.42 zeigt die Ergebnisse der Schadenslokalisierung und damit den korrekten Ort und das Ausmaß des Schadens.




**Abbildung 5.42: Simulierter (links) und identifizierter Schaden (rechts) in dem Tripodbein einer OWEA**

In der Realität sind aber geringe Steifigkeitsveränderungen im Tripodbereich und bei der in Abbildung 5.41 gegebenen Sensorstellenkonfiguration kaum lokalisierbar. Die Gründe dafür liegen darin, dass sich die Eigenfrequenzen und die Eigenmoden an den gemessenen Frei-

heitsgraden kaum verändern und diese schon sehr geringen Veränderungen zusätzlich durch EOC-Variation und Rauschen in den gemessenen Modaldaten maskiert werden. Auch die Anwendung eines nicht ausreichend an die Referenzmodaldaten angepassten Modells führt zu weiteren Unsicherheiten bei der Anwendung der Schadenslokalisationsmethode.

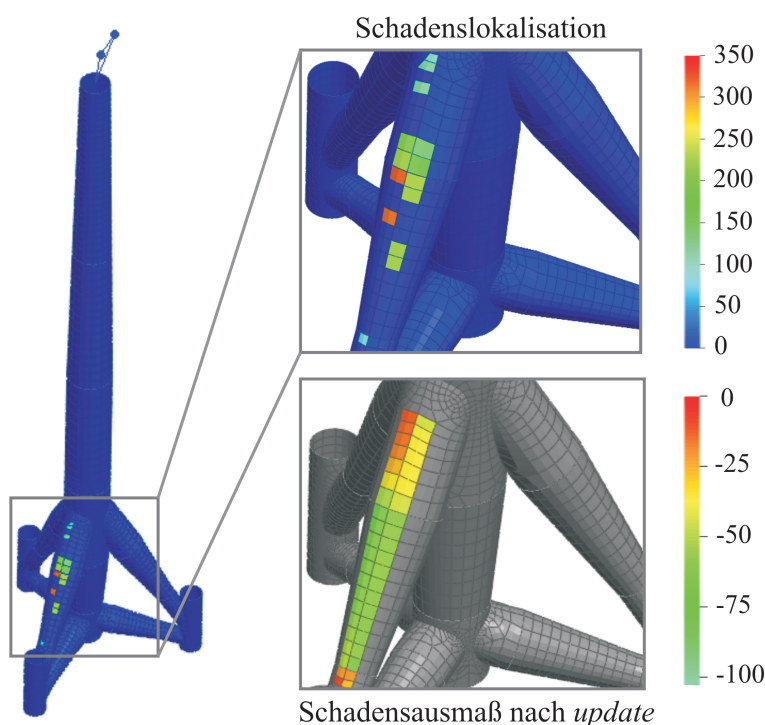
Größere Steifigkeitsreduktionen, wie z.B. eine E-Modul-Reduktion um 80% verursachen (besonders in einem Turmsegment) eine gewisse Veränderung des dynamischen Systemverhaltens, siehe Tabelle A.1 und Tabelle A.2 im Anhang. Die Berechnung wird mit Hilfe einer Bootstrap-Vorselektion durchgeführt, gefolgt von der schrittweisen Regression mit den Einstellungsparametern:  $\varepsilon_{Ap,th} = 1\%$  bzw.  $P_{ein} = 0,7$  und  $P_{aus} = 0,8$ . Diese Auswahl führt dazu, dass sich mehrere Parameter an der Lösung des Gleichungssystems beteiligen. Somit wird die Möglichkeit eingeräumt, Schäden zu identifizieren, die sich auf mehrere Elemente verteilen. Die Ergebnisse der Lokalisation für beide Strukturkomponenten (Turmsegment und Tripodbein) bei der Betrachtung dieser Schäden zeigen Abbildung 5.43 und Abbildung 5.44.



**Abbildung 5.43: Lokalisierter Turmschaden**

Aus dem oberen vergrößerten Bereich in Abbildung 5.43 und Abbildung 5.44 geht die betragsmäßige Parameterveränderung und die damit entsprechenden Linearisierungsfehler nach der Schadenslokalisierung hervor. Der untere Teil stellt die Steifigkeitsreduktion in der


Umgebung der bereits lokalisierten Parameter nach dem Optimierungsvorgang dar, siehe dazu Abschnitt 3.4.2.2 und 3.4.2.3. In beiden Fälle wurden die Schäden korrekt identifiziert.



**Abbildung 5.44: Lokalisierter Tripodscha-den**

Für die Untersuchung des Lokalisationspotentials bei überlagertem Messrauschen werden die Eigenfrequenzen und die Eigenvektoren der „gemessenen“ Modaldaten z.B. um  $c_{df} = 0,5\%$  bzw.  $c_{d\varphi} = 5\%$  gestört<sup>1</sup>. Es werden 30 Simulationen mit gleichem Störpegel auf den Moden initialisiert. Höhere Rauschniveaus, insbesondere auf die Eigenfrequenzen, haben dazu geführt, dass eine Schadenslokalisierung im Tripodbereich bei der vorhandenen Sensor-konfiguration und Schadensgröße nicht mehr möglich war. Abbildung 5.45 zeigt beispielhaft die Auswirkung des Rauschens auf den Residuenvektor für den „Turmscha-den“.

<sup>1</sup> Hierbei handelt es sich um ein normalverteiltes Rauschen mit einer maximalen Amplitude von 0,5% der Standardabweichung der Eigenfrequenzen bzw. 5% der Standardabweichung der Eigenvektoren. Dieses Störniveau wird zur Lokalisation des Turmschadens genutzt. Das Rauschen auf den Eigenfrequenzen und den Eigenvektoren für den Tripodscha-den beträgt  $c_{df} = 0,1\%$  bzw.  $c_{d\varphi} = 5\%$ .



**Abbildung 5.45: Auswirkung des Rauschens ( $c_{df} = 0,5\%$  und  $c_{d\varphi} = 5\%$ ) auf das Residuum bei einem Turmschaden**

Die Ergebnisse der Lokalisation unter dem Einfluss des Rauschens auf die Modaldaten sind in Abbildung 5.46 dargestellt. Hierbei handelt es sich um Mittelwerte der 30 Simulationen. Der Turmschaden wird korrekt identifiziert, aber das Verfahren zeigt nicht alle geschädigten Elemente an. Die Auswirkung des Schadens verteilt sich stattdessen nur auf wenige Schadensparameter, siehe Abbildung 5.46, links. Anders ist das Verhalten bei dem eingebauten Tripodschaden. Hier verteilt sich dieser auf mehrere Schädigungsparameter des Tripodbeins, siehe Abbildung 5.46, rechts. Dieses Verhalten ist möglicherweise auf die hohe Steifigkeit der Struktur und auf die fehlende Sensorinformation im Tripodbereich zurückzuführen.

Wie in der Tabelle A.1 und der Tabelle A.2 angedeutet, haben Schäden in Turm- oder Tripodbereich unterschiedliche Einflüsse auf die Veränderungen der Struktureigenschwingungen. Dadurch sind gleichzeitige Schäden in beiden Bereichen nur bedingt simultan identifizierbar, da der Turmschaden den Tripodschaden überdeckt.

Um zwei gleichzeitige Schäden zu betrachten, wird der Tripodschaden durch eine E-Modul-Reduktion um 90% und der Turmschaden durch eine E-Modul-Reduktion um 40% simuliert. Auch hier werden 30 Simulationen unter dem Einfluss von Rauschen auf die Modaldaten durchgeführt. Das Ergebnis der Schadenslokalisierung in Form von gemittelten Parameterveränderungen ist in Abbildung 5.47, oben, dargestellt. Beide Schäden sind gleichzeitig korrekt lokalisiert. Nach der Modelloptimierung zeigt der Turm und das Tripodbein im Schadensbereich eine Steifigkeitsabnahme von ca. 40% bzw. 70%.




Abbildung 5.46: Lokalisierungsergebnisse: Turmschaden (links); Tripodschaden (rechts)





Abbildung 5.47: Gleichzeitig lokalisierte Schäden in Turm- und Tripodbereich

### 5.1.3 Schadenslokalisierung am Beispiel einer *Steelquake*-Struktur

Um die Anwendbarkeit der Lokalisationsmethode auf reelle Strukturen zu validieren, wird diese im Folgenden auf eine zweigeschossige Struktur angewendet. Hierbei handelt es sich um eine sogenannte *Steelquake*-Struktur, dargestellt in Abbildung 5.48, links. Diese besteht aus Stahlträgern, zwei Betonzwischendecken und zwei Stockwerkrahmen mit den Abmessungen  $8\text{m} \times 3\text{m} \times 9\text{m}$ . Die Struktur wurde mit Hilfe von hydraulischen Shakern einer



dynamischen Belastung ausgesetzt. Dadurch soll eine Erdbebenbeanspruchung simuliert werden. Einer von den drei durch Materialermüdung entstandenen Rissen ist in Abbildung 5.48, rechts, dargestellt. Die Positionen der drei Risse in den Stahlträgern zeigt das Modell aus Abbildung 5.49, links.




**Abbildung 5.48: *Steelquake*-Struktur im europäischen Forschungszentrum „ELSA-JRC“ in Ispra, Italien (links) und Riss in einem Längsträger (rechts)**

Sowohl vor als auch nach der Schädigung wurden experimentelle Modalanalysen durchgeführt. Die gravierende Veränderung des dynamischen Verhaltens durch die gleichzeitigen Schäden ist in Tabelle A.3 im Anhang dargestellt. Hier können Veränderungen in den Eigenfrequenzen von bis zu 14,5% und in den MAC-Werten von bis zu 31% festgestellt werden. Das Sensornetzwerk besteht aus 15 eindimensionalen Beschleunigungssensoren, deren Positionen und Messrichtungen in Abbildung 5.49, rechts, angegeben sind.

Das Referenzmodell der Struktur besitzt 1188 FHG und wurde aus 72 vierknotigen Schalenelementen und 160 zweiknotigen Balkenelementen aufgebaut. Mit den Schalenelementen lassen sich die beiden Zwischendecks unter Verwendung von orthotropen Materialgesetzen modellieren. Die verschiedenen Träger bestehen aus unterschiedlichen isotropen Profilen und sind mit Balkenelementen modelliert. Am Boden ist die Struktur durch Verschraubungen fixiert, diese Auflagerung wird durch Federelemente modelliert. Die zu

identifizierenden Schäden befinden sich modellmäßig an den Elementen 15, 90 und 107, siehe auch Abbildung 5.49, links.

Zur Schadenslokalisierung stehen zehn Moden zur Verfügung, welche an die Referenzmessung angepasst werden. Das Ergebnis und die MAC-Werte werden jeweils in Tabelle A.4 im Anhang dargestellt.



**Abbildung 5.49: Schadenstellen (links) und Sensorpositionen (rechts)**

Zu Schadenslokalisierungszwecken wird die Parametervorselektion mit Hilfe des Bootstrap-Verfahrens angewendet. Anschließend erfolgt die Parameterselktion mit Hilfe der schrittweisen Regression unter Verwendung der Parameter  $P_{ein} = 0,7$  und  $P_{aus} = 0,8$ . Um nicht signifikante Schadensparameter schon direkt bei der Vorselektion ignorieren zu können<sup>1</sup>, wird der Schwellenwert für die Bootstrap-Vorselektion auf  $\varepsilon_{\Delta p, th} = 10\%$  eingestellt. Als Parameterschätzungsverfahren kommt die robuste Regression mit einer „Logistic“-Einflussfunktion zum Einsatz.

Abbildung 5.50 zeigt das Ergebnis der Schadenslokalisierung mit den realen Messdaten. Die Schäden an den Elementen 15 und 90 werden korrekt identifiziert. Anstatt des Elements 107 zeigt sich das Element 3 als „geschädigt“. Dieses Ergebnis ist akzeptabel, da der große Riss tatsächlich direkt an dem Knoten zwischen den beiden Elementen liegt. Infolge der Symmetrie der Struktur und der Sensorpositionierung taucht jedoch das Element 40 als geschädigt auf, das symmetrisch gegenüber dem Element 3 platziert ist. Dabei muss aber

<sup>1</sup> Es war bekannt, dass es sich bei der Struktur um große Schäden handelt.

beachtet werden, dass die geschätzte lineare Steifigkeitsabnahme des Elements 40 relativ klein im Vergleich zur Steifigkeitsabnahme der anderen drei Elemente ist.




Abbildung 5.50: Lokalisationsergebnis an der *Steelquake*-Struktur


Wie bei der Schadenslokalisierung an der OWEA und an dem Simulationsbeispiel 2, führt auch hier, der im Abschnitt 2.3 erwähnte Linearisierungsfehler während der Schadenslokalisierung zu unrealistisch hohen identifizierten Parameterveränderungen: 300% am El. 3, 340% am El. 90, 200% am El. 15 und 100% am Element 40. Erst nach dem *Modelupdating* stellt sich auf Grund einer sehr hohen Steifigkeitsabnahme in den als geschädigt lokalisierten Strukturbereichen heraus, dass die Balken an den Schadensstellen fast durchgerissen sind, was auch der Realität entsprach.

Anhand dieses Beispiels wurden auch unterschiedliche Studien bzgl. der Konfiguration für die Startwerte der Vorselektionsalgorithmen auf die Ergebnisse der Schadenslokalisierung an der *Steelquake*-Struktur durchgeführt. Diese sind in [TIAN 2010] dargestellt. Dabei konnte eine gewisse Abhängigkeit der Lokalisationsergebnisse von den manuellen Anpassungen z.B. den Überschreitungswahrscheinlichkeitswerten bei der schrittweisen Regression festgestellt werden. Die Ergebnisse zeigen allerdings deutlich, dass die identifizierten Schäden in der Nähe oder genau an den tatsächlichen Schädigungsorten lokalisiert sind. So konnte durch eine konservativere Auswahl der Regressionsparameter mit  $P_{ein} = 0,1$  und  $P_{aus} = 0,2$  vermieden

werden, dass fälschlicherweise ein Schaden am Element 40 angezeigt wird, gleichzeitig wurde aber auch der tatsächliche Schaden am Element 15 nicht mehr deutlich erkannt<sup>1</sup>.

## 5.2 SCHADENSERKENNUNG AN MASCHINENKOMPONENTEN

In diesem letzten Unterkapitel des Ergebnisteils werden Signale von aktuell betriebenen pitch-gesteuerten Windenergieanlagen ausgewertet. Dabei wird der Triebstrang der Anlage vom Generator bis zur langsamen Welle an unterschiedlichen Stellen untersucht, vgl. Abbildung 5.51.



**Abbildung 5.51: Triebstrang einer WEA; Quelle: Firma  $\mu$ -sen GmbH**

Es wird jeweils nur auf die charakteristischen Frequenzen eingegangen, die den Schaden betreffen. Andere, zum Teil größere Peaks, sind nicht Teil der Analyse und werden daher nicht weiter beachtet. Konkret werden folgende Schäden untersucht:

- Innenringschaden des Lagers beim Generator,
- Innenringschaden des Lagers bei der Zwischenwelle,
- Sonnenradschaden am Planetengetriebe.

<sup>1</sup> Diese Elemente werden wegen  $P_{ein} = 0,1$  schon bei dem Vorwärtselektionsschritt aus dem Gleichungssystem herausgelassen.

Die Schadensausmaße sind dem Verfasser der Arbeit nicht bekannt. Aus diesem Grund werden hier ausschließlich die klassischen Methoden mit den Ansätzen aus Kapitel 4 anhand der gleichen gemessenen Signale hinsichtlich der Schadensdiagnose miteinander verglichen. Dadurch soll die Überlegenheit der Verfahren aus Kapitel 4 zur Entdeckung kleiner Schäden bei einem schlechten Signal-zu-Rauschen-Verhältnis und langen Signalübertragungswegen gegenüber den klassischen Methoden demonstriert werden. Die Signale wurden in der Nähe der betrachteten Maschinenkomponenten mit Beschleunigungsaufnehmern gemessen<sup>1</sup>.


### 5.2.1 Innenringschaden eines Lagers beim Generator einer Pitch-Anlage

Im Folgenden wird ein Innenringschaden an einem Lager beim Generator einer WEA untersucht. Die charakteristischen Frequenzen und Queffrenzen sind in Tabelle 5.3 zusammengefasst. Die Einstellparameter für die durchgeführten Berechnungen befinden sich in Tabelle A.5.

		Entsprechende Queffrenz
Mittlere Drehfrequenz der schnellen Welle	20,82 Hz	48,0 ms
Lagerinnenringschaden	112,7 Hz	8,9 ms

**Tabelle 5.3: Charakteristische Frequenzen des betrachteten Signals**

Da es sich um eine Pitch-Anlage handelt, wird das digitale Order-Tracking angewendet (siehe Abschnitt 4.3), obwohl die Drehzahlschwankung im betrachteten Zeitraum von 13,5 Sekunden sehr gering ist (siehe Abbildung 5.52). Die Standardabweichung der Drehzahl beträgt lediglich 0,0059 Hz. Dies entspricht einer Abweichung von weniger als 0,03 % der mittleren Drehzahl.

