

Verbesserte Wälzlagerüberwachung durch Kombination von Vibrations- und AE-Sensorik sowie multivariater, ML-gestützter Datenanalyse

Christian SCHMIDT¹, Oliver MEY², André SCHNEIDER², Samuel KLEIN¹,
Dirk MAYER², Olaf ENGE-ROSENBLATT²

¹ Fraunhofer IZFP, Fraunhofer-Institut für Zerörungsfreie Prüfverfahren, Saarbrücken

² Fraunhofer IIS/EAS, Fraunhofer-Institut für Integrierte Schaltungen, Institutsteil
Entwicklung Adaptiver Systeme, Dresden

Kontakt E-Mail: christian.schmidt@izfp.fraunhofer.de

Kurzfassung

Wachsende Ansprüche an Verfügbarkeit und Effizienz von Produktionsanlagen führen zu einem größeren Bedarf, laufend Informationen über deren Zustand zu erhalten. Diese werden durch Condition Monitoring Systeme (CMS) gewonnen. Die sensorbasierte Überwachung des aktuellen Zustands ermöglicht die frühzeitige Detektion eintretender Schäden und Verschleißzustände, was zur Optimierung von Wartungsprogrammen genutzt wird. Insbesondere bei industriellen Anwendungen ist die Bandbreite der Einsatzfälle und Betriebsumgebungen der zu überwachenden Komponenten allerdings sehr groß. Ein anschauliches Beispiel sind die weit verbreiteten Wälzlager in der Antriebstechnik. Kleinste Ausführungen finden sich in der Medizintechnik, während in Windenergieanlagen und Kränen Durchmesser von mehreren Metern erreicht werden. Ebenso variieren die aufzunehmenden Lasten, Drehzahlen und Betriebsdauern sehr stark. Es werden daher deutliche Anpassungen der CMS für jeden Einzelfall notwendig. Dies betrifft zunächst die Instrumentierung mit verschiedenartiger Sensorik für Vibration, Ultraschall, Temperaturen oder Messung der Verunreinigungen in Schmiermitteln. Es zeigt sich, dass hier jeweils unterschiedliche Messgrößen zur Erzeugung aussagekräftiger Daten zu Schadensmerkmalen geeignet sind. Daraus resultieren Anpassungsarbeiten an den verwendeten Algorithmen zur Signalanalyse, Merkmalsextraktion und Klassifikation. Besonderes Potential liegt in der permanenten Instrumentierung mit heterogenen, miteinander vernetzten Sensoren im Sinne des IoT (Internet of Things) in Verbindung mit einer multivariaten Datenanalyse.

Aufbauend auf einer eigens entwickelten skalierbaren Sensorplattform zur Anbindung unterschiedlicher Sensoren und ihrer Datenströme konnte durch die Kombination von Vibrations- und Acoustic Emission-Sensoren sowie Machine Learning-Algorithmen ein flexibles System zur Gleitlagerüberwachung geschaffen werden.

Hauptnutzen für Anwender und Vorteile:

- Erhöhung der Genauigkeit der Datenanalyse durch Aggregation heterogener Messdaten



- Erhöhte Robustheit des Systems z.B. gegen variierende Einbaubedingungen des Lagers
- Schnelle Anpassung und Konfiguration des Systems an unterschiedliche Anwendungen
- IoT-basiertes Systemkonzept ermöglicht die Integration in vorhandene IT-Infrastrukturen

Verbesserte Wälzlagerüberwachung durch Kombination von Vibrations- und AE-Sensorik sowie multivariater, ML-gestützter Datenanalyse

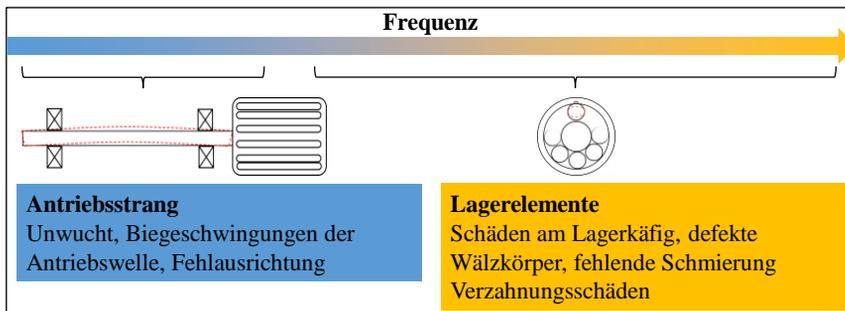
Anforderungen an ein Condition Monitoring System (CMS) zur Wälzlagerüberwachung

