Diss. ETH No. 24336

A Quality Inspection System for Precision Machinery Based on Generative Modeling

A thesis submitted to attain the degree of

DOCTOR OF SCIENCES of ETH ZURICH

(Dr. sc. ETH Zurich)

presented by

JIANWEN SUN

M.Sc., EPFL

born on 23.09.1987

citizen of People's Republic of China

accepted on the recommendation of

Prof. Dr. Richard Hahnloser, examiner

Dr. Michael Pfeiffer, co-examiner

Dr. Iason Kastanis, co-examiner

2017

Abstract

Precision machinery refers to small-sized mechanical products that work precisely under various conditions. It is widely used in diverse safety-critical systems with high requirements for the quality. As a critical step in manufacturing, quality inspection aims to detect defective products from the production line to guarantee the quality of shipped products. Numerous approaches to quality inspection have been developed over the past decades. Nevertheless, the selection of features from raw data remains a bottleneck problem for both academic and industrial solutions. Moreover, the automation level of current quality inspection systems needs to be improved since lots of human interventions are required.

In this thesis, we develop a new quality inspection system for the precision machinery industry to cope with the aforementioned issues. We utilize deep learning algorithms for their strong feature learning ability to overcome the bottleneck in feature selection. In view of the fact that there are usually a sufficient amount of good but a scarce amount of defective samples available for the feature learning, we build our system upon a generative model, the Deep Belief Network based Auto-Encoder (DBN-AE). The developed system '*Tilear*' has two modules, *Teacher* and *Tester*. *Teacher* is responsible for the training of a DBN-AE. During the training, the DBN-AE learns how to reconstruct signals of good samples closely, and determines a threshold to differentiate good samples from defective ones based on reconstruction errors of the training samples. *Tester* then makes a decision on a test sample by comparing its reconstruction error to the threshold.

We first prove the feasibility of *Tilear* with data sets acquired in the laboratory from electric motors provided by *Maxon Motor*. Our results indicate that *Tilear*, trained with different signal features and boosted with Graphic Processing Units, can detect defective samples effectively and efficiently, meeting industrial requirements for the runtime. By comparing *Tilear* to the one-class Support Vector Machine (SVM), a state-of-the-art academic approach to quality inspection, we demonstrate that *Tilear* has a comparable learning but better generalization abilities.

We also invite several companies to conduct industrial tests of *Tilear* with their products. In these tests, *Tilear* outperforms their current solutions in both aspects of accuracy and stability. More importantly, *Tilear* is easy to use even for operators without deep learning background. Therefore, human intervention is minimized.

Furthermore, we develop several tools to facilitate the integration of *Tilear* into production lines. We implement a hyperparameter optimization tool based on the random search method. Experiment results show that it significantly improves *Tilear*'s performance on the data set on which *Tilear* had a poor performance. We also construct two visualization tools based on the t-Stochastic Neighbor Embedding

(t-SNE) and activation maximization, respectively. The t-SNE-based tool proves to be of great help to interpret the learning process of a DBN-AE. Relatively, the activation maximization-based tool provides limited supports to understanding the learned features because of the difficulty in explaining one-dimensional features intuitively. In addition, we build a tool employing the 'dropout' technique to alleviate the overfitting associated with small sample sizes. This dropout-based tool largely improves *Tilear*'s generalization ability for small sample data sets while maintaining a comparable learning ability.

Zusammenfassung

Präzisionsmaschinen beziehen sich auf kleinangelegt mechanische Produkte, die unter verschiedenen Bedingungen präzise arbeiten. Es ist weit verbreitet in diversen sicherheitskritischen Systemen mit hohen Anforderungen an die Qualität eingesetzt. Als kritischer Schritt in der Fertigung zielt die Qualitätsprüfung darauf ab, fehlerhafte Produkte aus der Produktionslinie zu erkennen, um die Qualität der ausgelieferten Produkte zu garantieren. In den vergangenen Jahrzehnten wurden zahlreiche Ansätze zur Qualitätskontrolle entwickelt. Dennoch bleibt die Auswahl der Features aus Rohdaten ein Engpassproblem für akademische und industrielle Lösungen. Darüber hinaus muss das Automatisierungsniveau der aktuellen Qualitätskontrollsysteme verbessert werden, da viele menschliche Eingriffe erforderlich sind.

