

# **Strukturierte Zusammenfassung der Dissertation**

## **Beitrag zur Überwachung von Großkraftmaschinen durch Transfer-Lernen**

vorgelegt von  
M. Sc. Christian Scharr

### **Einleitung und Problemstellung**

Im Kontext der vierten industriellen Revolution ist ein signifikanter Anstieg der Anforderungen an die Maschinenverfügbarkeit zu beobachten. Damit wächst insbesondere auch der Bedarf an innovativen Instandhaltungsansätzen wie der Predictive Maintenance (dt.: vorausschauende Wartung). Als Bestandteil von Industrie 4.0, einem Sammelbegriff für Konzepte und Technologien zur Organisation der Wertschöpfungskette, haben sich Methoden der Predictive Maintenance zu einem wichtigen Instrument für Unternehmen entwickelt.

Die zunehmende Verfügbarkeit von Daten und die fortschreitende Entwicklung von Technologien der künstlichen Intelligenz eröffnen der Predictive Maintenance neue Möglichkeiten zur Erstellung hochpräziser Prognosen. Dadurch können Ausfallzeiten minimiert und der Betrieb von Anlagen optimiert werden. Der Einsatz von Predictive Maintenance ermöglicht Unternehmen nicht nur eine Reduktion von Kosten, sondern auch eine Steigerung der Betriebssicherheit sowie eine Verlängerung der Anlagenlebensdauer.

Einzelne Branchen sind bei der Umsetzung von Predictive Maintenance weiter fortgeschritten als andere. Die Forschung im Bereich der Schiffsmotoren ist beispielsweise noch nicht sehr weit entwickelt. Zwar stehen Metadaten der Maschine in großem Umfang zur Verfügung, doch werden diese aufgrund der überwältigenden Menge nur selten für Analysezwecke exportiert. Zudem fehlt es an der notwendigen Expertise für die Datenanalyse und auch an Unterstützung für die kostenintensiven Anfangsinvestitionen in Predictive-Maintenance-Systeme.

Die Effektivität des Trainings intelligenter Lernmodelle hängt stark von der Verfügbarkeit von Sensordaten ab. Aufgrund des Fehlens von Expertenwissen können diese jedoch nicht klassifiziert werden. Zudem liegen keine ausreichenden Motordaten im Fehlerbetrieb vor. Bereits die Aufnahme von Maschinengeräuschen im Betrieb ist mit hohem Aufwand verbunden, die Aufnahme von Fehlerdaten stellt eine noch größere Herausforderung dar.

## **Zielstellung**

Das Hauptziel dieser Dissertation ist die Entwicklung eines intelligenten Fehlererkennungssystems für Großkraftmaschinen, das durch die Interaktion von synthetisch generierten Sensordaten und Methoden des Transfer-Lernens trainiert wird. Das System ist insbesondere darauf ausgelegt, vom Normalzustand abweichende Maschinengeräusche zu identifizieren, um somit potenzielle Schäden frühzeitig zu erkennen, bevor diese zum Ausfall der Maschine führen. Die Validierung des Systems erfolgt anhand von Schiffsmotoren.

Das Problem der unzureichenden Trainingsgrundlage für die Fehlererkennung an Großmotoren wird durch den Einsatz von Methoden des maschinellen Lernens und der Datensynthese gelöst. Die Generierung und Transformation künstlicher akustischer Sensordaten stellt ein ausreichend breites Spektrum möglicher Motorgeräusche und -defekte bereit, um den Bedarf an Trainingsdaten für unterschiedliche Motorzustände zu decken.

Die mittels Datensynthese erzeugten Daten werden als Grundlage für ein Lernmodell zur Fehlererkennung verwendet. Im Anschluss erfolgt eine Übertragung des gewonnenen Wissens mittels Transfer-Lernens auf die Geräuschsignatur realer Anwendungsfälle übertragen, um darin potenzielle Fehler zu erkennen. Ein wesentlicher Vorteil des entwickelten Ansatzes soll in der Unabhängigkeit von der Verfügbarkeit des Schiffsmotors oder zufälligen Schadensfällen liegen, da auf das Wissen bereits trainierter Lernmethoden zurückgegriffen werden kann. Darüber hinaus soll der Ansatz auf verschiedene Motorentypen generalisierbar sein.

