

Vergleich und Anwendung fortgeschrittener Konzepte des  
maschinellen Lernens zur Anomaliedetektion auf einer  
Förderstrecke

**Bachelorarbeit**

zur Erlangung des akademischen Grades „Bachelor of Science (B. Sc.)“ im  
Studiengang Wirtschaftsingenieur  
der Fakultät für Elektrotechnik und Informatik, Fakultät für Maschinenbau und  
der Wirtschaftswissenschaftlichen Fakultät der Leibniz Universität Hannover

vorgelegt von

Julius Heinzel

██

██

Prüfer: Prof. Dr. Michael H. Breitner  
Betreuer: Philipp Nikolas Müller, Antje Janssen

Hannover, 30.07.2020

# Inhaltsverzeichnis

<b>Abbildungsverzeichnis</b> .....	<b>I</b>
<b>Tabellenverzeichnis</b> .....	<b>III</b>
<b>Abkürzungsverzeichnis</b> .....	<b>IV</b>
<b>1 Einleitung</b> .....	<b>1</b>
<b>2 Research Design &amp; Methodik</b> .....	<b>3</b>
2.1 Knowledge Discovery in Databases .....	3
2.2 Systematische Literaturrecherche .....	5
<b>3 Theoretische Grundlagen</b> .....	<b>9</b>
3.1 Maschinelles Lernen .....	9
3.1.1 Neuronales Netz .....	11
3.1.2 Training eines neuronalen Netzes .....	16
3.1.3 Backpropagation .....	19
3.1.4 Convolutional Neural Network .....	20
3.1.5 Recurrent Netzwerke .....	23
3.2 Autoencoder (AE) .....	24
3.3 Variational Autoencoder (VAE) .....	25
<b>4 Implementierung der Modelle</b> .....	<b>28</b>
4.1 Versuchsaufbau .....	28
4.2 Datenexploration .....	32
4.3 Autoencoder Anwendung und Vergleich .....	38
<b>5 Diskussion und Limitationen</b> .....	<b>50</b>

5.1	Diskussion .....	50
5.2	Limitationen .....	51
<b>6</b>	<b>Fazit und Empfehlung für weitere Forschung .....</b>	<b>52</b>
<b>7</b>	<b>Literaturverzeichnis .....</b>	<b>53</b>

# 1 Einleitung

In der heutigen Zeit wird der Druck nach Effizienz und Kostensenkung immer größer, weshalb sich Unternehmen stetig anpassen müssen, um ihre Wettbewerbsfähigkeit erhalten zu. Ein wichtiger Begriff hierbei ist die Industrie 4.0, deren Ziel es ist, einen effizienteren Produktentstehungsprozess zu erschaffen und die Menschen mit den Maschinen, sowie Produkten weiter zu vernetzen (vgl. Reschke 2016, S. 84).

Ein bedeutender Teil dieses Prozesses ist die Wartung von Maschinen, welche im heutigen industriellen Umfeld meist in festgelegten Wartungsintervallen stattfindet oder wenn eine Maschine einen Defekt aufweist und nicht mehr produktionsfähig ist. Diese Stillstandzeiten sind sehr kostenintensiv, können aber durch eine vorausschauende und zustandsorientierte Wartung (engl. Predictive Maintenance) reduziert werden.

Bei der Wartung von Maschinen gibt es neben der zustandsorientierten Wartung zwei weitere gängige Methoden. Diese sind die präventive Wartung, bei der die Maschinen in festgelegten Intervallen gewartet werden und die reaktive Wartung, bei welcher erst gehandelt wird, wenn ein Ausfall vorliegt. Die einfachste Variante ist die reaktive Wartung, welche jedoch auch die höchsten Kosten durch den ungeplanten Ausfall mit sich bringt. Eine bessere Methode ist die geplante Wartung, bei welcher der Zustand der Maschine aber auf Schätzungen beruht und somit über die Lebensspanne einer Maschine verzichtbare Wartungen durchgeführt werden. Die kosteneffektivste Methode ist die zustandsorientierte Wartung, die ungeplante Stillstandzeiten und Ausfälle umgeht. Um diese Stillstandzeiten so gut wie möglich zu planen ist eine präzise Erkennung des Degradierungszustands von Maschinen Teilen notwendig.

Diese Aufgabe der zustandsorientierten Wartung ist durch die vielen zu betrachtenden Verschleißzustände wie beispielsweise: Lager, Zahnriemen, Kolben und Motoren sehr komplex. Zusätzlich erschwert die Vielfalt von Domains, wie: Transportsysteme, Produktionsmaschinen oder Verpackungsanlagen eine einheitliche Lösung, welche auf mehrere Systeme anwendbar ist. Eine weitere Hürde ist die enorme Datenmenge, die aus den Maschinen ausgelesen wird und durch traditionelle Lösungen wie Domainspezifische Experten nicht bewältigt werden kann.