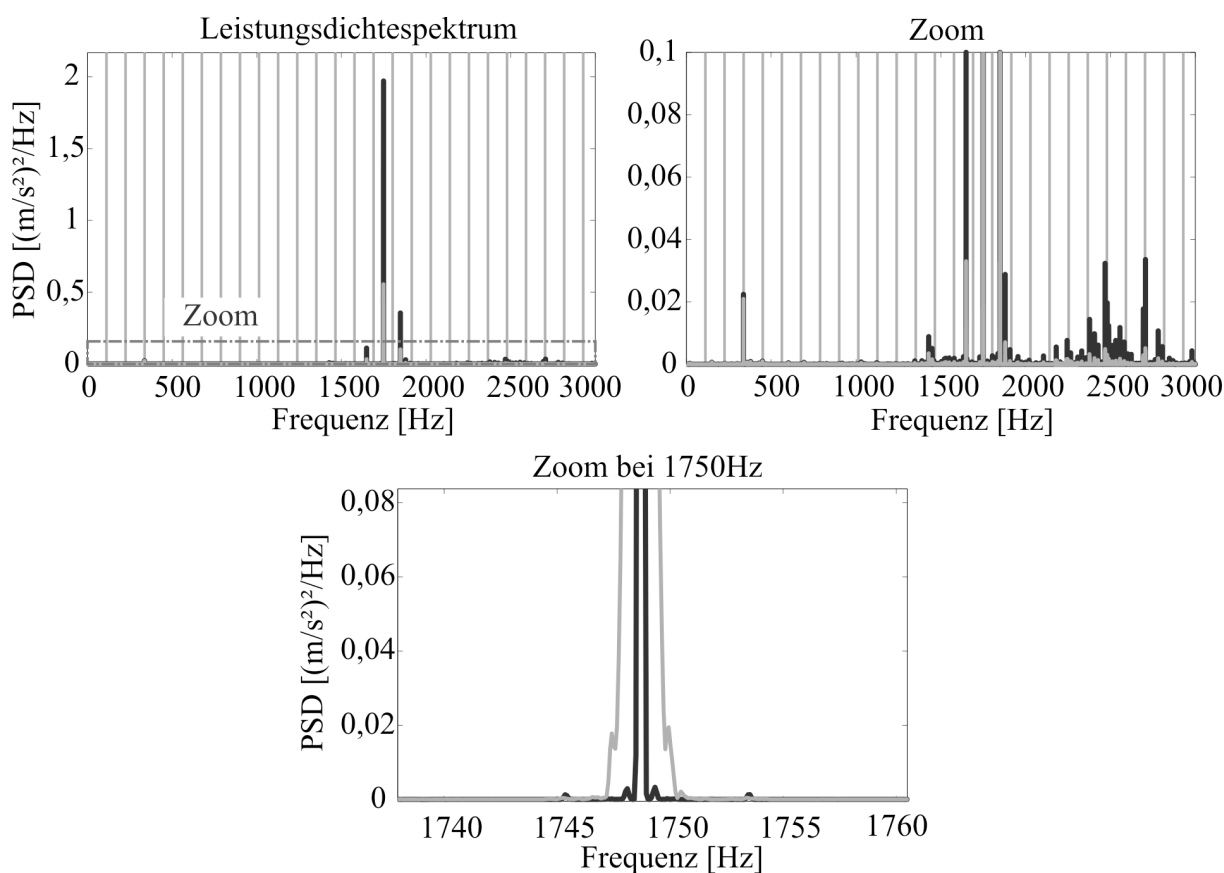


**Abbildung 5.52: Drehzahlschwankung des Signals**

<sup>1</sup> Die Position der Beschleunigungsaufnehmer ist hier nicht dargestellt. Hier wird ausschließlich erläutert, wie akkurat die eine oder andere Methode einen Schaden auf Grund des gleichen Signals identifizieren kann.

In Abbildung 5.53 ist der Vergleich des Leistungsdichtespektrums mit und ohne Order-Tracking dargestellt. Da die Standardabweichung des Signals sehr gering ist, verschieben sich die Peaks bei Anwendung des Order-Trackings nicht. Allerdings nimmt die Leistungsdichte bei einigen Frequenzen deutlich zu, beispielsweise bei ca. 1750 Hz (siehe Abbildung 5.53 links) oder im Bereich von 2000 bis 3000 Hz (siehe Abbildung 5.53 rechts), da die Peaks dann weniger verschmiert sind.


Der Innenringschaden geht aus dem Leistungsdichtespektrum kaum hervor. Lediglich bei der dritten Harmonischen (338,1 Hz) ist ein Peak klar zu erkennen (siehe Abbildung 5.53 rechts).



**Abbildung 5.53: Leistungsdichtespektren mit (schwarz) und ohne Order-Tracking (grau) bei verschiedenen Skalierungen; (graue vertikale Linien: Vielfache der Schadensfrequenz)**


Der Schaden geht auch aus dem Hüllkurvenspektrum nicht deutlich hervor. Zwar entstehen Peaks bei der charakteristischen Frequenz und deren Harmonischen (siehe graue vertikale Linien Abbildung 5.54 rechts), diese sind jedoch im Vergleich zu den Peaks bei anderen Frequenzen marginal (Abbildung 5.54 links). Da es sich um einen Innenringschaden handelt, müssten zudem auch Seitenbänder zu sehen sein (die Überrollfrequenzen werden mit der Drehfrequenz der Welle moduliert). Diese sind jedoch nicht zu erkennen, da das Rauschen und der Einfluss anderer Signalkomponenten groß sind.

Das Order-Tracking hat einen geringeren Einfluss auf das Hüllkurvenspektrum als auf das Leistungsdichtespektrum. Dies ist auch zu erwarten, da aus Abschnitt 2.5.2 bekannt ist, dass das Hüllkurvenspektrum weniger sensitiv auf zyklotionäres Verhalten reagiert (geringe Drehfrequenzschwankungen können auch als zyklotionäres Verhalten angesehen werden).



**Abbildung 5.54: Hüllkurvenspektren mit Order-Tracking bei verschiedenen Skalierungen; (graue gestrichelte Linien: mittlere Drehfrequenz, graue Linien: Schadensfrequenz)**

Der Schaden wird hingegen im Leistungsspektrum deutlich, vgl. Abbildung 5.55. Hierbei werden mehrere Harmonische der charakteristischen Schadensfrequenz (graue vertikale Linien) getroffen. Besonders hohe Auslenkungen werden bei den charakteristischen Schadensfrequenzen in der Nähe der Drehfrequenzen (graue gestrichelte vertikale Linien) registriert. Dies deutet auf den Innenringschaden hin, da dieser durch die Drehfrequenz amplitudenmoduliert wird.



**Abbildung 5.55: Leistungsspektrum mit Order-Tracking; (graue gestrichelte Linien: mittlere Drehfrequenz, graue Linien: Schadensfrequenz)**

Mit Hilfe der zyklischen Kohärenz werden viele verschiedene, zyklisch wiederkehrende Frequenzen ermittelt, die hauptsächlich im  $f$ -Frequenzbereich von 5000 bis 7000 Hz auftreten (siehe Abbildung 5.56). Die Schadensfrequenz wird hingegen besonders deutlich im  $f$ -

Frequenzbereich von 0 bis 500 Hz und von 8000 bis 8500 Hz (siehe grau markierte Bereiche). Die zyklische Kohärenz aus der  $\alpha$ -Ebene betrachtet, ist für die verschiedenen  $f$ -Frequenzbereiche in der Abbildung 5.57 und der Abbildung 5.58 dargestellt.

In Abbildung 5.57 wird der komplette  $f$ -Frequenzbereich berücksichtigt. Insbesondere die dritte Harmonische der Schadensfrequenz ist gut zu erkennen. Die erste und zweite Harmonische treten hingegen aufgrund anderer höherer Peaks in ihrer Nähe nicht so deutlich hervor. Betrachtet man nur den  $f$ -Frequenzbereich von 0 bis 500 Hz, sind alle drei Schadenspeaks deutlich zu erkennen (siehe Abbildung 5.58 links). Auch die Amplitudenmodulation durch die Drehfrequenz wird durch die Seitenbänder hervorgebracht. Dies ist auch im  $f$ -Frequenzbereich von 8000 bis 8500 Hz zu erkennen (siehe Abbildung 5.58 rechts). Hierbei sind allerdings außer der Schadensfrequenz und der Drehfrequenz auch andere Frequenzen höherer Amplitude wahrnehmbar.




Abbildung 5.56: Zyklische Kohärenz





Abbildung 5.57: Zyklische Kohärenz aus der  $\alpha$ -Ebene im kompletten  $f$ -Frequenzbereich betrachtet (graue gestrichelte Linien: Drehfrequenz, graue Linien: Schadensfrequenz)





**Abbildung 5.58:** Zyklische Kohärenz aus der  $\alpha$ -Ebene betrachtet im  $f$ -Frequenzbereich von 0 bis 500 Hz (links) und von 8000 bis 8500 Hz (rechts); (graue gestrichelte Linien: Drehfrequenz, graue Linien: Schadensfrequenz)

### 5.2.2 Innenringschaden an einem Lager der Zwischenwelle einer Pitch-Anlage

Im nächsten Schritt wird ein Lagerschaden der langsamer drehenden Zwischenwelle untersucht. Dabei wird der Entwicklungsprozess des Schadens durch zwei Signale verdeutlicht:

- 1) Signal im Frühstadium des Schadens
- 2) Signal bei deutlich ausgeprägtem Schaden

#### 5.2.2.1 Signal im Frühstadium des Schadens

Die schnelle Referenzwelle beim Generator dreht sich mit einer mittleren Frequenz von 22,5 Hz. Die Standardabweichung ist mit 0,1 Hz (entspricht ungefähr 0,5 % der mittleren Drehzahl) wesentlich höher als bei dem Signal in Abschnitt 5.2.1. Dies liegt daran, dass die Pitch-Anlage im betrachteten Zeitraum von 10 Sekunden tendenziell etwas schneller wird, wie aus Abbildung 5.59 hervorgeht.




**Abbildung 5.59:** Drehfrequenz der schnellen Welle im betrachteten Signal

Die relevanten charakteristischen Frequenzen und entsprechenden Queffrenzen sind in Tabelle 5.4 zusammengefasst. Weitere Einstellparameter für die durchgeführten Berechnungen befinden sich in Tabelle A.6.

		Entsprechende Queffrenz
Mittlere Drehfrequenz der Zwischenwelle	5,97 Hz	167,4 ms
Lagerinnenringschaden	49,9 Hz	20 ms

**Tabelle 5.4: Charakteristische Frequenzen des betrachteten Signals**


Im Leistungsdichtespektrum kann auf den ersten Blick kein Schaden erkannt werden (vgl. Abbildung 5.60, links). Der Innenringschaden ist im Hüllkurvenspektrum durch die erhöhte Amplitude bei der Schadensfrequenz angedeutet, wie aus der Abbildung 5.60, rechts, hervorgeht. Die zu erwartenden für einen Innenringschaden typischen Seitenbänder, als Resultat der Amplitudenmodulation durch die Drehfrequenz der Zwischenwelle, sind dagegen nicht ausgeprägt.



**Abbildung 5.60: Leistungsdichtespektrum (links) und Hüllkurvenspektrum (rechts) mit Order-Tracking (graue gestrichelte Linien: mittlere Drehfrequenz, graue Linien: Schadensfrequenz)**


Im Leistungsdichtespektrum ist der Schaden in diesem recht frühen Stadium schon deutlich zu sehen (Abbildung 5.61, links). Die Schadensqueffrenz ist in unmittelbarer Nähe der Drehqueffrenz der Zwischenwelle stark erhöht. Das bedeutet, dass das Leistungsdichtespektrum die Amplitudenmodulation durch die Drehqueffrenz der Welle registriert. Auch die Drehqueffrenz selbst wird im Gegensatz zum Hüllkurvenspektrum deutlich. Das Leistungsdichtespektrum ist also ohne weitere Signalvorverarbeitungsmethoden in der Lage, den Innenringschaden zu identifizieren.

Die spektrale Kurtosis zeigt zwar periodisch wiederkehrende Frequenzen bei ca. 550 und 900 Hz, allerdings können keine Aussagen darüber getroffen werden, ob diese tatsächlich auf den Innenringschaden zurückzuführen sind (siehe Abbildung 5.61 rechts).



**Abbildung 5.61: Leistungsspektrum (links) und spektrale Kurtosis (rechts) mit Order-Tracking; (graue gestrichelte Linien: mittlere Drehfrequenz, graue Linien: Schadensfrequenz)**

Mittels zyklischer Kohärenz geht die Schadensfrequenz bei Betrachtung des kompletten  $f$ -Frequenzbereichs ähnlich gut hervor wie beim Hüllkurvenspektrum (siehe Abbildung 5.62 und vgl. mit Abbildung 5.60, rechts).



**Abbildung 5.62: Zyklische Kohärenz mit Order-Tracking aus der  $\alpha$ -Ebene betrachtet im kompletten  $f$ -Frequenzbereich (graue gestrichelte Linien: mittlere Drehfrequenz, graue Linien: Schadensfrequenz)**

Die Anwendung des Kurtogramms zeigt, dass das Signal das Maximum bei der Mittenfrequenz  $f_c = 350$  Hz und einer Fensterlänge von 384 Abtastschritten, entsprechend einer Bandpassbreite  $f_{band}$  von ca. 310 Hz besitzt. Eine zweite Erhöhung der Kurtosis ist bei einer Mittenfrequenz  $f_c = 1100$  Hz und einer Fensterbreite von 256 Abtastschritten, entsprechend einer Bandpassbreite  $f_{band}$  von ca. 460 Hz, zu verzeichnen. Hier ist die Kurtosis allerdings nur ca. halb so hoch wie beim Maximum.

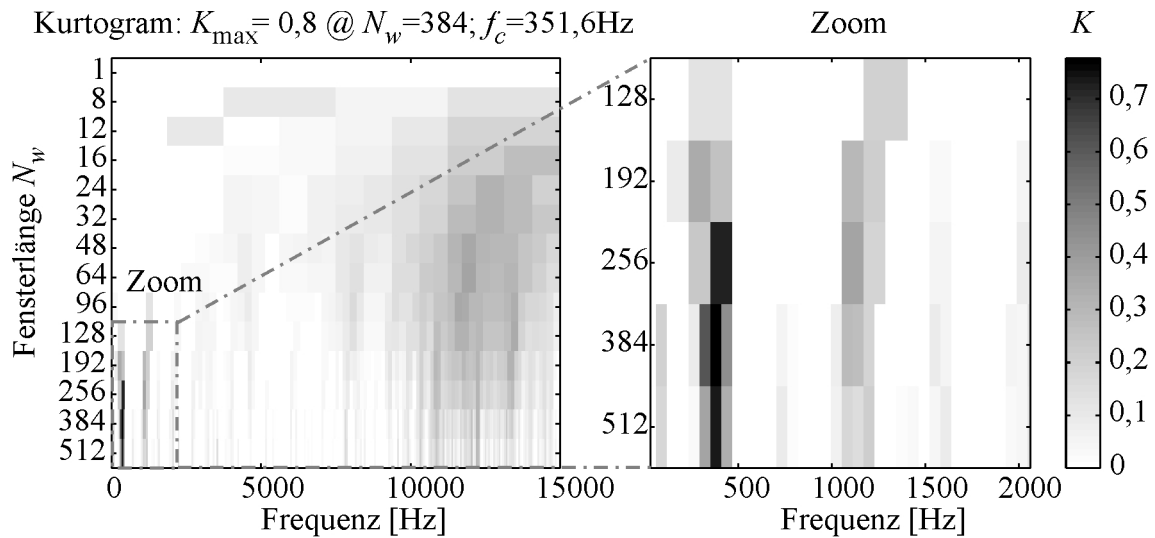


Abbildung 5.63: Kurtogramm des Signals (links) und eine Vergrößerung (rechts)

Die Betrachtung der zyklischen Kohärenz in den  $f$ -Frequenz-Bereichen von 200 bis 600 Hz und von 1000 bis 1200 Hz sind in Abbildung 5.64 links und rechts veranschaulicht. Neben der Schadensfrequenz (graue vertikale Linien) erkennt man in diesen Frequenzbereichen zusätzlich die Amplitudenmodulation durch die Drehfrequenz der Zwischenwelle, die sich in Form von Seitenbändern niederschlägt (graue gestrichelte vertikale Linien). Während die Schadensfrequenz im  $f$ -Frequenzbereich von 1000 bis 1200 Hz (Abbildung 5.64 rechts) etwas ausgeprägter als im Bereich von 200 bis 600 Hz ist, zeigt sich hier die Amplitudenmodulation deutlicher. Der Innenringschaden wird folglich, trotz des frühen Schadensstadiums, bei Anwendung der zyklischen Kohärenz identifiziert.