## **Vorgehensweise**

Da es das Ziel der vorliegenden Dissertation ist, die Problematik der unzureichenden Verfügbarkeit von Trainingsdatensätzen bei der Überwachung von Großkraftmaschinen zu überwinden, wird dazu ein Lernmodell zur intelligenten Fehlererkennung entwickelt, welches ohne bereits klassifizierte Sensordaten des untersuchten Anwendungsfalles operieren kann. Das Modell, beste-

hend aus einem Modul zur Datensynthese und einem Modul zum Transfer-Lernen, bildet die Grundlage für ein ganzheitliches Monitoring zur Predictive Maintenance. Das Modul der Datensynthese erweitert die akustischen Sensordaten eines kleinen Versuchsmotors mittels intelligenter Lernalgorithmen. Der Versuchsmotor wurde manipulierbar gestaltet, so dass verschiedene Motorzustände bei unterschiedlichen Drehzahlen und Fehlerzuständen manuell erzeugt werden können. Dies gewährleistet die Generierung eines ausgewogenen Trainingsdatensatzes.

Im Rahmen dieser Untersuchung erfolgt ein Vergleich verschiedener generativer Lernverfahren (WaveGAN, SpecGAN) hinsichtlich ihrer Fähigkeit, den gegebenen Labordatensatz generisch zu erweitern und zu manipulieren. Das Ergebnis ist ein realitätsnaher, synthetischer Datensatz beliebiger Größe für verschiedene Maschinenzustände.

Im zweiten Modul erfolgt dann die Wissensextraktion aus dem künstlich erweiterten Datensatz mittels intelligenter Lernalgorithmen. Das extrahierte Wissen wird anschließend mit Hilfe eines Transfer-Lernmodells auf Datensätze aus verschiedenen Anwendungsfällen übertragen. Dazu werden sowohl ein Benchmark-Lernmodell (VGGish) als auch ein vortrainierter Autoencoder verwendet, um das für den Wissenstransfer am besten geeignete Modell zu identifizieren.

Im letzten Schritt erfolgt die Evaluierung und Optimierung des entwickelten Gesamtmodells anhand von Testmessungen auf einem Motorenprüfstand. Darüber hinaus wird ein Benchmark-Datensatz (MiMii) für schallbasierte Maschinenfehler herangezogen, um die Übertragbarkeit des Verfahrens auf andere Einsatzgebiete zu validieren.

## Ergebnisse

Mit Hilfe der beiden generativen Lernverfahren konnten Ergebnisse in Form von synthetischen Audiodaten produziert werden, die sowohl in subjektiven Hörtests als auch mit objektiven Metriken gute Ergebnisse erzielten. Im direkten Vergleich zeigt sich, dass das SpecGAN die besten Ergebnisse liefert und daher als Basis für das Transfer-Lernen gewählt wurde.

Die trainierten Transfer-Lernmodelle können in den Untersuchungen gute Ergebnisse erzielen. Insbesondere der Wissenstransfer auf einen Datensatz eines Motorprüfstandes führt zu einer signifikanten Verbesserung bei der Fehlererkennung. Die Forschungshypothese, dass durch Transfer-Lernen von synthetisch generierten Schalldaten fehlerhafte Motorzustände allein auf Basis des ermittelten Normalzustands von Großmotoren erkannt werden können, kann durch die Untersuchungen bestätigt werden.

Um die Qualität der Modelle weiterhin zu verbessern, sind Langzeituntersuchungen im Realbetrieb erforderlich. Durch die Integration von Expertenwissen in semi-überwachten Lernmethoden könnten die Modelle weiter optimiert werden, sodass sie auf weitere Anwendungsfälle, wie z.B. Landmaschinen oder Werkzeuge im Fertigungsprozess, übertragen werden können. Diesbezüglich wurden bereits Gespräche mit Industrievertretern zur Realisierung des Ansatzes geführt.