

ABSTRACT

In the injection moulding industry, companies are exposed to increasing quality and cost pressure. The customers of these companies demand almost 100 % quality control. In this context, the analysis of multivariate time series data generated by machines plays a central role. In addition to noise, non-linear relationships between the individual process parameters can also be present in this process data. The detection of abnormal cycles is a challenge to sort out faulty mouldings. Furthermore, the interpretation of abnormal cycles is a key component for injection moulding companies in a regulated environment to understand the abnormal process behaviour. The objective of this thesis is to develop an explanatory method for a Deep Learning (DL) model to interpret an abnormal cycle.

In this work, explanatory methods for Machine Learning (ML) models were applied to injection moulding data. An approach was developed to explain the model decision from an Autoencoder (AE). Based on this approach, the SHapley Additive exPlanations (SHAP), Local Interpretable Model-agnostic Explanation (LIME) and Integrated Gradients (IG) explanatory methods were evaluated for accuracy using an innovative fingerprinting technique. As a result, these methods provide the influence of each feature on AE model decision. The accuracy and runtime of the methods were also investigated in the evaluation. These two aspects are essential for the use of explanatory methods in real-time industrial systems. Furthermore, a dashboard application was designed to support machine operators in interpreting abnormal process cycles. An expert discussion makes clear that the dashboard is a helpful tool for understanding abnormal cycles.

The result of this thesis shows that IG is the best method for explaining an AE model decision in terms of accuracy and real-time capability. The IG method achieves an AUC score of over 0.97 on the injection moulding data. In addition, domain-specific visualisations can assist a domain expert in explaining the causes of an abnormal cycle.

Keywords: anomaly detection, time series, deep learning, autoencoder, explanatory methods, injection moulding

ZUSAMMENFASSUNG

In der Spritzgussindustrie sind Unternehmen einem steigenden Qualitäts- und Kostendruck ausgesetzt. Die Kunden dieser Unternehmen fordern eine nahezu 100 % Qualitätskontrolle. In diesem Zusammenhang spielt die Analyse der von Maschinen erzeugten multivariaten Zeitreihendaten eine zentrale Rolle. In diesen Prozessdaten können neben Rauschen auch nichtlineare Beziehungen zwischen den einzelnen Prozessparametern vorliegen. Hierbei ist die Erkennung von anormalen Zyklen eine Herausforderung, um fehlerhafte Spritzlinge auszusortieren. Des Weiteren ist die Interpretation von anormalen Zyklen ein zentraler Baustein für Spritzguss Unternehmen im regulierten Umfeld, um das anormale Prozessverhalten zu verstehen. Die Problemstellung der Arbeit ist es, eine Erklärungsmethode für ein Deep Learning (DL)-Modell zur Interpretation eines anormalen Zyklus zu entwickeln.

In dieser Arbeit wurden Erklärungsmethoden für Machine Learning (ML) Verfahren auf Spritzgussdaten angewendet. Es wurde ein Vorgehen entwickelt, um die Modellentscheidung von einem Autoencoder (AE) zu erklären. Auf Basis dieses Vorgehens wurden die Erklärungsmethoden SHapley Additive exPlanations (SHAP), Local Interpretable Model-agnostic Explanation (LIME) und Integrated Gradients (IG) mit einer innovativen Fingerabdruck Technik hinsichtlich der Genauigkeit evaluiert. Als Ergebnis liefern diese Methoden den Einfluss der einzelnen Merkmale auf die AE-Modellentscheidung. In der Evaluation wurde neben der Genauigkeit auch die Laufzeit der Methoden untersucht. Diese beiden Aspekte sind essentiell für den Einsatz von Erklärungsmethoden in echtzeitfähigen industriellen Systemen. Des Weiteren wurde eine Dashboard Anwendung konzipiert, um Maschinenbediener bei der Interpretation von anormalen Prozesszyklen zu unterstützen. In einem Expertengespräch wurde ersichtlich, dass das Dashboard ein nützliches Werkzeug zum Verstehen von anormalen Zyklen darstellt.

Im Ergebnis zeigte sich, dass die IG Methode zur Erklärung einer AE-Modellentscheidung hinsichtlich der Genauigkeit und Echtzeitfähigkeit am besten geeignet ist. Die IG Methode erreicht einen AUC-Score von über 0,97 auf den Spritzgussdaten. Außerdem können domänenspezifische Visualisierungen einen Domänenexperten bei der Erklärung der Ursachen eines anormalen Zyklus unterstützen.

Schlagwörter: Anomalie Detektion, Zeitreihen, Deep Learning, Autoencoder, Erklärungsmethoden, Spritzgussfertigung