Verschiedene Algorithmen des Maschinellen Lernens legen die Grundlage für die Verarbeitung von hochdimensionierten Datenreihen, weshalb die Anwendung eines Algorithmus zur Verarbeitung der großen Datenmengen hier sinnvoll ist. Da der Bereich des Maschinellen Lernens sehr umfassend ist wird hier der Teilbereich des Deep Learning genauer betrachtet. Die Schwierigkeit liegt hierbei in der zuverlässigen Erkennung von sehr geringen Abweichungen des Prozesses und der Daten von dem Sollzustand. Diese frühzeitige Erkennung von Anomalien ist notwendig, um den weiteren Prozess zu überwachen und dann rechtzeitig eingreifen zu können, sofern der Verschleiß ein Stadium erreicht hat, welches notwendige Instandhaltungen benötigt.

Um diese Problemstellung zu untersuchen, wird in dieser Arbeit die verbesserte Vorhersage von Zeitreihendaten durch Machine Learning Methoden untersucht. Im Rahmen einer vorangegangenen Arbeit wurden bereits verschiedene Machine Learning Methoden auf diesen Daten verglichen. Eins dieser Modelle, der Autoencoder, wird in dieser Arbeit mit einer weiterentwickelten Form, dem sogenannten Variational Autoencoder in der Performance verglichen. Die Anwendung und Vergleiche der Konzepte finden auf Sensordaten einer Förderstrecke statt, welche von Lenze SE zur Verfügung gestellt wurden.

Der weitere Verlauf der Arbeit gliedert sich wie folgt:

In Kapitel 2 wird ein Forschungsdesign zur Generierung von Wissen aus Daten vorgestellt und anschließend eine Strukturierte Literaturanalyse durchgeführt. In Kapitel 3 werden die theoretischen Grundlagen dieser Arbeit dargelegt. Dabei wird auf verschiedene Konzepte des Deep Learning eingegangen sowie die grundlegenden Ideen der Algorithmischen Optimierung im Bereich des Deep Learning erläutert. In Kapitel 4 findet die Implementierung der Modelle statt. Hierbei wird zuerst der Versuchsaufbau beschrieben und anschließend eine Datenexploration durchgeführt. Danach werden die Anwendung und der Vergleich der Modelle anhand der Daten vorgenommen. In Kapitel 5 werden die Ergebnisse aufgezeigt und kritisch diskutiert. Anschließend werden die Limitationen aufgeführt, welche die Arbeit einschränken. Abschließend wird in Kapitel 6 die Arbeit zusammengefasst und ein Ausblick, sowie Empfehlungen für weitere Forschung gegeben.

## 6 Fazit und Empfehlung für weitere Forschung

Diese Arbeit untersuchte die unterschiedlichen Rekonstruktionen von einem Standard und einem Variational Autoencoder auf Zeitreihendaten, im Rahmen der Entwicklung einer Predictive Maintenance Lösung für Intralogistik Anwendungen. Die verwendeten Daten stammen aus einer Teststrecke von Lenze SE und wurden von Sensoren an einer Förderstrecke ausgelesen. Der Vergleich zeigte, dass die Modelle von unterschiedlichen Hyperparametereinstellungen unterschiedlich stark profitieren. Bei dem Variational Autoencoder müssen zur deutlichen Verbesserung des Rekonstruktionsfehlers nicht nur die Epochen, sondern auch anderen Hyperparameter angepasst werden. In Betrachtung auf den Rekonstruktionsfehler, welcher als Messwert für die Performance der Modelle dient, erreichte der Variational Autoencoder deutlich genauere Vorhersagen. Diese besseren Ergebnisse wurden überdies auch noch in einer deutlich kürzeren Trainingszeit erzielt.

In zukünftigen Forschungen ist es empfehlenswert die trainierten Modelle auf Datensätzen mit Anomalien zu evaluieren, um die Performanceverbesserung bei der Anomaliedetektion zu untersuchen. Nachdem eine Anomalie erkannt wurde ist jedoch nur bekannt, dass ein Fehler vorliegt der jedoch noch nicht klassifiziert und in seiner Stärke bestimmt ist. Weitere Untersuchungen beschäftigen sich hier mit den Klassifizierungen von erkannten Fehlern, wobei wieder neue Hürden, wie Pseudofehler bestehen. Diese Pseudofehler sind potentielle Fehler, die im Verlaufe des Kontrollprozesses auftreten können (vgl. Li et al. 2004, S. 812). Ein Beispiel hierfür wäre, dass das Transportband eine Koffermasse 0 erwartet, jedoch eine Koffermasse 2 erhält und deshalb ein Fehler klassifiziert wird, welcher aber in Wirklichkeit nur ein Scheinfehler ist. Ein weiteres Problem bei der Klassifikation ist zudem der Umgang mit neuen Schadensklassen, weshalb bei der Einführung eines Konstruktes zwei Dinge erfüllt werden müssen. Dies sind zum einen die robuste Erkennung von bekannten Schadensklassen und zum anderen ein Verfahren zum Umgang mit neuartigen, unbekanntem Schadensklassen. Eine weitere Möglichkeit ist die Anwendung auf einer realen Anlage um zu untersuchen, ob die erreichten Ergebnisse auch auf Daten, welche nicht aus einer Laborumgebung stammen erreicht werden können.

Zudem wäre bei weiteren Forschungen auch die Anwendung eines Convolutional Netzwerks oder ein hybrides Modell, wie ein Convolutional Variational Autoencoder denkbar (vgl. Kim et al., S. 67–71)