In dieser Arbeit entwickeln wir ein neues Qualitätsprüfsystem für die Präzisionsmaschinenindustrie, um die vorgenannten Themen zu bewältigen. Wir nutzen deep learning algorithmen für ihre starke Feature-Lernfähigkeit, um den Engpass in der Feature-Auswahl zu überwinden. Angesichts der Tatsache, dass es in der Regel eine ausreichende Menge an gutem, aber eine knappe Menge an defekten Proben gibt, die für das Feature-Lernen verfügbar sind, bauen wir unser System auf einem generativen Modell, dem Deep Belief Network Based Auto-Encoder (DBN-AE). Das entwickelte System '*Tilear*' hat zwei Module, *Teacher* und *Tester*. Der *Teacher* ist für die Ausbildung eines DBN-AE verantwortlich. Während des Trainings lernt der DBN-AE, wie man Signale von guten Proben genau rekonstruiert, und bestimmt eine Schwelle, um gute Proben von defekten auf der Grundlage von Rekonstruktionsfehlern der Trainingsproben zu unterscheiden. Der *Tester* entscheidet dann über eine Testprobe, indem er seinen Rekonstruktionsfehler mit dem Schwellenwert vergleicht.

Zuerst beweisen wir die Machbarkeit von *Tilear* mit Datensätzen, die von Elektromotoren von *Maxon Motor* im Labor erworben wurden. Unsere Ergebnisse zeigen, dass *Tilear*, der mit unterschiedlichen Signalmerkmalen trainiert und mit Graphic Processing Units (GPUs) verstärkt wurde, fehlerhafte Proben effektiv und effizient erkennen und den industriellen Anforderungen für die Laufzeit gerecht wird. Durch den Vergleich von *Tilear* mit der "one-class Support Vector Machine (SVM)", einem hochmodernen akademischen Ansatz zur Qualitätskontrolle, zeigen wir, dass *Tilear* ein vergleichbares Lernfähigkeit, aber bessere Verallgemeinerungsfähigkeiten hat.

Wir laden auch mehrere Unternehmen ein, industrielle Tests von *Tilear* mit ihren Produkten durchzuführen. In diesen Tests übertrifft *Tilear* ihre aktuellen Lösungen in beiden Aspekten der Genauigkeit und Stabilität. Noch wichtiger ist, *Tilear* ist einfach zu bedienen, auch für Betreiber ohne deep learning Hintergrund. Daher wird

die menschliche Intervention minimiert.

Darüber hinaus entwickeln wir verschiedene Werkzeuge, um die Integration von *Tilear* in Produktionslinien zu erleichtern. Wir implementieren ein Hyperparameter-Optimierungswerkzeug basierend auf der random search Methode. Die Ergebnisse des Experiments zeigen, dass es die Leistung von *Tilear* auf dem Datensatz, auf dem *Tilear* eine schlechte Leistung hatte, deutlich verbessert. Wir konstruieren auch zwei Visualisierungswerkzeuge, die auf der "t-Stochastic Neighbor Embedding (t-SNE)" beziehungsweise der "activation maximization" basieren. Das t-SNE-basierte Tool erweist sich als sehr hilfreich, um den Lernprozess eines DBN-AE zu interpretieren. Relativ dazu bietet das activation-maximization-basierte Tool begrenzte Unterstützung für das Verständnis der gelernten Features, da es schwierig ist, eindimensionale Merkmale intuitiv zu erklären. Darüber hinaus bauen wir ein Werkzeug mit der "Dropout" -Technik, um die Überfüllung mit kleinen Stichprobengrößen zu lindern. Dieses Dropout-basierte Tool verbessert die Verallgemeinerungsfähigkeit von *Tilear* für kleine Beispieldatensätze weitgehend, während eine vergleichbare Lernfähigkeit beibehalten wird.