- Hohe Empfindlichkeit bei aufkommenden Schäden für eine planbare Wartung
- Verfügbarkeit und Zuverlässigkeit
- Hoher Abdeckungsgrad hinsichtlich möglicher Schäden
- Wirtschaftlicher Mehrwert

Herausforderungen

- Große Variantenvielfalt in der industriellen Antriebstechnik
- Wechselnde Einsatzbedingungen (Drehzahl, Drehmoment, Lastfälle)
- Zuordnung von Signaturen in Sensorsignalen zu Komponenten in Antrieben
- Unterschiedliche Phänomene in Antriebssträngen müssen detektiert und separiert werden
- Datenerfassung muss robust gegenüber nicht zu vermeidenden signifikanten Störeinflüssen sein

- CMS zur Antriebsstrangüberwachung basieren häufig auf Vibrationssensorik (VS) zur Beschleunigungsmessung
- Bei langsam laufenden Maschinen, variierender Drehzahl oder hochfrequenten Schadensereignissen stoßen auf VS basierende CMS oft an ihre Grenzen [1]
- Acoustic Emission (AE) kann bei diesen mittels VS nicht zufriedenstellend lösbaren Problemstellungen gute Ergebnisse erzielen [2]
- Idee: Erweiterung des zeitgleich beobachteten Frequenzbereichs durch Kombination von Vibrations- und Acoustic Emission-(AE-)Sensorik
- Durch Machine Learning-(ML-)Algorithmen [3] und Datenfusion kann eine verbesserte, auch bei variierenden Einbaubedingungen robuste, Schadensdetektion und -klassifikation erreicht werden



- Konzeption und Aufbau eines Antriebsstrangs zur Erprobung und Demonstration
- Instrumentierung mit multimodaler Sensorik (Vibration und AE)
- Vier Schadensklassen an Schulterkugellagern
 - Defektfrei (*No Defect*)
 - Kerbe in der Lauffläche des Innenrings (*Inner Ring*)
 - Kerbe in der Lauffläche des Außenrings (*Outer Ring*)
 - Abflachungen am Wälzkörper (*Rolling Element*)
- Aufnahme mehrerer Messreihen je Schaden
- Regelmäßiger Ein- und Ausbau der Lager zwischen Messungen mit Änderung der Fehlerposition und des Anziehmoments, zur Reduktion der Einflüsse durch Variationen beim Lagereinbau sowie der Position des Fehlers auf das ML-Modell
- Software zur Datenerfassung, -verarbeitung und -ausgabe sowie zur Motorsteuerung läuft auf einer Linux-basierten IoT-fähigen Plattform



- Frequenzfilterung der Vibrations- und AE-Rohdaten, um äußere Störeinflüsse (Umrichter, Netzstörungen) zu eliminieren
- Separieren der Daten in einen Trainingsdatensatz und einen Validierungsdatensatz; die Datensätze enthalten gelabelte Messdaten der vier Schadensklassen
- FFT der einzelnen Datensätze und Training von neuronalen Netzwerken mit den Frequenzspektren zur Schadensklassifikation
- Training eines Klassifikators je Sensormodalität (Vibration, AE); Verwendung von Messdatensätzen bei unterschiedlichen Fehlerpositionen und Anziehmomenten, um eine hiervon unabhängige Schadensklassifikation zu erreichen
- Validierung der Klassifikatoren am Validierungsdatensatz
 - *No Defect* und *Rolling Element* können von beiden Klassifikatoren korrekt zugeordnet werden
 - *Outer Ring* kann von beiden Klassifikatoren nicht korrekt zugeordnet werden
 - *Inner Ring* kann von AE-Klassifikator korrekt, von Vibrationsklassifikator nur schlecht zugeordnet werden

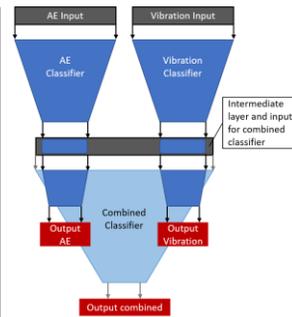
(a) Vibration Classifier

Actual Labels	Predicted Labels			
	No Defect	Inner ring	Outer ring	Rolling element
No Defect	100.00%	0.00%	0.00%	0.00%
Inner ring	0.00%	50.00%	34.38%	15.62%
Outer ring	0.00%	90.62%	9.38%	0.00%
Rolling element	0.00%	0.00%	0.00%	100.00%

(b) Acoustic Emission Classifier

Actual Labels	Predicted Labels			
	No Defect	Inner ring	Outer ring	Rolling element
No Defect	100.00%	0.00%	0.00%	0.00%
Inner ring	0.00%	100.00%	0.00%	0.00%
Outer ring	78.12%	0.00%	12.50%	9.38%
Rolling element	0.00%	0.00%	0.00%	100.00%