Abbildung 5.64: Zyklische Kohärenz mit Order-Tracking aus der  $\alpha$ -Ebene betrachtet im  $f$ -Frequenzbereich von 200 bis 600 Hz (links) und von 1000 bis 1200 Hz (rechts); (graue gestrichelte Linien: mittlere Drehfrequenz, graue Linien: Schadensfrequenz)

Wie effektiv das Kurtogramm auch zur optimalen Bandpassfilterung genutzt werden kann, ist in Abbildung 5.63 gezeigt. Aus den Hüllkurvenspektren der beiden bandpassgefilterten Signalen geht der Innenringschaden eindeutig hervor (siehe Abbildung 5.65). Wie bei der

zyklischen Kohärenz sticht bei der ersten Bandpassfilterung ( $f_c = 350$  Hz,  $f_{band} = 310$  Hz) die Drehfrequenz der Zwischenwelle in Form von Seitenbändern um die Schadensfrequenz hervor (siehe Abbildung 5.65 links).




**Abbildung 5.65: Hüllkurvenspektren der bandpassgefilterten Signale:  $f_c = 350$  Hz,  $f_{band} = 310$  Hz (links) und  $f_c = 1100$  Hz,  $f_{band} = 460$  Hz (rechts)**

Bei der zweiten Filterung ( $f_c = 1100$  Hz,  $f_{band} = 460$  Hz, siehe Abbildung 5.65 rechts) wird die Schadensfrequenz deutlicher, die auch bei der dritten Harmonischen noch zu sehen ist. Im Vergleich zum Hüllkurvenspektrum ohne Bandpassfilterung ist der Schaden bei den beiden bandpassgefilterten Signalen wesentlich besser zu erkennen.

### 5.2.2.2 Signal bei deutlich ausgeprägtem Schaden

Bei dem im Folgenden betrachteten Signal ist derselbe Schaden bereits deutlich fortgeschritten. Die schnelle Referenzwelle beim Generator wird im betrachteten Zeitabschnitt von 10 Sekunden allgemein langsamer (siehe Abbildung 5.66). Daher ist die Standardabweichung mit 0,51 Hz (entspricht ungefähr 2 % der mittleren Drehzahl) wesentlich höher als bei dem Signal in Abschnitt 5.2.1 und auch bei dem Signal aus Abschnitt 5.2.2.1, dem Frühstadium dieses Schadens. Daher wird in diesem Abschnitt unter anderem nochmals auf die Wichtigkeit des Order-Trackings eingegangen.



**Abbildung 5.66: Drehzahl des Signals im betrachteten Zeitraum**


Die Drehzahlfrequenz der Welle und die charakteristische Frequenz des Innenringschadens sind in Tabelle 5.5 dargestellt. Relevante Einstellparameter für die Berechnung der Spektren befinden sich in Tabelle A.7.

		Entsprechende Queffrenz
Mittlere Drehfrequenz der Zwischenwelle	6,9 Hz	145,2 ms
Lagerinnenringschaden	57,5 Hz	17,4 ms

**Tabelle 5.5: Charakteristische Frequenzen des betrachteten Signals**

Mit Hilfe des Leistungsdichtespektrums kann bei globaler Betrachtung kein unmittelbarer Schaden festgestellt werden (siehe Abbildung 5.67, links). Allerdings wird hierbei, wie in den vorhergehenden Abschnitten bereits gezeigt, der Effekt des Order-Trackings deutlich, der eine Verschmierung der Frequenzen durch Drehzahländerungen verhindert.


Im Gegensatz zu Abschnitt 5.2.1 wird der Schaden im Leistungscpstrum nur dann ausgeprägt, wenn das Order-Tracking angewendet wird (siehe Cepstrum in schwarz in Abbildung 5.67 rechts, vergleiche auch Abbildung 5.61 links). Dies entspricht den Erwartungen, da das Leistungscpstrum nur periodisch wiederkehrende Peaks erkennt. Wenn der Abstand zwischen den Peaks jedoch größer oder kleiner wird, wie es bei Drehzahländerungen der Fall ist, werden diese Peaks nicht mehr detektiert. Auch hier kommen, wie beim vorhergehenden Signal mit einem im Frühstadium befindlichen Schaden, die Schadenspeaks im Leistungscpstrum vor allem in unmittelbarer Nähe zu den Drehqueffrenzen vor.



**Abbildung 5.67: Leistungsdichtespektrum (links) und Leistungscpstrum (rechts) mit (schwarz) und ohne Order-Tracking (grau); (graue vertikale gestrichelte Linien: mittlere Drehfrequenz, graue vertikale Linien: Schadensfrequenz)**

Im Hüllkurvenspektrum wird der ausgeprägte Schaden wesentlich deutlicher als zuvor, wie aus Abbildung 5.68 links hervorgeht. Da die Drehzahl im betrachteten Zeitraum nicht


sinusförmig schwankt, sondern generell abnimmt, sind die Peaks bei den charakteristischen Frequenzen ohne Order-Tracking sehr verschwommen (siehe die graue Kurve in Abbildung 5.68, rechts).




**Abbildung 5.68:** Hüllkurvenspektren mit (schwarz) und ohne Order-Tracking (grau) bei verschiedenen Skalierungen; (graue vertikale gestrichelte Linien: mittlere Drehfrequenz, graue vertikale Linien: Schadensfrequenz)

Der Schaden kann eindeutig als Innenringschaden identifiziert werden, da die Schadenspeaks von Seitenbändern mit der Drehfrequenz der Zwischenwelle umgeben sind (graue gestrichelte Linien in Abbildung 5.68 links).

Auch bei der zyklischen Kohärenz erkennt man einen ausgeprägten Innenringschaden (siehe Abbildung 5.69 und Abbildung 5.70). Der Schaden kommt wie in dessen Frühstadium im Frequenzband zwischen 1000 und 1200 Hz besonders deutlich hervor (siehe Abbildung 5.70 rechts).




**Abbildung 5.69:** Zyklische Kohärenz mit Order-Tracking



**Abbildung 5.70:** Zyklische Kohärenz mit Order-Tracking aus der  $\alpha$ -Ebene betrachtet im kompletten  $f$ -Frequenzbereich (links) und von 1000 bis 1200 Hz (rechts); (graue gestrichelte Linien: mittlere Drehfrequenz, graue Linien: Schadensfrequenz)

Wird bei der zyklischen Kohärenz das Order-Tracking nicht angewendet, so nimmt die Amplitude der Peaks im Gegensatz zum Hüllkurvenspektrum kaum ab (Abbildung 5.71). In diesem Fall entsprechen die Peaks nicht mehr genau den charakteristischen Schadensfrequenzen (graue gestrichelte vertikale Linien und graue vertikale Linien), sondern verschieben sich mit zunehmenden  $\alpha$ -Frequenzen.



**Abbildung 5.71:** Zyklische Kohärenz ohne Order-Tracking aus der  $\alpha$ -Ebene betrachtet im kompletten  $f$ -Frequenzbereich (links) und von 1000 bis 1200 Hz (rechts); (graue gestrichelte Linien: mittlere Drehfrequenz, graue Linien: Schadensfrequenz)

### 5.2.3 Sonnenradschaden am Planetengetriebe

Als nächstes wird ein Schaden am Planetengetriebe (vgl. die Skizze in Abbildung A.2 im Anhang) näher untersucht. Allgemein sind Schäden an der Planetenstufe sehr schwierig zu finden, da die Wellen sehr langsam drehen (mittlere Drehzahl der langsamen Welle hier: 1,56 Hz), viele charakteristische Frequenzen das Signal amplitudenmodulieren und der Übertragungsweg des Signals zum Sensor verhältnismäßig lang ist. Im vorliegenden Fall hat das Sonnenrad einen Verzahnungsschaden, der sich in einem relativ frühen Stadium befindet.

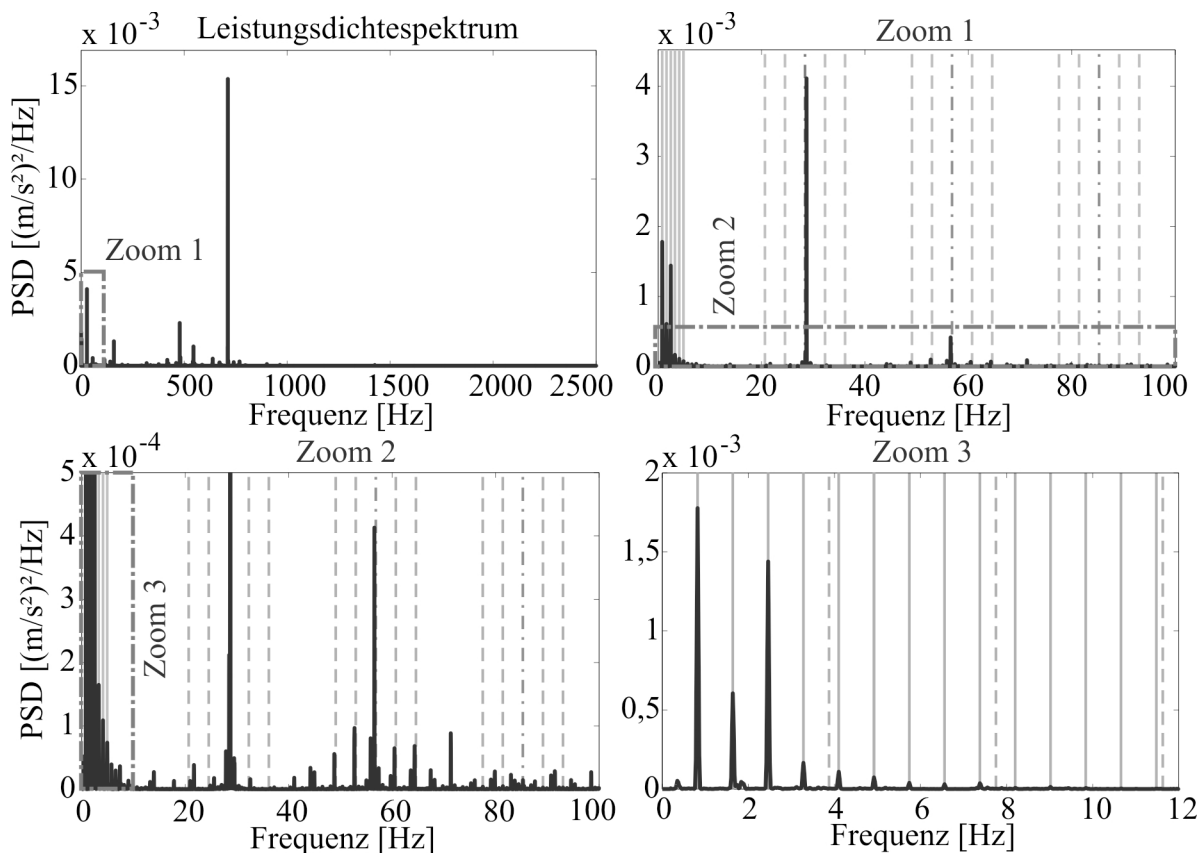


Der Schaden muss theoretisch durch die Sonnenradüberrollfrequenz sichtbar werden, siehe auch Gl. (A.28) im Anhang. Die charakteristischen Frequenzen sind explizit in Tabelle 5.6 aufgeführt.

		Entsprechende Queffenz
Zahneingriffsfrequenz der Planetenstufe	28,42 Hz	35,2 ms
Sonnenradüberrollfrequenz	3,88 Hz	258 ms
Hohlradüberrollfrequenz	0,82 Hz	1221 ms

**Tabelle 5.6: Charakteristische Frequenzen und Queffenzen für den vorliegenden Fall**

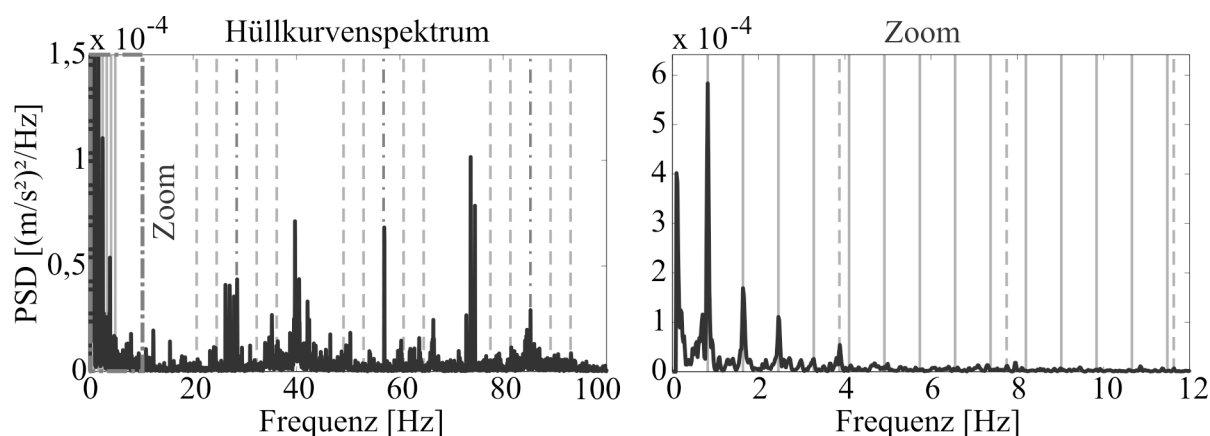
Im Leistungsdichtespektrum wird der Sonnenradschaden erst bei starker Vergrößerung des Frequenzbereichs sichtbar (vgl. Abbildung 5.72). Der Schaden zeigt sich durch die Amplitudenmodulation der stark ausgeprägten Zahneingriffsfrequenz (graue vertikale Strichpunktlinien) mit der Sonnenradüberrollfrequenz (graue gestrichelte vertikale Linien in Abbildung 5.72 im ersten Zoom-Bereich). Diese Amplitudenmodulation wird im zweiten Vergrößerungsbereich der Abbildung 5.72 noch deutlicher.



**Abbildung 5.72: Komplettes Leistungsdichtespektrum und unterschiedliche Vergrößerungsbereiche: Zoom 1, 2 und 3; (graue gestrichelte Linien: Sonnenradüberrollfrequenz, graue Linien: Hohlradüberrollfrequenz, graue Strichpunktlinien: Zahneingriffsfrequenz)**


Der Schaden kann im Leistungsdichtespektrum nur in Form von Seitenbändern der Zahneingriffsfrequenz identifiziert werden, nicht jedoch als einzelne Frequenz (zuzüglich deren Harmonischen) am Anfang des Spektrums (siehe Abbildung 5.72 in den dritten Zoom-Bereich von 0 bis 12 Hz). Hier ist allerdings die Hohlradüberrollfrequenz (graue vertikale Linien) sehr stark ausgeprägt, was in diesem Ausmaß aus Erfahrung jedoch normal ist und nicht auf einen Schaden am Hohlrad zurückzuführen ist.

Im Hüllkurvenspektrum erscheint die Signatur der Zahneingriffsfrequenz nicht so deutlich und ihre erwarteten Seitenbänder durch die relative Sonnenraddrehfrequenz sind ebenfalls nicht zu sehen (siehe Abbildung 5.73, links). Dies liegt vermutlich daran, dass bei der Bildung der Hüllkurve die Zahneingriffsfrequenz durch andere dominantere Frequenzen überdeckt wird. Die Sonnenradüberrollfrequenz erscheint einzeln ohne Harmonische in der stärker vergrößerten Darstellung des Hüllkurvenspektrums (siehe Abbildung 5.73, rechts). Der Schaden ist demnach, wenn überhaupt, besser im Leistungsdichtespektrum zu erkennen.




**Abbildung 5.73: Hüllkurvenspektrum (links) und eine ausgewählte Vergrößerung davon (rechts); (graue gestrichelte Linien: Sonnenradüberrollfrequenz, graue Linien: Hohlradüberrollfrequenz, graue Strichpunktlinien: Zahneingriffsfrequenz)**

Mittels des Leistungsdichtespektrums wird der Schaden bei der fünften Harmonischen der Sonnenradüberrollfrequenz detektiert (siehe graue gestrichelte vertikale Linien in Abbildung 5.74 links). Da dieser Peak in der unmittelbaren Nähe der Hohlradüberrollfrequenz erscheint, kann davon ausgegangen werden, dass die Sonnenradüberrollfrequenz von der im Leistungsdichtespektrum deutlichen Hohlradüberrollfrequenz amplitudenmoduliert ist. Die Hohlradüberrollfrequenz selbst wird im Leistungsdichtespektrum jedoch nur in geringem Maße wiedergegeben, da im Leistungsdichtespektrum die Hohlradüberrollfrequenzen nur in einem kleinen Frequenzbereich vorkommen.




