



IVS-Award 2020

mit Prämierung am 24.11.2020 / 01.12.2020 für

Herrn Hannes Vietz

**für seine am Institut für Automatisierungstechnik und
Softwaresysteme (IAS) durchgeführte Masterarbeit
(Abgabe: 09/2019) mit dem Titel**

Entwicklung und Implementierung eines Deep Learning Verschleißprognosealgorithmus

Development and Implementation of a Deep Learning based Wear Prognosis Algorithm

Zusammenfassung

Mit dem Aufkommen von leistungsbasierter Logistik und vorausschauender Wartung ist der Bedarf an präziseren Verschleißprognosemethoden gestiegen. Herkömmliche domänenspezifische Simulationen werden durch datengetriebene maschinelle Lernalgorithmen wie Support-Vektor-Maschinen und Random Forests ersetzt. In den letzten Jahren haben tiefe maschinelle Lernverfahren wie Convolutional Neuronale Netzwerke und Netzwerke mit long-short term Gedächtnis begonnen in jedem Bereich bessere Ergebnisse zu erzielen als ihre klassischen Vorgänger, wobei Verschleißprognosen keine Ausnahme darstellen. Obwohl sie außergewöhnliche Ergebnisse erzielen, haben Methoden des tiefen maschinellen Lernens immer noch Implementierungsprobleme, die ein aktives Forschungsfeld darstellen. Eines davon ist das katastrophale Vergessen. Das beschreibt die Unfähigkeit von tiefen lernenden Algorithmen, sequentiell aus verschiedenen Datenquellen zu lernen, ohne, dass vorher gelerntes Wissen sofort zu vergessen.

Diese Arbeit stellt einen neuen Algorithmus zum tiefen Lernen für die Verschleißprognose vor. Ein Netzwerk mit long-short term Gedächtnis wird mit einem sparse Autoencoder zu einem neuen teilüberwachten Verschleißprognose-Algorithmus kombiniert, der Ergebnisse erzielt, die im Bereich der besten veröffentlichten Ergebnisse auf dem NASA-Turbofan-Triebwerksdatensatz liegen. Darüber hinaus wird in der Arbeit untersucht, wie eine tiefe Lernmethode zur Verschleißprognose durch Elastic Weight Consolidation (EWC) aus verschiedenen Datenquellen weiterlernen kann. Es werden neue Erkenntnisse über die Anwendbarkeit von EWC für industrielle Daten gewonnen. Die Ergebnisse deuten darauf hin, dass EWC mit korrelierten Datensätzen verwendet werden kann, aber für Datensätze, deren Komplexität sehr unterschiedlich ist, eher nicht geeignet ist.

Schlüsselwörter: *Künstliche Intelligenz, Maschinelles Lernen, Deep learning, Verschleißvorhersage, Ausfallvorhersage, Elastic weight consolidation, Kontinuierliches Lernen, Teilüberwachtes Lernen*

Abstract

With the rise of performance-based logistics and predictive maintenance, the need for more precise wear prognosis methods has increased. Conventional domain-specific simulation methods are being replaced by data driven machine learning algorithms like support vector machines and random forests. In recent years, deep machine learning methods like convolutional neural networks and long-short term memory networks started to achieve better results than their shallow counterparts in every field and wear prognosis is no exception. While achieving exceptional results, deep learning methods still have implementational problems that are active research interests. One is called catastrophic forgetting. This describes the inability of deep learning algorithms to learn sequentially from different data sources without immediately forgetting earlier knowledge.

This thesis presents a new deep learning algorithm for wear prognosis. A long-short term memory network is combined with a sparse autoencoder to a new semi-supervised wear prognosis algorithm that achieves state of the art results on the NASA turbofan engine dataset. Additionally, the thesis investigates how a deep learning method for wear prognosis can continue learning from different data sources through elastic weight consolidation (EWC). New insights into the applicability of EWC for industrial data are gained. Results suggest that EWC can be used with correlated data sets, but data sets, whose complexity differs greatly will decrease the effect of EWC.

Key Words: *Artificial intelligence, Machine learning, Deep learning, Wear prognosis, Failure prediction, Elastic weight consolidation, Continual learning, Semi-supervised learning*