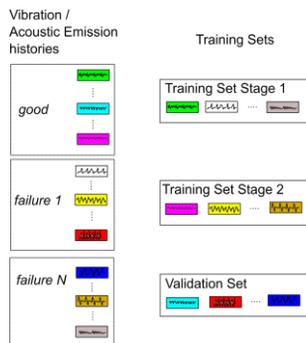
- Validierung der Einzelklassifikatoren mit Trainingsdaten erlaubt korrekte Zuordnung aller Schadensklassen
 - Diskrepanz der Ergebnisse zwischen Validierung an Validierungs- oder Trainingsdatensatz ist Hinweis auf Overfitting
- Erklärung: Aus- und Einbau der Lager zwischen den Messungen und absichtliche Variation der Einbaubedingungen haben nachweislich starken Einfluss auf Frequenzspektren
 - Klassifikatoren lernen somit Charakteristika der Einbaubedingungen, nicht Charakteristika der Schadensklassen
- Datenfusion: Training eines kombinierten Klassifikators; Input ist jeweils eine Zwischenschicht der Einzelklassifikatoren
- Im ersten Schritt Training mit gesamtem Datensatz und Validierung an Validierungsdatensatz
 - Keine nennenswerte Verbesserung, da Problem des Overfitting bestehen bleibt



(c) Combined Classifier

Actual Labels	No Defect	Inner ring	Outer ring	Rolling element
No Defect	100.00%	0.00%	0.00%	0.00%
Inner ring	0.00%	62.50%	21.88%	15.62%
Outer ring	0.00%	75.00%	21.88%	3.12%
Rolling element	0.00%	0.00%	3.12%	96.88%
	Predicted Labels			
	No Defect	Inner ring	Outer ring	Rolling element

- Zur Reduktion des Overfitting und Erhöhung der Robustheit wird Trainingsdatensatz in zwei Datensätze aufgeteilt (*Training Set Stage 1* und *Training Set Stage 2*)
- Training der Einzelklassifikatoren an *Training Set Stage 1*
- Anschließendes Training des kombinierten Klassifikators an *Training Set Stage 2*; Input für diesen Klassifikator ist weiterhin jeweils Zwischenschicht der Einzelklassifikatoren, die an *Training Set Stage 1* trainiert wurden
 - Somit kein „Durchreichen“ des Overfitting der beiden Einzelklassifikatoren an kombinierten Klassifikator
- Validierung an Validierungsdatensatz



(d) Combined Classifier with Splitted Training Dataset

Actual Labels	No Defect	Inner ring	Outer ring	Rolling element
No Defect	100.00%	0.00%	0.00%	0.00%
Inner ring	0.00%	100.00%	0.00%	0.00%
Outer ring	0.00%	15.62%	84.38%	0.00%
Rolling element	0.00%	3.12%	0.00%	96.88%
	Predicted Labels			
	No Defect	Inner ring	Outer ring	Rolling element

Fazit

- Der vorgestellte Ansatz ermöglicht eine präzise Klassifizierung aller betrachteten Schadensfälle durch Fusion von Vibrations- und Acoustic Emission-Daten
- Die Schadensklassifizierung ist robust im Hinblick auf variierende Lagereinbaubedingungen und Fehlerpositionen
- Deutliche Verbesserung einer kombinierten Klassifizierung durch Implementierung einer wirksamen Maßnahme gegen Overfitting (Aufteilen der Trainingsdaten)

Ausblick

- Generierung von Messdaten und Validierung des Ansatzes für einen großen kontinuierlichen Drehzahlbereich, verschieden dimensionierte Antriebsstränge und verschiedene Schadensabstufungen
- Hinzunahme zusätzlicher Modalitäten (bspw. Motor Current Signature Analysis) zur weiteren Verbesserung der Klassifizierungsgenauigkeit, -robustheit und Schadensquantifizierung im Sinne der Predictive Maintenance

Referenzen

- [1] Kang, Myeongsu et al. "Reliable Fault Diagnosis for Low-Speed Bearings Using Individually Trained Support Vector Machines With Kernel Discriminative Feature Analysis.", *IEEE Transactions on Power Electronics*, vol. 30, pp. 2786-2797, 2015.
- [2] Widodo Achmad et al. "Fault diagnosis of low speed bearing based on acoustic emission signal and multi-class relevance vector machine", *Nondestructive Testing and Evaluation*, vol. 24, pp. 313-328, 2009.
- [3] Mey, Oliver et al. "Machine Learning-Based Unbalance Detection of a Rotating Shaft Using Vibration Data", *25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, Vienna, Austria, 08-11 September 2020, pp. 1610-1617.