**Abbildung 5.74: Leistungscepstrum; (graue gestrichelte Linien: Sonnenradüberrollfrequenz, graue Linien: Hohlradüberrollfrequenz, graue Strichpunktlinien: Zahneingriffsfrequenz)**

Durch die Berechnung der zyklischen Kohärenz wird der Schaden wieder sehr deutlich (siehe Abbildung 5.75 und Abbildung 5.76). Der Schaden tritt zwar nicht in Form von Seitenbändern um die Zahneingriffsfrequenz auf, jedoch als einzelne Frequenz mit ihren Harmonischen (siehe Abbildung 5.76). Insbesondere in dem mit Hilfe des Kurtogramms ermittelten  $f$ -Frequenzbereich zwischen 115 und 200 Hz kommt der Schaden relativ isoliert von anderen Frequenzen vor (siehe Abbildung 5.76, rechts).



**Abbildung 5.75: Zyklische Kohärenz**



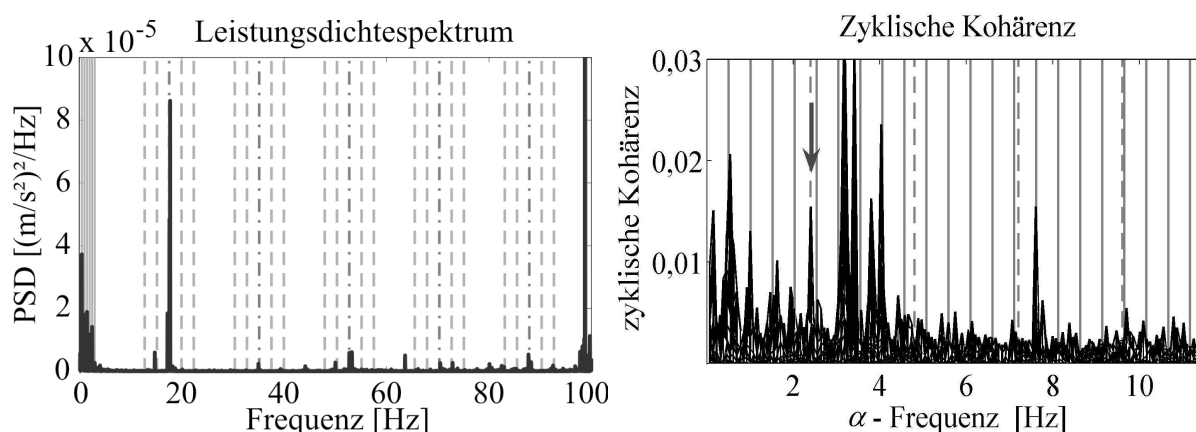
**Abbildung 5.76:** Zyklische Kohärenz aus der  $\alpha$ -Ebene betrachtet im kompletten  $f$ -Frequenzbereich (links) und im Bereich von 115 bis 200 Hz (rechts); (graue gestrichelte Linien: Sonnenradüberrollfrequenz, graue Linien: Hohlradüberrollfrequenz)

Die Effektivität der zyklischen Kohärenz kann anhand eines weiteren Signals unterstrichen werden, das vier Tage später aufgenommen wurde. Hierbei betrug die mittlere Drehzahl der langsamen Welle 0,97 Hz. Die charakteristischen Frequenzen sind in Tabelle 5.7 dargestellt.

		Entsprechende Quefrequenz
Zahneingriffsfrequenz der Planetenstufe	17,6 Hz	57 ms
Sonnenradüberrollfrequenz	2,40 Hz	417 ms
Hohlradüberrollfrequenz	0,51 Hz	1972 ms

**Tabelle 5.7:** Charakteristische Frequenzen und Quefrequenzen für 0,97 Hz Wellendrehzahl

Der Schaden hat noch ungefähr das gleiche Ausmaß, allerdings ist bei diesem Signal die Anregung wesentlich niedriger, so dass der Schaden nicht so deutlich wird. Im Leistungsdichtespektrum sind die Seitenbänder der Zahneingriffsfrequenz, wenn überhaupt vorhanden, nur sehr gering ausgeprägt (Abbildung 5.77 links). Im Vergleich zum vorhergehenden Signal hat die Leistungsdichte der Seitenbänder um mehr als den Faktor 10 abgenommen. Bei der zyklischen Kohärenz ist die Amplitude dagegen kaum zurückgegangen (siehe Abbildung 5.77 rechts grauer Pfeil).



**Abbildung 5.77: Leistungsdichtespektrum (links) und zyklische Kohärenz aus der  $\alpha$ -Ebene betrachtet im kompletten  $f$ -Frequenzbereich (rechts); (graue gestrichelte Linien: Sonnenradüberrollfrequenz, graue Linien: Hohlradüberrollfrequenz)**

Die Anwendung der klassischen Methoden auf unterschiedliche gemessene Signale an Maschinenkomponenten von Windenergieanlagen hat gezeigt, dass das Hüllkurvenspektrum zur Detektion der Lagerschäden und das Leistungsdichtespektrum zur Identifikation von Verzahnungsschaden in Planetengetriebe geeignet sind. Die Leistung dieser Methoden konnte mit Hilfe von gezielten Bandpassfilterungen gesteigert werden. Die einzige klassische Methode, die sich für alle untersuchten Schadenstypen geeignet zeigte, basiert auf den Leistungscepstren. Allerdings erwies sich die Interpretation der genannten Spektren bei nicht deutlich ausgeprägten Schäden trotz Anwendung des digitalen Order-Tracking als schwierig. Eine deutliche Verbesserung der Ergebnisse konnte mit Hilfe der zyklischen Kohärenz in Kombination mit Kurtogrammen und digitalem Order-Tracking erzielt werden, siehe auch [LAUTENSCHLAGER 2008]. Alle untersuchten Schäden der WEAs wurden damit korrekt und deutlich identifiziert.

## 6 ZUSAMMENFASSUNG UND AUSBLICK

Notwendige Perspektiven zur Energiegewinnung aus sog. alternativen Ressourcen haben in den letzten Jahren zu einem rasanten Wachstum der Windenergieindustrie geführt. Gleichzeitig stellte sich heraus, dass eine planmäßige Instandhaltung von Windenergieanlagen, besonders im Offshore-Bereich sehr kostenintensiv und wegen der schlechten Erreichbarkeit nicht immer durchführbar ist. Um trotzdem wirtschaftliche Verluste durch nicht rechtzeitig entdeckte Schäden und deren Folgen zu vermeiden, hat es sich als notwendig herausgestellt, Fernüberwachungssysteme zu entwickeln, welche dem Anlagenbetreiber Informationen über den Zustand der Anlage liefern und gegebenenfalls eine außerplanmäßige Einleitung von Wartungsarbeiten ermöglichen. Dadurch soll das Überwachungssystem den Wartungsaufwand senken und gleichzeitig die Betriebssicherheit erhöhen.

Gegenstand der vorliegenden Dissertation ist daher die Methodenentwicklung für ein integriertes Überwachungssystem hinsichtlich der Schadensfrüherkennung und der Sensor-selbstdiagnose an Offshore-Windenergieanlagen. Der Schwerpunkt der Forschung lag besonders in der Zustandsüberwachung von Turm, Fundament und Maschinenkomponenten der Anlage. Die Methoden wurden schließlich in einem autonomen Online-Überwachungssystem implementiert. Die Methodenentwicklung baut auf der Erweiterung und Kombination unterschiedlicher Ansätze der Datenanalyse aus Strukturdynamik, Informationstheorie und Maschinenzustandsüberwachung auf, damit diese den spezifischen Anforderungen für den Einsatz an Offshore-Windenergieanlagen (OWEAs) gerecht werden.

In Kapitel 3 ist dazu ein Gesamtkonzept zur Strukturüberwachung vorgestellt, das prinzipiell auf der gemessenen dynamischen Strukturantwort als Schadens- oder Sensorfehler-signatur aufbaut. Es besteht aus den drei Hauptmodulen: Schadensdetektion, Schadenslokalisation und Sensorfehlererkennung.

Dabei wurde schon bei der „einfachen“ Schadensdetektion erläutert, dass die Umgebungs- und Betriebszustände (EOC) einer Anlage eine entscheidende Rolle in der Anregung sowie in den Veränderungen ihrer dynamischen Eigenschaften spielen. Auf Grund dieser Erkenntnisse wurden mehrere existierende Methoden zur Mustererkennung und Schadensdetektion, die Veränderungen der dynamischen Struktureigenschaften infolge EOCs berücksichtigen, auf die Anwendbarkeit an OWEAs untersucht. Die entwickelten Methoden nutzen als Schadensindikatoren oder -merkmale Residuen aus *Output-Only* identifizierten linearen Systemen. Diese zeigten sich sehr sensitiv gegenüber kleinen Strukturveränderungen. Die System-

identifikation erfolgte mit Hilfe der *Stochastic Subspace Identification* Methode oder Vektor-Autoregressiven Modellen. Die somit identifizierten Systeme repräsentieren Referenzzustände der ungeschädigten Struktur. Die Kompensation der Einflüsse der Umgebungs- und Betriebsbedingungen erfolgt unter Anwendung von Klassifikationsverfahren, wobei das Gesamtsystem, in Abhängigkeit der EOCs, in mehrere repräsentative Zustände zerlegt wird. Somit lassen sich Residuen bei unterschiedlichen EOCs aus den entsprechenden repräsentativen Referenzzuständen generieren. Wenn die Residuen/Schädigungsindikatoren die dazugehörigen Klassenschwellenwerte unzulässig überschreiten, kann dies auf einen Schaden zurückgeführt werden. Damit steigt die Sensitivität der Methoden gegenüber Schäden und gleichzeitig lässt sich vermeiden, dass dynamische Systemveränderungen durch Schäden von Änderungen infolge veränderlichen Umgebungs- und Betriebszuständen maskiert werden.

Um die Annahmen für die Anwendung der *Output-Only*-Schadensdetektionsmethoden, welche eine unbekannt, aber stochastische Anregung der Struktur voraussetzen, zu gewährleisten, kam die Ausreißeranalyse zum Einsatz. Damit konnten Messdaten, die z.B. unter einer transienten Anregung der Struktur aufgenommen wurden, in einem automatischen Modus von der Auswertung ausgeschlossen werden.

Die Lokalisation erfolgte modellgestützt mit Hilfe von Modaldaten und einem FE-Modell der Anlage. Für die Extraktion der Modaldaten aus den gemessenen Strukturantworten wurden die gleichen ARV-Modelle, die man u.a. auch zu Schadensdetektionszwecken nutzte, weiterentwickelt. Mit Hilfe der Modalanalyse können die dynamischen Eigenschaften der Struktur in Form von Eigenfrequenzen, modalen Dämpfungen und komplexen Eigenvektoren und deren Veränderungen infolge variabler EOC in einem automatischen Modus beobachtet werden. Die Schadenslokalisationsmethode nutzt einen inversen sensitivitätsbasierten Ansatz [BOHLE 2005], der modellgestützt die Ursachen für Veränderungen in Residuen gemessener Modaldaten untersucht. Dabei werden mit Hilfe einer Sensitivitätsanalyse lokale Steifigkeitsveränderungen des Modells über festgelegte Schadensparameter in Korrelation mit den modalen Residuen gebracht. Die Lösung dieses inversen Problems nach den Schadensparametern erfolgt mittels der Regressionsanalyse. Um die Schädigungsorte/Schadensparameter in Gegenwart von Rauschen und Ausreißern in gemessenen Daten sowie Kollinearität in der Sensitivitätsmatrix zu identifizieren, wird von dem *Robust Ridge Regression*-Verfahren Gebrauch gemacht. Mit Hilfe der *Bootstrap-t*-Statistik und der schrittweisen Regression lassen sich eine große Anzahl an potenziellen Schadensparametern, die z.B. in ausgedehnten Modellen von OWEAs vorkommen, bis auf wenige für die untersuchten Schäden signifikante

Parameter reduzieren. Das Schadensausmaß, in Form einer linearen Steifigkeitsabnahme an den signifikanten Parametern, erfolgt mit Hilfe von Optimierungsverfahren. Die Schadenslokalisationsmethode wurde in der Berechnungsplattform FEMTools implementiert, so dass zu Schadenslokalisationszwecken auch komplexe FE-Modelle mit einer sehr hohen Anzahl an Freiheitsgraden und komplizierten Geometrien verwendet werden können.

Für die Selbstdiagnose der verwendeten Beschleunigungssensoren wurden unterschiedliche Methoden aus der Literatur untersucht und anhand von Simulationen miteinander verglichen. Zur Sensorfehlerdetektion und -isolation erfolgte die Entwicklung einer Methode, die auf der Veränderung der redundanten Information (eng. *Mutual Information*, MI) zwischen den Sensorpaaren basiert. Begleitende Simulationsbeispiele zeigen, dass die Sensorfehlerindikatoren, basierend auf der MI-Methode, den gewünschten Effekt aufweisen, dass sie relativ insensitive gegenüber Strukturveränderungen oder veränderlichen EOCs sind, aber sensitiv auf Sensorfehler reagieren. Eine Signalrekonstruktion dient zur Klärung des Sensorfehlerstyps und möglicher Ursachen für den Fehler. Hierfür wird eine multivariate Signalschätzung mit Hilfe von Kalman-Filtern angewendet. Dabei kann das „Vertrauen“ in die mit der MI-Methode als fehlerhaft identifizierten Signale durch eine geeignete Manipulation der Einträge in der Kovarianzmatrix des Messrauschens herabgesetzt werden. Somit lassen sich die fehlerbehafteten Signale mit Hilfe der weiteren Signale in dem Datensatz und des Systemzustandsraums rekonstruieren. Die für den Kalman-Filter benötigten Zustandsraummatrizen werden mit Hilfe von FE-Modellen oder direkt aus den Modaldaten, berechnet aus den ARV-Modellen oder mit der SSI-Methode, bereitgestellt.

Das Kapitel 4 stellt geeignete Methoden zur Maschinenkomponentenüberwachung in einer OWEA vor und erläutert, aus welchen Gründen diese besonders effektiv zur Überwachung langsam rotierender Maschinen von OWEA (z.B. Planetengetrieben) bei schlechten Signalübertragungswegen und dadurch ungünstigen Signal-zu-Rauschen-Verhältnissen eingesetzt werden können. Es handelt sich um eine Kombination unterschiedlicher Methoden im Frequenzbereich, die bei der Überwachung von WEA bislang noch nicht eingesetzt worden sind. Die Zyklkohärenzmethode nutzt die Spektrale Korrelation zur Untersuchung von Seitenbänderstrukturen und höheren Harmonischen von schadensrelevanten Überrollfrequenzen und unterdrückt gleichzeitig die Effekte des Signalrauschens auf die Qualität der Schadensidentifikation. Die Ergebnisse der Zyklkohärenzmethode wurden durch Einsatz der Spektralen Kurtosis und Erstellung von Kurtogrammen verbessert. Die Kurtogramme machen genau den Frequenzbereich des Signals ausfindig, in dem die Schadenssignatur am



deutlichsten vorkommt. Dadurch kann die Zyklkohärenzmethode gezielt nur in diesem Frequenzbereich näher betrachtet werden. Um Signale von drehzahlvariablen WEAs zu analysieren, findet das digitale *Order-Tracking* als Signalvorverarbeitungsmethode Anwendung. Diese Methoden, sowie die bedeutendsten klassischen Verfahren zur Maschinenzustandsüberwachung und Signalanalyse wurden in einem Softwarepaket zum *Condition Monitoring* zusammengefasst.

In Kapitel 5 ist anhand von ausgewählten Ergebnissen die Funktionalität des entwickelten Gesamtüberwachungskonzepts erläutert. Die Schadensdetektion an der Laborstruktur zeigt, dass die Schädigungsindikatoren aus Residuen identifizierter Systemzustände sehr sensitiv gegenüber sehr kleinen Schäden sind. Diese Schäden konnten, wie erwartet, nur dann identifiziert werden, wenn Klassifikationsverfahren zur Kompensation der EOC-Einflüsse auf die Indikatoren angewendet wurden. Die Sensorfehlerisolation und die Signalrekonstruktion zeigten, dass sich Signale eines schlecht an die Struktur gekoppelten Sensors korrekt identifizieren und rekonstruieren ließen.

Aus den erzielten Ergebnissen der Signalrekonstruktion ergab sich, dass die rekonstruierten Signale nicht mehr zu Schadensererkennungszwecken genutzt werden können. Dies liegt daran, dass die Schadensdetektion i.d.R. mit nur wenigen Sensoren durchgeführt wird und dadurch aus Redundanzgründen die Signale auf noch weniger Moden als die Sensoranzahl gefiltert werden müssen. Da kleine Strukturschäden sich i.d.R. erst in Veränderungen der höheren Eigenmoden bemerkbar machen, sind die rekonstruierten Signale zu Schadensidentifikationszwecken nicht mehr brauchbar. Um die rekonstruierten Signale weiter zur Schadensdiagnose in dem vorgestellten SHM-Konzept anzuwenden, muss die Struktur mit überzähligen Sensoren in Bezug zur Anzahl der interessierenden Schwingungsmoden ausgerüstet werden.

Die Dauerüberwachung der Anlage M5000-2 erfolgte anhand des erarbeiteten Konzeptes, welches auch in einer Prototyp-Software umgesetzt wurde. Hierbei fand die Übertragung der Messdaten der Anlage an die Berechnungseinheit und die Übersendung der berechneten Modaldaten, Schadens- und Sensorfehlerindikatoren an den Anlagenbetreiber über das Internet statt. Die Überwachungsergebnisse sind in Abschnitt 5.1.2 vorgestellt. Hier wurden zuerst die dynamischen Eigenschaften der Anlage über der Zeit beobachtet und die gemessenen Eigenwerte und –vektoren des Systems u.a. auch mit Hilfe eines FE-Modells zugeordnet und identifiziert. Das System zeigte, dass es während der Überwachung zu Sensorausfällen gekommen ist aber kein Strukturschaden vorhanden war. Aus diesen Gründen wurde die Möglichkeit, Strukturschäden zu identifizieren, mit Hilfe eines vereinfachten FE-

Modells der Anlage M5000-2 untersucht, wobei dieses zur Modellierung eines progressiven Schadens an einer *hot spot* Stelle der Anlage und zur Generierung von Beschleunigungsdaten verwendet wurde. Die Systemanregung und die variablen Betriebszustände der Struktur ergaben sich direkt aus an der Anlage gemessenen EOCs. Das Modell wurde erfolgreich zur Schadensdetektion bei unterschiedlich verrauschten Messsignalen und zur Durchführung von Parameterstudien bzgl. der Klassenanzahl und Lernfähigkeit der Algorithmen eingesetzt.

Die Ergebnisse und die theoretische Gestaltung der Schadensdetektion bei veränderlichen Umgebungs- und Betriebszuständen haben gezeigt, dass die Zuverlässigkeit der Detektionsergebnisse im Allgemeinen erhöht werden kann, wenn mehrere Messdaten für möglichst viele repräsentative EOCs während der Lernphase zur Verfügung stehen. Dies führt dazu, dass Schwellenwerte für den geschädigten Zustand aus vielen Daten und damit repräsentativer für die Verteilung der Schadensindikatoren aufgestellt werden können. Weitere Verbesserungen lassen sich erzielen, wenn aus Erfahrungswerten Effekte von relevanten Schäden für die Betriebssicherheit der Anlage und deren Einfluss auf die Indikatoren bekannt sind. Dann kann der Algorithmus zur Schadensdetektion durch eine geeignete Auswahl der Referenzanzahl gezielt zur Entdeckung dieser speziellen Schäden eingestellt werden.

Ein weiteres detaillierteres FE-Modell der Anlage M5000-2 mit mehr als 140.000 Freiheitsgraden wurde zu Schadenslokalisationszwecken verwendet. Hierbei wurden Schäden an einem *hot spot* und auf dem Turm der Anlage simuliert. Diese konnten bis zu einer gewissen Grenze auch bei verrauschten Modaldaten korrekt lokalisiert werden. Bei der Simulationen stellte sich heraus, dass insbesondere die Lokalisation von Schäden unterhalb der Wasseroberfläche und bei wenigen vorhandenen Sensoren schwierig ist. In Abwesenheit eines vorhandenen Schadens an der Anlage M5000-2 wurde die Möglichkeit, Schäden in realen Strukturen zu lokalisieren, anhand der sog. *Steelquake*-Struktur gezeigt. Hier konnten drei gleichzeitig vorhandene Schäden zuverlässig geortet werden.

Ein gewisser Nachteil der modellgestützten Schadenslokalisierung ist, dass die Methode sehr gute FE-Modelle und gleichzeitig akkurat gemessene Modaldaten benötigt. Um bessere Modelle zu erzielen, sind mehrere Sensoren und somit mehrere „Modellvalidierungsstellen“ anhand der Eigenvektoren notwendig. Da die Modaldaten schon durch Effekte der EOC variieren, konnte bisher die Lokalisationsmethode nur für einen Betriebszustandspunkt, der auch in dem FE-Modell modelliert wurde, erfolgreich durchgeführt werden. Nach Meinung des Verfassers ist eine automatisierte Lokalisation von Schäden bei veränderlichen EOC nur mit einem zeitveränderlichen Modell oder nur mit Einbußen seitens der Ergebnisgenauigkeit

durchführbar. Aus Sicht der Automatisierbarkeit des Prozesses muss noch beachtet werden, dass die zeitinvariante Modalanalyse „verschmierte“ Werte über den Messzeitraum liefert. An dieser Stelle würde eine zeitvariante Modalanalyse einen genaueren Einblick in die Veränderung der Moden mit der Zeit gewährleisten und dadurch die Unsicherheit in den gemessenen modalen Daten reduzieren.

Der letzte Teil des Kapitels 5 stellt die Ergebnisse der Maschinenüberwachung an pitch-gesteuerten Anlagen vor. Hierbei handelt es sich um drei schwer auffindbare Schäden an unterschiedlichen Maschinenkomponenten: einen Innenringschaden des Lagers beim Generator, einen Innenringschaden des Lagers an der Zwischenwelle, und einen Sonnenradschaden am Planetengetriebe. Alle drei Schäden konnten mit Hilfe der in dieser Arbeit vorgeschlagenen Methodenkombination korrekt identifiziert werden. Vergleichsstudien zwischen den in dieser Arbeit vorgeschlagenen Methoden und den klassischen Verfahren haben gezeigt, dass die neuen Ansätze sensitiver gegenüber Schäden in einem frühen Stadium als die klassischen Algorithmen der Maschinenzustandsüberwachung sind.

Auch wenn sich die Zyklkohärenzmethode in Kombination mit weiteren Signalverarbeitungsmethoden für eine automatisierte Überwachung eignet, lassen sich damit ausschließlich Schadenssignaturen, die sich als zyklstationäre Impulse erweisen, identifizieren. Für andere Schadenstypen, wie z.B. eine erhöhte Reibung in den Gleitlagern durch Schmierungsprobleme, sollten weitere geeignete Zustandsüberwachungsmethoden und die daraus entstehenden Indikatoren verwendet werden. Dadurch ist es ersichtlich, dass eine Gesamtdiagnose aller Maschinenkomponenten nur mit Hilfe mehrerer Verfahren samt deren spezifischen Schadensindikatoren möglich ist.

Die in dieser Arbeit entstandenen und angewendeten Konzepte zum *Structural Health Monitoring* und *Condition Monitoring* repräsentieren nach heutigem Stand der Technik eine praktikable Lösung für die Überwachung von OWEAs. Dadurch kann mit einer relativ geringen Sensoranzahl, das System global überwacht werden.

Sollten in der Zukunft neue Erkenntnisse über die *hot spots* der Struktur gewonnen und zuverlässige Sensorik für Methoden im Hochfrequenzbereich entwickelt werden, dann können lokale Überwachungsansätze die hier vorgestellten globalen Ansätze ergänzen. Aus Sicht des Verfassers repräsentiert eine Kombination zwischen globalen und lokalen Verfahren die optimale Lösung für eine zuverlässige Überwachung von OWEAs. Dadurch können die *hot spots* gezielt überwacht werden, ohne dass man Gefahr läuft, Schäden an unerwarteten Stellen nicht zu identifizieren.

**LITERATUR**

- ABDELGHANI, M. und FRISWELL, M. I., 2001: *A parity space approach to sensor validation*, Proceedings of SPIE, the International Society for Optical Engineering (Band 4359 (1)), S. 405-411.
- ANDERSEN, P., 1997: *Identification of Civil Engineering Structures using Vector ARMA Models*, Dissertation, Aalborg University.
- ANDERSEN, P.; BRINCKER, B.; PEETERS, B.; DE ROECK, G.; HERMANS, L. und KRÄMER, C., 1999: *Comparison of System Identification Methods Using Ambient Bridge Data*, Proc. of the 17th Int. Modal Analysis Conference, Kissimmee, USA.
- ANDERSEN, P. und KIRKEGAARD, P. H., 1998: *Statistical damage detection of civil engineering structures using ARMA Models*, ETATS-UNIS (3243), S. 356-362.
- ANDERSON, T. W., 1958: *Introduction to multivariate statistical analysis*, John Wiley & Sons, Inc., New York.
- ANTONI, J., 2007a: *Cyclic spectral analysis in practice*, Mechanical Systems and Signal Processing (Band 21), Nr. 2, S. 597-630.
- ANTONI, J., 2007b: *Cyclic spectral analysis of rolling-element bearing signals: Facts and fictions*, Journal of Sound and Vibration (Band 304), S. 497-529.
- ANTONI, J. und RANDALL, R. B., 2002: *Differential Diagnosis of Gear and bearing faults*, Journal of Vibration and Acoustics (Band 124), S. 165-171.
- ANTONI, J. und RANDALL, R. B., 2004a: *The Spectral Kurtosis: a useful tool for characterising nonstationary signals*, Mechanical Systems and Signal Processing (Band 20), S. 286-307.
- ANTONI, J. und RANDALL, R. B., 2004b: *The Spectral Kurtosis: application to the vibratory surveillance and diagnostics of rotating machines*, Mechanical Systems and Signal Processing (Band 20), S. 308-331.
- BALAGEAS, D.; FRITZEN, C.-P. und GÜEMES, A., 2006: *Structural Health Monitoring*, Hermes Science Publishing, London UK.
- BALASKO, B.; ABONYI, J. und FEIL, B., 2005: *Fuzzy Clustering and Data Analysis Toolbox*. URL: [www.fmt.vein.hu/softcomp](http://www.fmt.vein.hu/softcomp).
- BARNETT, V. und LEWIS, T., 1984: *Outliers in Statistical Data*, John Wiley & Sons.
- BASSEVILLE, M.; ABDELGHANI, M. und BENVENISTE, A., 2000: *Subspace-based fault detection algorithms for vibration monitoring*, Automatica (Band 36), S. 101-109.
- BASSEVILLE, M.; BOURQUIN, F.; MEVEL, L.; NASSER, H. und TREYSSÈDE, F., 2006: *Merging sensor data from multiple temperature scenarios for vibration-based monitoring of civil structures*, 3rd European Workshop on Structural Health Monitoring, Madrid, S. 759-766.
- BEZDEK, J. C., 1973: *Fuzzy Mathematics in Pattern Classification*, Dissertation, Cornell University, Ithaca.
- BIGE, Y., HANFENG, Z., RONG, W., 2006: *Analysis of microstructural alterations of normal and pathological breast tissue in vivo using AR cepstrum*, Ultrasonics (Band 44), Nr. 2, S. 211.
- BISHOP, C. M., 1995: *Neural Networks for Pattern Recognition*, Oxford Univ. Press, Oxford.
- BODEUX, J. B. und GOLINVAL, J. C., 2001: *Application of ARMA models to the identification and damage detection of mechanical and civil engineering structures*, Smart Materials and Structures (Band 10), S. 479-489.
- BOHLE, K., 2005: *Sensitivitätsbasierte Methoden zur modellgestützten Schadendiagnose mit Modaldaten*, Dissertation, Shaker Verlag, Universität Siegen.

- BOX, G. E. P., 1949: *A general distribution theory for a class of likelihood criteria*, Biometrika (Band 36), S. 317–346.
- BROERSEN, P. M. T., 2006: *Automatic Autocorrelation and Spectral Analysis*, Springer, London.
- BUNR, 2002: *Strategie der Bundesregierung zur Windenergienutzung auf See*, Bundesministerium für Umwelt, N. u. R., Deutsche Energie-Agentur.
- BUNR, 2010: *Entwicklung der erneuerbaren Energien in Deutschland im Jahr 2009*, Bundesministerium für Umwelt, Arbeitsgruppe Erneuerbare Energien.
- CASTILLO, E.; HAD, I. A. S.; BALAKRISHNAN, N. und SARABIA, J. M., 2005: *Extreme Value and Related models with Applications in Engineering and Science*, John Wiley & Sons, New Jersey.
- CIANG, C. C.; LEE, J.-R. und BANG, H.-J., 2008: *Structural health monitoring for a wind turbine system: a review of damage detection methods*, Measurement Science and Technology (Band 19).
- COX, D. R. und HINKLEY, D. V., 1974: *Theoretical Statistics*, Chapman and Hall.
- COX, D. R. und OAKES, D., 1984: *Analysis of Survival Data*, Chapman & Hall, London.
- CYBENKO, G., 1989: *Approximation by Superposition of a Signoidal Function*, Mathematical Control Signal and System (Band 4), Nr. 2, S. 303-314.
- DASCOTTE, E.; STROBBE, J. und HUA, H., 1995: *Sensitivity-based model updating using multiple types of simultaneous state variable*, IMAC XIII, Nashville, S. 1035-1041.
- DDS, 2008: *FEMTools Model Updating Theoretical Manual*, Version 3.3, Dynamic Design Solution.
- DING, S. X.; FRANK, P. M. und DING, E. L., 2002: *Observer-based fault detection schemes for linear uncertain systems*, 15th Triennial World Congress, Barcelona, Spain. URL: [www.nt.ntnu.no/users/skoge/prost/proceedings/ifac2002/data/content/02171/2171.pdf](http://www.nt.ntnu.no/users/skoge/prost/proceedings/ifac2002/data/content/02171/2171.pdf)
- DRAPER, N. R. und SMITH, H., 1998: *Applied Regression Analysis*, Wiley-Interscience, New York.
- DUDA, R. O.; HART, P. E. und STORK, D. G., 2001: *Pattern Classification*, John Wiley & Sons. Inc.
- DUNIA, R.; QIN, S. J.; EDGAR, T. F. und MCAVOY, T. J., 1996: *Identification of faulty sensors using principal component analysis*, AiChe Journal (Band 42(10)), S. 2797-2812.
- DUNN, J. C., 1974: *A Fuzzy Relative of the ISODATA Process and its Use in Detecting Compact, Well Separated Clusters*, Journal of Cybernetics (Band 3), S. 32-57.
- EFRON, B. und TIBSHIRANI, R. J., 1993: *An introduction to the bootstrap*, Hall, C., New York.
- EWINS, D. J., 2000: *Modal Testing Theory, Practice and Application*, Research Studies Press, Somerset, England.
- FAHRMEIR, L.; KÜNSTLER, R.; PIGEOT, I. und TUTZ, G., 2007: *Statistik*, 6. Auflage, Springer-Verlag.
- FARRAR, C. R.; WORDEN, K.; TODD, M. D.; PARK, G.; NICHOLS, J.; ADAMS, D. E.; BEMENT, M. T. und FARINHOLT, K., 2007: *Nonlinear System Identification for Damage Detection*, Internal Annual Report LA-14353, Los Alamos, USA.
- FASSOIS, S. D. und SAKELLARIOU, J. S., 2007: *Time series methods for fault detection and identification in vibrating structures*, Phil. Trans. Royal Society (Band 365), S. 411-448.
- FAULSTICH, S.; HAHN, B.; JUNG, H.; RAFIK, K. und RINGHANDT, A., 2008: *Appropriate Failure Statistics and Reliability Characteristics*, Deutsche Wind Energie Konferenz, DEWEK.

- FOX, L. R. und KAPOOR, M. P., 1968: *Rates of Change of Eigenvalues and Eigenvectors*, AAIA Journal (Band 6(12)), S. 2426-2429.
- FRISWELL, M. I. und MOTTERSHEAD, J. E., 1995: *Finite Element Model Updating in Structural Dynamics*, Kluwer Academic Publishers.
- FRITZEN, C.-P., 2006: *Vibration-Based Techniques for Structural Health Monitoring*, Structural Health Monitoring, Hermes Science Publishing, London, UK.
- FRITZEN, C.-P. und BOHLE, K., 2001: *Model-Based Damage Identification from Change of Modal Data – A Comparison of Different Methods*, in *Structural Health Monitoring Proc. 2nd Intl. Workshop on SHM*, Stanford, S. 849-859.
- FRITZEN, C.-P. und BOHLE, K., 2006: *Robust Regression in Model-based Structural Health Monitoring*, IMAC XXIV, Jacksonville, Florida, USA.
- FRITZEN, C.-P.; JENNEWEIN, D. und KIEFER, T., 1998: *Damage Detection Based on Model-Updating Methods*, Mechanical Systems and Signal Processing (Band 12(1)), S. 163-186.
- FRITZEN, C.-P. und KRAEMER, P., 2009: *Self-diagnosis of smart structures based on dynamical properties*, Mechanical Systems and Signal Processing (Band 23), S. 1830–1845.
- FRITZEN, C.-P.; KRAEMER, P. und KLINKOV, M., 2008: *Structural Health Monitoring of Offshore Wind Energy Plants*, 4th European Workshop on Structural Health Monitoring, Cracow, Poland, S. 3-21.
- FRITZEN, C.-P.; KRAEMER, P. und KLINKOV, M., 2010a: *An Integrated SHM Approach for Offshore Wind Energy Plants*, IMAC XXVIII, Jacksonville, Florida, USA.
- FRITZEN, C.-P.; KRAEMER, P. und KLINKOV, M., 2010b: *Schwingungsbasierte Schadensdiagnose für Offshore-Windenergieanlagen*, VDI Tagung "Schwingungsanalyse & Identifikation". Leonberg, Germany, S. 183-194.
- FRITZEN, C.-P.; MENGELKAMP, G. und GÜEMES, A., 2003: *Elimination of Temperature Effects on Damage Detection within a Smart Structure Concept*, 4th Int. Workshop on Structural Health Monitoring, Stanford University, S. 1530-1538.
- FUGATE, M. L.; SOHN, H. und FARRAR, C. R., 2001: *Vibration-Based Damage Detection Using Statistical Process Control*, Mechanical Systems and Signal Processing (Band 15 (4)), S. 707-721.
- GASCH, R. und TWELE, J., 2005: *Windkraftanlagen*, Teubner Verlag.
- GAWRONSKI, W. K., 2004: *Advanced Structural Dynamics and Active Control of Structures*, Springer.
- GERTLER, J. J., 1998: *Fault Detection and Diagnosis in Engineering Systems*, Dekker, M., New York.
- GHAHRAMANI, Z. und HINTON, G. E., 1996: *The EM-Algorithm for mixtures of factor analyzers*, Technical Report CRG-TR-96-1, University of Toronto.
- GIURGIUTIU, V., 2008: *Structural Health Monitoring: With Piezoelectric Wafer Active Sensors*, Academic Press.
- GLWIND, 2007: *Richtlinie für die Zertifizierung von Condition Monitoring Systemen für Windenergieanlagen*, Germanischer Lloyd.
- GREWAL, M. S. und ANDREWS, A. P., 2001: *Kalman Filtering: Theory and Practice using Matlab*, John Wiley & Sons Inc., New York, Chichester, Weinheim, Brisbane, Singapore, Toronto.
- GUSTAFSON, D. E. und KESSEL, W. C., 1979: *Fuzzy clustering with fuzzy covariance matrix*, Proceedings of IEEE CDC, San Diego, USA, S. 761-766.
- GUSTAFSSON, F., 2005: *Residual generation for diagnosis of additive faults in linear systems*. URL: <http://www.control.isy.liu.se/~fredrik/edu/detect/paper.pdf>.

- HAAKE, G., 2010: *Systemidentifikation mit Autoregressiven Modellen und Validierung numerischer Strukturmodelle bei Offshore-Windenergieanlagen*, Dissertation, Institut für Statik und Dynamik, Leibniz Universität Hannover.
- HAU, E., 1988: *Windkraftanlagen: Grundlagen, Technik, Einsatz, Wirtschaftlichkeit*, Springer, Berlin, Heidelberg.
- HEIER, S., 2005: *Windkraftanlagen: Systemauslegung, Netzwerkimtegration und Regelung*, Teubner, Wiesbaden.
- HELLIER, C., 2001: *Handbook of Nondestructive Evaluation*, McGraw-Hill Professional.
- HEYLEN, W.; LAMMENS, S. und SAS, P., 1998: *Modal Analysis Theory and Testing*, Kath. Universiteit Leuven, Leuven, Belgium.
- HIGHAM, N. J., 1996: *Accuracy and Stability of Numerical Algorithms*, Society for Industrial and Applied Mathematics, Philadelphia.
- HINES, J. W. und UHRIG, R. E., 1998: *Use of Autoassociative Neural Networks for Signal Validation*, Journal of Intelligent and Robotic Systems (Band 21), S. 143-154.
- HOGG, R. V., 1979: *An Introduction to Robust Estimation*, Robustness in Statistics, New York, S. 1-18.
- IEA, 2009: *Monthly Electricity Statistics, December 2009*, International Energy Agency. URL: <http://www.iea.org>.
- JIAN, Y.; QIANSHENG, C. und HOUKUAN, H., 2004: *Analysis of the weighting exponent in the FCM*, Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on (Band 34), Nr. 1, S. 634-639. URL: 10.1109/TSMCB.2003.810951
- JOHNSON, R. A. und WICHERN, D. W., 1998: *Applied multivariate statistical analysis*, Prentice-Hall, Upper Saddle River, NJ.
- JUANG, J.-N., 1994: *Applied System Identification*, Prentice Hall PTR.
- KERSCHEN, G.; DE BOE, P.; GOLINVAL, J.-C. und WORDEN, K., 2004: *Sensor validation for on-line vibration monitoring*, 2nd European Workshop on Structural Health Monitoring, Munich, S. 819-827.
- KERSCHEN, G.; DE BOE, P.; GOLINVAL, J.-C. und WORDEN, K., 2005: *Sensor validation using principal component analysis*, Smart Materials and Structures (Band 14), S. 36-42.
- KIM, H. und MELHEM, H., 2004: *Damage detection of structures by wavelet analysis*, Journal of Engineering Structures (Band 26(3)), S. 347-362.
- KIM, J. T. und STUBBS, N., 1995: *Damage Detection in Offshore Jacket Structures from Limited Modal Information*, International Journal of Offshore and Polar Engineering (Band 5(1), ISSN 1053-5381).
- KLEIN, U., 2003: *Schwingungsdiagnostische Beurteilung von Maschinen und Anlagen*, Verlag Stahleisen, Düsseldorf.
- KÖHLER, B.-U., 2005: *Konzepte der statistischen Signalverarbeitung*, Springer.
- KOHONEN, T., 2001: *Self Organizing Maps*, Springer.
- KOLERUS, J., 2000: *Zustandsüberwachung von Maschinen*, Expert-Verlag, Renningen-Malmsheim.
- KOTZ, S. und NADARAJAH, S., 2001: *Extreme Value Distributions: Theory and Applications*, World Scientific Publishing Company.
- KRAEMER, P.; BÜTHE, I. und FRITZEN, C.-P., 2010: *Damage detection under variable environmental conditions using Self Organizing Maps*, IMEKO TC, 11th Workshop on Smart Diagnostics of Structures, Kraków, Poland.
- KRAEMER, P. und FRITZEN, C.-P., 2007a: *Concept for Structural Damage Identification of Offshore Wind Energy Plants*, 6th International Workshop on Structural Health Monitoring, Stanford University, S. 1881-1888.

- KRAEMER, P. und FRITZEN, C.-P., 2007b: *Sensor Fault Identification Using Autoregressive Models and the Mutual Information Concept*, Key Engineering Materials, Trans Tech Publications, Switzerland, S. 387-392.
- KRAEMER, P. und FRITZEN, C.-P., 2008a: *Damage Identification of Structural Components of Offshore Wind Energy Plants*, Deutsche Windenergie Konferenz, DEWEK2008, Bremen, Germany.
- KRAEMER, P. und FRITZEN, C.-P., 2008b: *Sensor Fault Detection and Signal Reconstruction using Mutual Information and Kalman Filters*, International Conference on Noise and Vibration Engineering, Leuven, Belgium, S. 3267-3282.
- KRAEMER, P. und FRITZEN, C.-P., 2008c: *Zwischenbericht 2007, Projekt 16INO327*.
- KRAEMER, P. und FRITZEN, C.-P., 2010a: *Aspects of Operational Modal Analysis for Structures of Offshore Wind Energy Plants*, IMAC XXVIII, Jacksonville, USA.
- KRAEMER, P. und FRITZEN, C.-P., 2010b: *Vibration analysis for structures of offshore wind energy plants*, Deutsche Windenergie Konferenz, DEWEK2010, Bremen, Germany.
- KRAEMER, P.; LAUTENSCHLAGER, D.; FRITZEN, C.-P. und OERTEL, U., 2008: *Condition Monitoring Methods for Machine and Drive Train Components of Wind Energy Plants*, Deutsche Windenergie Konferenz DEWEK2008, Bremen, Germany.
- KRAMER, A. M., 1991: *Nonlinear Principal Component Analysis Using Autoassociative Neural Networks*, AIChE Journal (Band 37(2)), S. 233-243.
- KULLAA, J., 2002: *Elimination of Environmental Influences from Damage-Sensitive Features in a Structural Health Monitoring System*, 1st European Workshop on SHM, Paris, S. 742-749.
- KULLAA, J., 2003: *Is temperature measurement essential in Structural Health Monitoring?*, 4th International Workshop on Structural Health Monitoring, Stanford University, S. 717-724.
- KULLAA, J., 2004: *Structural Health Monitoring under variable environmental or operational conditions*, 2nd European Workshop on Structural Health Monitoring, Munich, S. 1262-1269.
- KULLAA, J., 2005: *Damage Detection under a Varying Environment using the Missing Data Concept*, 5th International Workshop on Structural Health Monitoring, Stanford University, S. 565-573.
- KULLAA, J., 2006a: *Removing non-linear environmental influences from structural features*, 3rd European Workshop on Structural Health Monitoring, Madrid, S. 635-642.
- KULLAA, J., 2006b: *Sensor fault identification and correction in structural health monitoring*, International Conference on Noise and Vibration Engineering, Leuven, Belgium, S. 873-884.
- KULLAA, J., 2007: *Sensor Fault Identification and Correction in Vibration-Based Multichannel Structural Health Monitoring*, 6th International Workshop on Structural Health Monitoring, Stanford University, S. 606-613.
- KULLAA, J., 2008: *Eliminating Environmental or Operational Influences in Structural Health Monitoring using Missing Data Analysis*, Journal of Intelligent Material Systems and Structures, Nr. 10.1177/1045389X08096050.
- LADING, L.; MCGUGAN, M.; SENDRUP, P.; RHEINLÄNDER, J. und RUSBORG, J., 2002: *Fundamentals for Remote Structural Health Monitoring of Wind Turbine Blades*, Bericht: Risø-R-1341, Risø National Laboratory, Roskilde.
- LÄMSÄ, V. und KULLAA, J., 2007: *Nonlinear Factor Analysis in Structural Health Monitoring to Remove Environmental Effects*, 6th International Workshop on Structural Health Monitoring, Stanford University, S. 1092-1099.



- LANGE, H., 2008: *Structural and Lifetime Condition Monitoring Systems for Wind Energy Plants*, Deutsche Windenergie Konferenz DEWEK2008, Bremen, Germany.
- LAUTENSCHLAGER, D., 2008: *Entwicklung und Anwendung von Schadenidentifikationsmethoden an Maschinenkomponenten in Windenergieanlagen*, Diplomarbeit, Universität Siegen.
- LÜTKEPOHL, H., 1985: *Comparison of criteria for estimating the order of a vector autoregressive process*, Journal of Time Series Analysis (Band 8), S. 373.
- LÜTKEPOHL, H., 1993: *Introduction to Multiple Time Series Analysis*, 2. Auflage, Springer, Berlin.
- MAECK, J., 2003: *Damage Assessment of Civil Engineering Structures by Vibration Monitoring*, PhD, KU Leuven, Leuven, Belgium.
- MENGELKAMP, G., 2006: *Entwicklung einer intelligenten Struktur - Eine Kombination globaler und lokaler Verfahren zur Schadensdiagnose*, Dissertation, Siegen.
- MOLINA, F. J.; PASCUAL, R. und GOLINVAL, J. C., 2003: *Description of the Steelquake Benchmark*, Mechanical Systems and Signal Processing (Band 17), S. 77-82.
- MOLL, J.; KRAEMER, P. und FRITZEN, C.-P., 2008: *Compensation of Environmental Influences for Damage Detection using Classification Techniques*, 4th European Workshop on Structural Health Monitoring, Cracow, Poland, S. 1080-1087.
- MOLL, J.; SCHULTE, R. T.; HARTMANN, B.; FRITZEN, C.-P. und NELLES, O., 2010: *Multi-Site Damage Localization in Anisotropic Plate-Like Structures Using an Active Guided Wave Structural Health Monitoring System*, Smart Materials and Structures (Band 19(4)).
- MONTGOMERY, D. C., 1991: *Introduction to Statistical Quality Control*, John Wiley and Sons.
- MONTGOMERY, D. C., 1997: *Introduction to statistical quality control*, 3. Auflage, John Wiley & Sons, New York.
- MONTGOMERY, D. C.; PECK, E. A. und VINING, G. G., 2006: *Introduction to linear Regression Analysis*, 4. Auflage, John Wiley & Sons.
- NAIR, K. K. und KIREMIDJIAN, A. S., 2007: *Time Series Based Structural Damage Detection Algorithm Using Gaussian Mixtures Modeling*, Journal of Dynamic Systems, Measurement and Control (Band 129), S. 285-293.
- NATKE, H. G., 1992: *Einführung in Theorie und Praxis der Zeitreihen- und Modalanalyse* (Band 3), Vieweg, Germany.
- NATKE, H. G. und CEMPEL, C., 1997: *Model-Aided Diagnosis of Mechanical Systems*, Springer.
- NELLES, O., 2001: *Nonlinear System Identification*, Springer.
- NETER, J.; KUTNER, M. H.; NACHTSHEIM und W., W. C. J., 1996: *Applied linear statistical models*, McGraw-Hill.
- NEUMAIER, A. und SCHNEIDER, T., 2001: *Estimation of parameters and eigenmodes of multivariate autoregressive models*, ACM Transactions on Mathematical Software (Band 27), S. 27-57.
- NGUYEN, P. D., 2002: *Beitrag zur Diagnostik der Verzahnungen in Getrieben mittels Zeit-Frequenz-Analyse*, Dissertation, Chemnitz.
- NICHOLS, J. M., 2003: *Structural health monitoring of offshore structures using ambient excitation*, Applied Ocean Research (Band 25), S. 101-114.
- NIU, Y.; KRAEMER, P. und FRITZEN, C.-P., 2011: *Operational Modal Analysis for the Guangzhou New TV Tower*, IMAC XXIX, Jacksonville, Florida, USA.
- OBSERVER, 2009: *Worldwide electricity production from renewable energy sources, Eleventh inventory*. URL: <http://www.energies-renouvelables.org>.

- ODE, 2007: *Study of the costs of offshore wind generation*, Offshore Design Engineering.
- ODGAARD, P. F. und STOUSTRUP, J., 2010: *Unknown Input Observer Based Detection of Sensor Faults in a Wind Turbine*, International Conference on Control Applications, Yokohama, Japan, S. 310-315.
- OPPENHEIM, A. V., SCHAFFER, R.W., 1998: *Discrete-Time Signal Processing* (Band 2), Prentice-Hall.
- PAPADIMITRIOU, C.; FRITZEN, C.-P.; KRAEMER, P. und NTOTSIOS, E., 2009: *Fatigue Lifetime Estimation in Structures using Ambient Vibration Measurements*, COMPDYN 2009, Rhodes, Greece.
- PEETERS, B., 2000: *System Identification and Damage Detection in Civil Engineering*, PhD. Thesis, K.U. Leuven, Leuven, Belgium.
- PEETERS, B. und DE ROECK, G., 1999: *Reference-Based Stochastic Subspace Identification for Output-Only Modal Analysis*, Mechanical Systems and Signal Processing (Band 12(6)), S. 855-878.
- PEETERS, B. und DE ROECK, G., 2001: *Stochastic system identification for operational modal analysis: A Review*, Journal of Dynamic Systems, Measurement and Control (Band 123(4)), S. 659-667.
- PEETERS, J.; VANDEPITTE, D. und SAS, P., 2006: *Structural analysis of a wind turbine and its drive train using the flexible multibody simulation technique*, ISMA2006, Leuven, Belgium.
- PITCHFORD, W., 2007: *Impedance-Based Structural Health Monitoring of Wind Turbine Blades*, Master Thesis, Virginia Polytechnic Institute and State University.
- RANDALL, R. B., 1987: *Frequency Analysis* (Band 3), Bruel & Kjaer.
- RENCHER, A. C., 2002: *Methods of Multivariate Analysis*, Wiley Series in Probability and Statistics, John Wiley & Sons, Inc.
- ROHRMANN, R.; BÄSSLER, M.; SAID, S.; SCHMID, W. und RÜCKER, W., 1999: *Structural causes of temperature affected modal data of civil structures obtained by long time monitoring*, XVII IMAC, Kissimmee, Florida, S. 1-6.
- ROHRMANN, R. und RUECKER, W., 2005: *IMO-Wind: An Integrated Monitoring System for Offshore Wind Energy Turbines*, Eurodyn 2005, Paris.
- ROHRMANN, R. G.; RÜCKER, W. und BÄUMER, S., 2007: *Dynamic investigations at offshore wind turbines*, Experimental Vibration Analysis for Civil Engineering Structures, EVACES's 2007, Porto, Portugal, S. 965-976.
- ROLFES, R.; GERASCH, W.-J.; HAAKE, G.; REETZ, J. und ZERBST, S., 2006: *Early Damage Detection System for Tower and Rotor Blades of Offshore Wind Turbines*, 3rd European Workshop on Structural Health Monitoring, Granada, Spain, S. 455-462.
- ROLFES, R.; ZERBST, S.; HAAKE, G.; REETZ, J. und LYNCH, P., 2007: *Integral SHM-System for Offshore Wind Turbines using Smart Wireless Sensors*, 6th International Workshop on Structural Health Monitoring, Stanford University, S. 1889-1896.
- RÜCKER, W., 2007: *Offshore wind energy plants: Problems and possible solutions*, Experimental Vibration Analysis for Civil Engineering Structures, Porto, S. 55-72.
- RYTTER, A., 1993: *Vibration Based Inspection of Civil Engineering Structures*, Dissertation, Aalborg.
- SACHS, L. und HEDDERICH, J., 2006: *Angewandte Statistik, Methodensammlung mit R*, Springer.
- SANGER, T. D., 1989: *Optimal Unsupervised Learning in a Single-Layer Linear Feedforward Neural Network*, Neural Networks (Band 6), Nr. 2, S. 459-473.
- SCHAUMANN, P.; BÖKER, C. und WILKE, F., 2005: *Lebensdaueranalyse komplexer Tragstrukturen unter Seegangsbeanspruchung*, Stahlbau 74 (Band 6), S. 406-411.

- SCHLECHT, B. und GUTT, S., 2002: *Multibody-System-Simulation of Drive Trains of Wind Turbines*, 5th World Congress on Computational Mechanics, Vienna, Austria.
- SHAN, J.; BAUER, B. und SEELIGER, A., 1999: *Schadensdiagnose von Planetengetrieben*, VDI Schwingungstagung 1999.
- SHANNON, C. E., 1948: *A mathematical theory of communication*, The Bell System Technical Journal (Band 27(3)), S. 379-423 und 623-656.
- SOHN, H., 2007: *Effects of environmental and operational variability on structural health monitoring*, Philosophical Transactions of the Royal Society (Band 365), S. 539-560.
- SOHN, H.; ALLEN, D. W.; WORDEN, K. und FARRAR, C. R., 2005: *Structural Damage Classification Using Extreme Value Statistics*, Journal of Dynamic Systems, Measurement and Control (Band 127), S. 125-132.
- SOHN, H.; CZARNECKI, J. J. und FARRAR, C. R., 2000: *Structural health monitoring using statistical process control*, Journal of Mechanical Engineering, ASCE at press.
- SOHN, H.; DZWONCZYK, M.; STRASER, E. G.; LAW, K. H.; MENG, T. und KIREMIDJIAN, A. S., 1998: *Adaptive modeling of environmental effects in modal parameters for damage detection in civil structures*, Proc. SPIE, S. 127-138.
- SOHN, H.; FARRAR, C. F.; HUNTER, N. F. und WORDEN, K., 2001: *Structural Health Monitoring Using Statistical Pattern Recognition Techniques*, Journal of Dynamic Systems, Measurement and Control (Band 123), S. 706-711.
- SOHN, H. und FARRAR, C. R., 2001: *Damage diagnosis using time series analysis of vibration signals*, Smart Materials and Structures (Band 10), S. 446-451.
- SOHN, H.; WORDEN, K. und FARRAR, C. R., 2002: *Statistical Damage Classification Under Changing Environmental and Operational Conditions*, Journal of Intelligent Material Systems and Structures (Band 13), S. 561-574.
- STARK, H. und WOODS, J. W., 2002: *Probability and Random Processes with Application to Signal Processing*, Prentice Hall, New Jersey.
- STEVENS, J., 1992: *Applied Multivariate Statistics for Social Sciences*, 2. Auflage, Lawrance Erlbaum Associates Publishers, New-Jersey.
- STURGES, H. A., 1926: *The choice of a class interval*, Journal of American Statistical Association, S. 65-66.
- SUNDARAM, S. und HADJICOSTIS, C. D., 2005: *On delayed Observers for Linear Systems with Unknown Inputs*, 44th IEEE Conf. on Decision and Control, Sevilla, S. 7210-7215.
- SWAMI, A.; MENDEL, J. M. und NIKIAS, C. L., 2001: *Higher-Order Spectral Analysis Toolbox, User's guide Version 2*.
- SWARTZ, R. A.; LYNCH, J. P.; SWEETMAN, B.; ROLFES, R. und ZERBST, S., 2010: *Structural Monitoring of Wind Turbines using Wireless Sensor Networks*, Smart Structures and Systems (Band 6), S. 183-196.
- THÖNS, S.; ROHRMANN, R. G.; RÜCKER, W. und FABER, M. H., 2008: *Bewertung der Ermüdungsfestigkeit von Baustrukturen in Offshore-Windenergie-Anlagen*, Stahlbau 77 (Band 9), S. 630-638.
- TIAN, Y., 2010: *Funktionalitätserweiterung der Berechnungsplattform FEMtools um ein Modul zur modellgestützten Schadenlokalisation*, Diplomarbeit, Universität Siegen.
- TOURASSI, G. D.; FREDERICK, E. D.; MARKEY, M. K. und FLOYD, C. E. J., 2001: *Application of the mutual information criterion for feature selection in computer-aided diagnosis*, American Association of Physicists in Medicine (Band 28), Nr. 12, S. 2394-2402.

- VANLANDUIT, S.; PARLOO, E.; CAUBERGHE, B.; GUILLAUME, P. und VERBOVEN, P., 2005: *A robust singular value decomposition for damage detection under changing conditions and structural uncertainties*, Journal of Sound and Vibration (Band 284), S. 1033-1050.
- VOLKMER, P.; KÜHL, A.; MÜLLER, F.; SCHLBACH, D. und D, V., 2006: *Continuous Natural Frequency monitoring of Rotor Blades for Detection of Damages, Ice-foundation and Dynamik Overloads*, Deutsche Windenergiekongress, DEWEK 2006, Bremen.
- VRABIE, V. D.; GRANJON, P. und SERVIÈRE, C., 2003: *Spectral kurtosis: from definition to application*, Workshop on Nonlinear Signal and Image Processing, Grado, Italy.
- WALTERS-WILLIAMS, J. und LI, Y., 2009: *Estimation of Mutual Information: A Survey*, 4th International Conference on Rough Set and Knowledge Technology, Gold Coast, Australia., S. 389–396.
- WANG, H.; TIAN, Z.; SHI, S. und WENG, Z., 2010: *Fault Detection and Isolation Scheme Based on Parity Space Method for Discrete Time-Delay System*, Wei Zhang, Vukovar, Croatia, ISBN: ISBN 978-953-307-037-7.
- WELCH, G. und BISHOP, G., 2001: *An Introduction to the Kalman Filter* (Band Course 8), SIGGRAPH.
- WELCH, P. D., 1963: *The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms*, IEEE Trans. Audio Electroacoustics (Band AU-15), S. 70-73.
- WITTEN, I. H. und FRANK, E., 2005: *Data Mining: Practical Machine Learning Tools and Techniques*, Morgan Kaufmann, Amsterdam.
- WORDEN, K., 2003: *Sensor validation and correction using auto-associative neural networks and principal component analysis*, IMAC XXI, Orlando, USA.
- WORDEN, K.; FARRAR, C. R.; MANSON, G. und PARK, G., 2005: *Fundamental Axioms of Structural Health Monitoring*, 4th International Workshop Structural Health Monitoring, Stanford University, S. 26-41.
- WÜNNENBERG, J., 1990: *Observer-Based Fault Detection in Dynamic Systems*, Dissertation, Universität Duisburg.
- WWEA (2010): *World Wind Energy Report 2009*, World Wind Energy Association, <http://www.world-wind-energy.info/>.
- YAN, A.-M.; KERSCHEN, G.; DE BOE, P. und GOLINVAL, J.-C., 2005: *Structural damage diagnosis under varying environmental conditions - Part I: A linear analysis*, Mechanical Systems and Signal Processing (Band 19), S. 847–864.
- YANG, S. S. und LEE, Y., 1987: *Identification of a Multivariate Outlier*, Annual Meeting of the American Statistical Association, San Francisco.
- ZERBST, S.; REETZ, J.; GERASCH, W.-J. und ROLFES, R. S., 2007: *Methoden zur Schadenserkennung an Tragstrukturen von Windenergieanlagen*, 5. Symposium Offshore-Windenergie, bau- und umwelttechnische Aspekte, Hannover, Germany.

## ANHANG

### A1.1 BERECHNUNG VON AR-KOEFFIZIENTEN EINER MULTIVARIATEN ZEITREIHE

Die folgende Beschreibung basiert auf [LÜTKEPOHL 1985; LÜTKEPOHL 1993; NEUMAIER und SCHNEIDER 2001]<sup>1</sup>.

Für die Berechnung der Koeffizientenmatrizen  $[A_1 \ \dots \ A_p]$  eines  $m$ -variaten AR-Modells der Ordnung  $p$  lässt sich zuerst die multivariate Zeitreihe  $\mathbf{y}_k$  der Länge  $n_t$  anhand eines Regressionsmodells der Form

$$\mathbf{y}_k = \mathbf{B}_{AR} \tilde{\mathbf{z}}_k + \boldsymbol{\varepsilon}_k \quad (k = 1 \dots n_t) \quad (\text{A.1})$$

mit der Parameter-Matrix

$$\mathbf{B}_{AR} = [\mathbf{w} \ A_1 \ \dots \ A_p]. \quad (\text{A.2})$$

und der Prädiktoren

$$\tilde{\mathbf{z}}_k = \begin{pmatrix} 1 \\ \mathbf{y}_{k-1} \\ \vdots \\ \mathbf{y}_{k-p} \end{pmatrix} \quad (\text{A.3})$$

beschreiben.  $\mathbf{w}$  ist ein Vektor mit Mittelwertverschiebungen der Zeitreihe und  $\boldsymbol{\varepsilon}$  der Fehler der linearen Approximation. Anhand der Momentenmatrizen

$$\tilde{\mathbf{Z}} = \sum_{k=1}^{n_t} \tilde{\mathbf{z}}_k \tilde{\mathbf{z}}_k^T, \quad \mathbf{Y} = \sum_{k=1}^{n_t} \mathbf{y}_k \mathbf{y}_k^T, \quad \mathbf{W} = \sum_{k=1}^{n_t} \mathbf{y}_k \tilde{\mathbf{z}}_k^T, \quad (\text{A.4})$$

kann die Matrix  $\mathbf{B}$  mit der Methode der kleinsten Fehlerquadrate wie folgt geschätzt werden:

$$\hat{\mathbf{B}}_{AR} = \mathbf{W} \tilde{\mathbf{Z}}^{-1}. \quad (\text{A.5})$$

Die Residuunkovarianzmatrix

$$\hat{\mathbf{C}}_{AR} = \frac{1}{n_t - mp - 1} \sum_{k=1}^{n_t} \boldsymbol{\varepsilon}_k \boldsymbol{\varepsilon}_k^T \quad \text{mit} \quad \boldsymbol{\varepsilon}_k = \mathbf{y}_k - \hat{\mathbf{B}}_{AR} \tilde{\mathbf{z}}_k \quad (\text{A.6})$$

---

<sup>1</sup> Die Algorithmen sind implementiert in der Matlab Toolbox ARFit.

lässt sich auch aus den Momentenmatrizen wie folgt herleiten:

$$\hat{\mathbf{C}}_{AR} = \frac{1}{n_t - mp - 1} (\mathbf{Y} - \mathbf{W}\tilde{\mathbf{Z}}^{-1}\mathbf{W}^T) \quad (\text{A.7})$$

Diese ist proportional zu einem SCHUR-Komplement der Matrix

$$\mathbf{\Gamma} = \begin{pmatrix} \tilde{\mathbf{Z}} & \mathbf{W}^T \\ \mathbf{W} & \mathbf{Y} \end{pmatrix} = \sum_{k=1}^{n_t} \begin{pmatrix} \tilde{\mathbf{z}}_k \\ \mathbf{y}_k \end{pmatrix} \begin{pmatrix} \tilde{\mathbf{z}}_k^T & \mathbf{y}_k^T \end{pmatrix}, \quad (\text{A.8})$$

welche die Momentmatrix  $\mathbf{\Gamma} = \tilde{\mathbf{K}}^T \tilde{\mathbf{K}}$  der Matrix

$$\tilde{\mathbf{K}} = \begin{pmatrix} \tilde{\mathbf{z}}_1^T & \mathbf{y}_1^T \\ \vdots & \vdots \\ \tilde{\mathbf{z}}_{n_t}^T & \mathbf{y}_{n_t}^T \end{pmatrix} \quad (\text{A.9})$$

ist. Die kleinsten Fehlerquadrate berechnen sich nun mit Hilfe einer QR-Faktorisierung der Matrix

$$\tilde{\mathbf{K}} = \mathbf{Q}\mathbf{R}, \quad (\text{A.10})$$

wobei  $\mathbf{Q}$  eine orthogonale Matrix und  $\mathbf{R}$  eine obere Dreiecksmatrix ist:

$$\mathbf{R} = \begin{pmatrix} \mathbf{R}_{11} & \mathbf{R}_{12} \\ \mathbf{0} & \mathbf{R}_{22} \end{pmatrix}. \quad (\text{A.11})$$

Nach der QR-Faktorisierung folgt eine weitere CHOLESKY-Faktorisierung  $\mathbf{\Gamma} = \tilde{\mathbf{K}}^T \tilde{\mathbf{K}} = \mathbf{R}^T \mathbf{R}$  der Momentenmatrix

$$\begin{pmatrix} \tilde{\mathbf{Z}} & \mathbf{W}^T \\ \mathbf{W} & \mathbf{Y} \end{pmatrix} = \mathbf{R}^T \mathbf{R} = \begin{pmatrix} \mathbf{R}_{11}^T \mathbf{R}_{11} & \mathbf{R}_{11}^T \mathbf{R}_{12} \\ \mathbf{R}_{12}^T \mathbf{R}_{11} & \mathbf{R}_{12}^T \mathbf{R}_{12} + \mathbf{R}_{22}^T \mathbf{R}_{22} \end{pmatrix}. \quad (\text{A.12})$$

Ein Vergleich zwischen Gl. (A.12) mit Gl. (A.5) und (A.7) führt zu:

$$\hat{\mathbf{B}}_{AR} = (\mathbf{R}_{11}^{-1} \mathbf{R}_{12})^T \quad \text{und} \quad \hat{\mathbf{C}}_{AR} = \frac{1}{n_t - mp - 1} \mathbf{R}_{22}^T \mathbf{R}_{22}. \quad (\text{A.13})$$

Wenn die Momentenmatrix  $\mathbf{\Gamma}$  schlecht konditioniert ist, lassen sich die damit verbundenen Fehler bei der Parameterschätzung reduzieren, indem  $\mathbf{\Gamma}$  um den Term  $\delta \mathbf{D}^2$  erweitert wird. Hierbei stellt  $\mathbf{D}^2$  eine positive definierte Diagonalmatrix und  $\delta$  einen Regularisierungsfaktor

dar. Somit bietet sich, eine Faktorisierung der Momentenmatrix  $\boldsymbol{\Gamma} + \delta \boldsymbol{D}^2 = \boldsymbol{R}^T \boldsymbol{R}$  nach der folgenden Schema an:

$$\begin{pmatrix} \tilde{\boldsymbol{K}} \\ \sqrt{\delta} \boldsymbol{D} \end{pmatrix} = \boldsymbol{Q} \boldsymbol{R}. \quad (\text{A.14})$$

Die Diagonalmatrix  $\boldsymbol{D}$  kann aus den euklidischen Normen der Spalten der Matrix  $\tilde{\boldsymbol{K}}$  gewählt werden. Der Regularisierungsfaktor ist hier ein empirischer Wert, welcher sich an die Dimension der Matrix  $\boldsymbol{\Gamma}$  richtet [HIGHAM 1996].

## A1.2 WÄLZLAGER

Wälzlager sind Verschleißteile, bei denen im Laufe der Zeit durch wechselnde Beanspruchungen Ausbrüche, sogenannte Pittings, auftreten können. Solche Fehler erzeugen eine Folge von Einzelstößen, deren Wiederholfrequenz durch den Ort des Fehlers bestimmt wird. Je nachdem, ob die Pittings am Lagerinnenring, -außenring, Wälzkörper oder dem Wälzkörperkäfig auftreten, besitzt das Schwingungssignal unterschiedliche periodische Belastungsspitzen. Die charakteristischen Frequenzen, mit denen die Belastungsspitzen wiederkehren, nennt man Überrollfrequenzen. Diese lassen sich folgendermaßen berechnen [KLEIN 2003]:

$$f_I = \frac{1}{2} f \cdot Z \left( 1 + \frac{d}{D_T} \cos \beta \right) \text{ (Innenringüberrollfrequenz),} \quad (\text{A.15})$$

$$f_A = \frac{1}{2} f \cdot Z \left( 1 - \frac{d}{D_T} \cos \beta \right) \text{ (Außenringüberrollfrequenz),} \quad (\text{A.16})$$

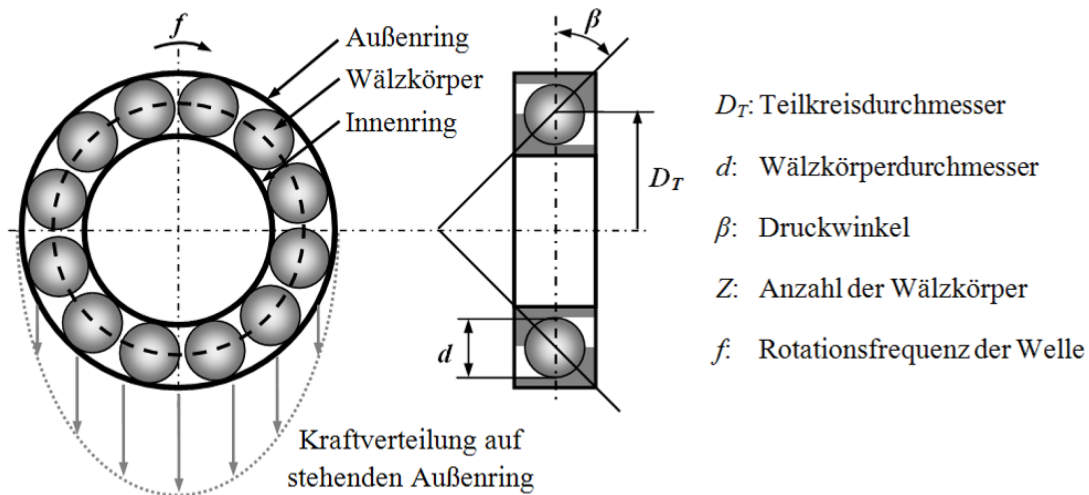
$$f_W = f \left( 1 + \frac{D_T}{d} \right) \cdot \left( 1 - \frac{d}{D_T} \cos \beta \right) \text{ (Wälzkörperüberrollfrequenz),} \quad (\text{A.17})$$

$$f_K = \frac{1}{2} f \cdot \left( 1 - \frac{d}{D_T} \cos \beta \right) \text{ (Käfigüberrollfrequenz, stehender Außenring),} \quad (\text{A.18})$$

$$f_K = \frac{1}{2} f \cdot \left( 1 + \frac{d}{D_T} \cos \beta \right) \text{ (Käfigüberrollfrequenz, stehender Innenring).} \quad (\text{A.19})$$

Die Bezeichnungen der Geometriedaten eines Wälzlagers sowie weitere Abkürzungen sind in Abbildung A.1 dargestellt.

Bei der Wälzkörperüberrollfrequenz sei darauf hingewiesen, dass sich die Position eines Wälzkörperschadens in Bezug auf die Drehachse des Wälzkörpers ändern kann und somit möglicherweise nicht ständig überrollt wird. In diesem Fall ist die Wälzkörperüberrollfrequenz für eine Schadensdiagnose nur bedingt aussagekräftig.



**Abbildung A.1: Komponenten und Geometrie eines Wälzlagers mit zugehöriger Kraftverteilung für einen stehenden Außenring**

### A1.3 VERZÄHNUNGEN

Im Getriebe entstehen außer an Wälzlagern auch an Zahnrädern häufig Schäden. Daher werden die kinematischen Zusammenhänge für Stirnradverzahnungen und Planetengetriebe im Folgenden erläutert.

#### *Stirnradverzahnung*

Sind die Zahnräder ideal mit exakten Evolventenflanken gefertigt, sollten sie theoretisch völlig schwingungsfrei laufen. In der Realität verursachen aber sogar fehlerfrei gefertigte Zahnräder Schwingungen beim Zahneingriff, beispielsweise durch Zahndeformation unter hoher Last. Dabei findet die Anregung von Schwingungen in erster Linie durch den Zahneingriff selbst statt, der eine Ungleichförmigkeit der Drehbewegung der kämmenden Zahnräder in Form von Drehbeschleunigungen bewirkt. Es werden demnach auch in völlig intakten Getrieben periodische Schwingungen erzeugt, die von denen zu unterscheiden sind, die durch Schäden hervorgerufen werden.

Beim Zahneintritt und -austritt verbiegen sich jeweils die im Eingriff stehenden Zähne aufgrund der Kraftübertragung. Durch die entstehende Verlagerung der Zahnflanken stoßen



schon die nächsten Zähnepaare aufeinander, was einen Stoßimpuls zur Folge hat. Diese Eintritts- und Austrittsimpulse werden jeweils mit der Zahneingriffsfrequenz  $f_{ze}$  angeregt:

$$f_{ze} = f_a \cdot z_a = f_b \cdot z_b, \quad (\text{A.20})$$

wobei  $f_a$  und die  $f_b$  Drehfrequenzen der Zahnräder,  $z_a$  und  $z_b$  Zähnezahlen der Zahnräder  $a$  und  $b$  bezeichnen.

Weitere Merkmale von Verzahnungen werden stichpunktartig zur besseren Übersicht zusammengefasst:

- Änderungen der Zahnfedersteifigkeit, die sich im Verlauf des Zahneingriffes ändert, verursacht Schwingungen, die sich periodisch mit der Zahneingriffsfrequenz wiederholen.
- Der sogenannte Reibwechselimpuls entsteht als Folge des Richtungswechsels der Reibkraft im Wälzpunkt, so dass Schwingungen periodisch mit dem Zahneingriff erzeugt werden.
- Reibgeräusche entstehen durch die auftretenden Gleit- und Wälzreibung.

Mit Ausnahme der Reibgeräusche, die keiner Frequenz direkt zugeordnet werden können, werden alle beschriebenen Mechanismen mit der Zahneingriffsfrequenz angeregt. Hierbei ist die Anregung bei Geradverzahnungen höher als bei Schrägverzahnungen.

Aus Gründen der Vereinfachung werden bei der Verzahnungsdiagnose die Betrachtungen in der Regel auf den Zahneingriffstoß (Zahneingriffsfrequenz) beschränkt.

Die bisher erläuterten Schwingungserregungen resultieren alle aus einer unbeschädigten Verzahnung. Sie können allerdings auch bei beschädigten Zahnrädern auftreten. Zudem können Schäden an Verzahnungen beim Zahneingriff zu Intensitätsschwankungen des Beschleunigungssignals führen. Dies ermöglicht ein Erkennen der Schäden bei der Zustandsdiagnose. Die Schäden oder auch Bauungenauigkeiten rufen eine stoßimpulsförmige Schwingung hervor, die immer dann auftritt, wenn sich die gleichen Zähne beim Kämmen wieder treffen. Die Anzahl der dazu erforderlichen Umdrehungen der Zahnräder hängt dabei von den Zähnezahlen ab und lässt sich folgendermaßen berechnen:

$$U_a = \frac{KGV(z_a, z_b)}{z_a} \quad (\text{Anzahl der Umdrehungen Zahnrad } a). \quad (\text{A.21})$$

$$U_b = \frac{KGV(z_a, z_b)}{z_b} \quad (\text{Anzahl der Umdrehungen Zahnrad } b) \quad (\text{A.22})$$

Dabei beschreibt  $KGV(z_a, z_b)$  das kleinste gemeinsame Vielfache der Zahnanzahl der beiden Zahnräder  $a$  und  $b$ . Die Zahneingriffswiederholfrequenz  $f_{zew}$  berechnet sich dann folgendermaßen:

$$f_{zew} = f_a \cdot \frac{z_a}{KGV(z_a, z_b)} = f_b \cdot \frac{z_b}{KGV(z_a, z_b)}. \quad (\text{A.23})$$

### Planetengetriebe

Auch wenn die schwingungsanregenden Mechanismen grundsätzlich die gleichen wie bei Stirnradgetrieben sind, gestaltet sich das Erkennen von Fehlern an der Verzahnung von Planetengetrieben komplizierter, da sich immer mehrere Planeten im Zahneingriff befinden und die Planeten sich nicht nur um die eigene Achse drehen, sondern zusätzlich auch um den Mittelpunkt des Planetenträgers (vgl. Abbildung A.2),.




Abbildung A.2: Skizze eines Planetengetriebes

Bei einstufigen Planetengetrieben mit feststehendem Hohlrad gilt für die Drehfrequenz der Planetenräder nach [SHAN *et al.* 1999]:

$$f_P = \frac{z_S \cdot z_H}{z_P \cdot (z_S + z_H)} \cdot f_S. \quad (\text{A.24})$$

Die Zahneingriffsfrequenz  $f_{ze}$  [SHAN *et al.* 1999] ergibt sich in diesem Fall zu:

$$f_{ze} = \frac{z_S \cdot z_H}{z_S + z_H} \cdot f_S. \quad (\text{A.25})$$

Für die Zahneingriffswiederholfrequenzen von Sonnen- und Planetenrad  $f_{zew(S,P)}$  bzw. von Planeten- und Hohlrad  $f_{zew(P,H)}$  gilt [SHAN *et al.* 1999]:

$$f_{zew(S,P)} = \frac{z_S}{KGV(z_S, z_P)} \cdot (f_S - f_T), \quad (\text{A.26})$$

$$f_{zew(P,H)} = \frac{z_H}{KGV(z_P, z_H)} \cdot f_T. \quad (\text{A.27})$$

Für die Überrollfrequenzen (Passierfrequenzen) einer Unregelmäßigkeit auf den verschiedenen Zahnrädern gilt [SHAN *et al.* 1999]:

$$f_{SÜ} = k \cdot \frac{z_H}{z_S + z_H} \cdot f_S \text{ (Sonnenrad)}, \quad (\text{A.28})$$

$$f_{HÜ} = k \cdot \frac{z_S}{z_S + z_H} \cdot f_S \text{ (Hohlrad)}, \quad (\text{A.29})$$

$$f_{PÜ} = 2 \cdot \frac{z_S \cdot z_H}{z_P \cdot (z_S + z_H)} \cdot f_S \text{ (Planetenrad)}, \quad (\text{A.30})$$

mit:	$f_P$	Planetendrehfrequenz
	$f_T$	Planetenträgerdrehfrequenz
	$f_S$	Sonnenraddrehfrequenz
	$k$	Anzahl der Planetenräder
	$z_S$	Zähnezahl des Sonnenrades
	$z_H$	Zähnezahl des Hohlrades
	$z_P$	Zähnezahl des Planetenrades
	$KGV(z_S, z_P)$	als das kleinste gemeinsame Vielfache der beiden Zähnezahlen $z_S$ und $z_P$
	$KGV(z_S, z_H)$	als das kleinste gemeinsame Vielfache der beiden Zähnezahlen $z_S$ und $z_H$

## A1.4 SCHADENSLOKALISATION




Abbildung A.3: Sieben Schwingungsmoden des Offshore-Windenergieanlage-Modells

Mode	$f_{FE}$ [Hz]	$f_{Test}$ [Hz]	Diff. [%]	MAC [%]
1	0,44	0,44	1,44	100
2	0,44	0,42	7,12	99,9
3	3,37	3,24	4,06	99,9
4	3,49	3,42	2,18	100
5	6,53	6,46	1,04	99,8
6	7,54	7,48	0,81	99,2
7	7,91	7,90	0,17	99,9

Tabelle A.1: Veränderung der Modaldaten durch den „Turmschaden“

Mode	$f_{FE}$ [Hz]	$f_{Test}$ [Hz]	Diff. [%]	MAC [%]
1	0,44	0,44	0,01	100
2	0,44	0,44	0,40	100
3	3,37	3,34	0,94	100
4	3,49	3,49	0,01	100
5	6,53	6,53	0,10	100
6	7,54	7,54	0,03	100
7	7,91	7,87	0,53	100

Tabelle A.2: Veränderung der Modaldaten durch den „Tripodschaden“

Mode	$f_{mr}$ [Hz]	$f_{mg}$ [Hz]	Diff. [%]	MAC [%]
1	3,13	2,68	-14,47	97
2	3,93	3,93	-1,64	93
3	6,13	6,06	-1,15	98
4	9,69	9,52	-1,79	99
5	10,82	9,9	-8,53	69
6	12,27	10,69	-12,86	78
7	13,05	11,29	-13,46	95
8	17,70	15,09	-14,72	94
9	19,03	16,19	-14,9	95
10	21,41	18,83	-12,06	98

**Tabelle A.3:** Gemessene Moden der ungeschädigten ( $mr$ ) und der geschädigten ( $mg$ ) *Steelquake* Struktur

Mode	$f_{FE}$ [Hz]	$f_{mr}$ [Hz]	Diff. [%]	MAC [%]
1	3,17	3,13	1,36	99,7
2	3,93	3,93	0,12	99,1
3	6,31	6,13	2,98	99,6
4	10,28	10,82	-4,94	98,8
5	10,94	9,69	12,93	98,9
6	12,19	12,27	-0,65	99,4
7	13,00	13,05	-0,38	99,3
8	19,29	17,70	9,02	95,8
9	20,84	19,03	9,51	97,2
10	24,22	21,41	13,14	94

**Tabelle A.4:** FE-Modellanpassung (FE) an die Referenzmessung ( $mr$ ) bei der *Steelquake* Struktur

## A1.5 SCHADENSDIAGNOSE AN MASCHINENKOMPONENTEN

Aufgenommene Signallänge [Abtastschritte]	270000
Abtastrate [Hz]	20000
Aufnahmedatum	02.06.2006

Methodenname	Parameter	Wert
Leistungsdichtespektrum und Hüllkurvenspektrum	Länge des Signals $n_t$	262032
	Fenstertyp	Hann
	Anzahl der Stützstellen $N_{fft}$	65508 ( $=n_t/4$ )
	Fensterlänge $N_{Fenster}$	$N_{fft}$
	Fensterüberlappung	$N_{fft}/2$
Leistungsspektrum	Länge des Signals $n_t$	262032
	Fenstertyp	Kein Fenster
	Anzahl der Stützstellen $N_{fft}$	65508 ( $=n_t/4$ )
	Fensterlänge $N_{Fenster}$	$N_{fft}$
	Fensterüberlappung	$N_{fft}/2$
Spektrale Kurtosis	Länge des Signals $n_t$	262032
	Fenstertyp	Hann
	Anzahl der Stützstellen $N_{fft}$	1024
	Fensterlänge $N_{Fenster}$	$N_{fft}$
	Fensterüberlappung	$2/3 \cdot N_{fft}$
Zyklische Kohärenz	Länge des Signals $n_t$	16333
	Fenstertyp	Hann
	Anzahl der Stützstellen $N_{fft}$	256
	Fensterlänge $N_{Fenster}$	128
	Fensterüberlappung	$2/3 \cdot N_{Fenster}$
	$\Delta\alpha$ auf $\alpha$ -Achse	$\approx 1,22$ Hz
	$\Delta f$ auf f-Achse	$\approx 78,1$ Hz

Tabelle A.5: Verwendete Einstellparameter (Innenringschaden des Lagers beim Generator)

Aufgenommene Signallänge [Abtastschritte]	270000
Abtastrate [Hz]	30000
Aufnahmedatum	25.10.2007

Methoden	Parameter	Wert
Leistungsdichtespektrum und Hüllkurvenspektrum	Länge des Signals $n_t$	261786
	Fenstertyp	Hann
	Anzahl der Stützstellen $N_{fft}$	$n_t$
	Fensterlänge $N_{Fenster}$	$N_{fft}$
Leistungsspektrum	Länge des Signals $n_t$	261786
	Fenstertyp	Kein Fenster
	Anzahl der Stützstellen $N_{fft}$	$n_t$
	Fensterlänge $N_{Fenster}$	$N_{fft}$
Zyklische Kohärenz	Länge des Signals $N$	32332
	Fenstertyp	Hann
	Anzahl der Stützstellen $N_{fft}$	256
	Fensterlänge $N_{Fenster}$	128
	Fensterüberlappung	$2/3 \cdot N_{Fenster}$
	$\Delta\alpha$ auf $\alpha$ -Achse	$\approx 0,93$ Hz
	$\Delta f$ auf $f$ -Achse	$\approx 117,2$ Hz

**Tabelle A.6: Verwendete Einstellparameter (Innenringschaden des Lagers bei der Zwischenwelle)**

Aufgenommene Signallänge [Abtastschritte]	270000
Abtastrate [Hz]	5000
Aufnahmedatum	15.08.2007

Methoden	Parameter	Wert
Leistungsdichtespektrum und Hüllkurvenspektrum	Länge des Signals $n_t$	256111
	Fenstertyp	Hann
	Anzahl der Stützstellen $N_{fft}$	$n_t$
	Fensterlänge $N_{Fenster}$	$N_{fft}$
Leistungsspektrum	Länge des Signals $n_t$	256111
	Fenstertyp	Kein Fenster
	Anzahl der Stützstellen $N_{fft}$	$n_t$
	Fensterlänge $N_{Fenster}$	$N_{fft}$
Zyklische Kohärenz	Länge des Signals $n_t$	65135
	Fenstertyp	Hann
	Anzahl der Stützstellen $N_{fft}$	128
	Fensterlänge $N_{Fenster}$	64
	Fensterüberlappung	$2/3 \cdot N_{Fenster}$
	$\Delta\alpha$ auf $\alpha$ -Achse	$\approx 0,077$ Hz
	$\Delta f$ auf f-Achse	$\approx 39,1$ Hz

Tabelle A.7: Verwendete Einstellparameter (Sonnenradschaden am Planetengetriebe)

Anmerkung: Die Anzahl der Stützstellen wurden jeweils so gewählt, dass die Schadensfrequenz optimal aufgelöst werden kann.