

# Vorhersagbare Qualität: Maschinelles Lernmodell mit Ofen- und Fülldaten zur Vorhersage von Prüffeldergebnissen

Masterarbeit im Studium Computational Social Systems von Benjamin Gigerl<sup>1</sup>  
 Betreut von Stefan Thalmann<sup>2</sup>, Roman Kern<sup>3</sup>, Tim Keßler<sup>4</sup> und Johann Raminger<sup>5</sup>

<sup>1</sup>Abteilung für Prozessdigitalisierung, Siemens Energy, Weiz, Österreich, [benjamin.gigerl@siemens-energy.com](mailto:benjamin.gigerl@siemens-energy.com)

<sup>2</sup>Institut für Operations und Information Systems, Universität Graz, Graz, Österreich, [stefan.thalmann@uni-graz.at](mailto:stefan.thalmann@uni-graz.at)

<sup>3</sup>Institut für Interactive Systems und Data Science, Technische Universität Graz, Graz, Österreich, [rkern@tugraz.at](mailto:rkern@tugraz.at)

<sup>4</sup>Abteilung für Prozessdigitalisierung, Siemens Energy, Erlangen, Deutschland, [tim.kessler@siemens-energy.com](mailto:tim.kessler@siemens-energy.com)

<sup>5</sup>Abteilung Prüffeld, Siemens Energy, Weiz, Österreich, [johann.raminger@siemens-energy.com](mailto:johann.raminger@siemens-energy.com)

*Zusammenfassung* - Im Rahmen einer Fallstudie eines Industrieunternehmens wird hierbei die Beantwortung der Frage gelöst, ob prädiktive Qualitätskontrolle bereits bei der Herstellung von Transformatoren möglich ist. Da die respektiven Fertigungsprozesse in Zukunft immer komplexer werden, wird eine Methodik zur frühzeitigen Identifizierung von Prüffehlern angestrebt. Mittels maschinellen Lernens (ML) wurde somit ein Entscheidungsunterstützungssystem aufgebaut, welches dem/der Fertigungsmitarbeiter\*in präventive Maßnahmen zur Verhinderung eines Prüfschadens setzen lässt. Der Vorteil von prädiktiver Qualitätskontrolle obliegt dabei, kostenintensive Totalausfälle zu vermindern. Im Anwendungsfall wird spezifisch auf den Ofen- und Füllprozess eingegangen, wobei ebenfalls technische Produktdaten sowie Sensordaten der Maschinen und Hallenwetterstationen herangezogen werden. Durch das Trainieren verschiedener überwachter Lernmethoden konnten somit Aussagen über die Merkmalwichtigkeit sowie erste Vorhersagen in der Fertigung durchgeführt werden. Der datenwissenschaftliche Lebenszyklus zeigte schließlich auf, wie wichtig eine Einbindung von Domainwissen bei der Entwicklung solcher prozessspezifischen Modelle ist. Die Datenbereinigung verzeichnete dabei 70% der Zeit im gesamten datenwissenschaftlichen Lebenszyklus. Der XGBoost lieferte anwendungsspezifisch die leistungsstärksten Ergebnisse für beide Modelle zur korrekten Klassifizierung von kostenintensiven Prüfschäden. Eine generelle Klassifizierungsgenauigkeit von 83,3% und 81,2% konnte final erreicht werden. Aus betriebswirtschaftlicher Sichtweise amortisiert sich das Entscheidungsunterstützungssystem in 4 Monaten und konnte 64% der historischen Nacharbeitskosten bereits präventiv identifizieren. Insgesamt unterstreicht diese Forschungsarbeit das Potenzial von ML zur Kosteneinsparung, Verringerung der Fehlerquote und Steigerung der Prozesstransparenz im Qualitätsbereich. Ausgewählte Abschnitte der Masterarbeit werden noch im Rahmen eines Papiers bei der IEEM2023 Konferenz in Singapur publiziert.

*Schlüsselwörter* - Prädiktive Qualitätskontrolle; Transformatoren; Entscheidungsunterstützungssystem

*Prozessablauf* - In der Produktion greift der/die Fertigungsmitarbeiter\*in über analytische Apps auf die aktuellen ML-Modelle zu (siehe Abbildung 1).

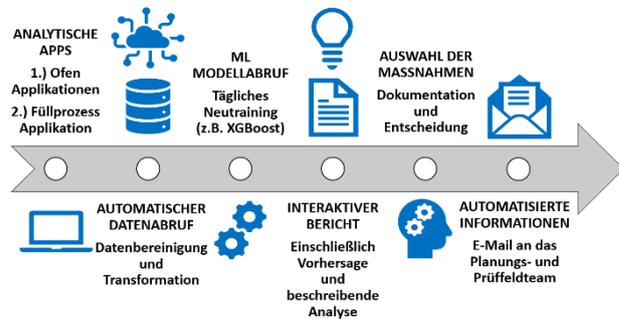


Abbildung 1. Produktives Entscheidungsunterstützungssystem

Wenn ein Prozess beendet ist, kann der/die Benutzer\*in mit einer Abrufanfrage aktuelle Fertigungsdaten anfordern und so eine Live-Qualitätsprognose durchführen. Automatisch wird die letzte Prozesscharge identifiziert und für jeden Transformator eine Ausfallwahrscheinlichkeit für Teilentladungen berechnet. In dieser Fallstudie liegt der Fokus auf erklärungs-fähiger künstlicher Intelligenz, daher werden dem/der Produktionsmitarbeiter\*in umfassende Prozessdiagramme, signifikante Ausreißer Parameter im Prozess und Statistiken von ähnlichen guten sowie schlechten Transformatoren in einem interaktiven Bericht präsentiert. Dies hilft qualitätsbeeinflussende Faktoren aus Ofen- und Füllprozessen zu interpretieren und so im nächsten Schritt präventive Maßnahmen zu ergreifen. Um den Entscheidungsprozess transparent und effizient zu gestalten, werden vordefinierte Maßnahmen vorgeschlagen und die Details der Maßnahme können über ein Kommentarfeld dokumentiert werden. In Abbildung 2 ist dabei das Projektteam zu sehen und die Vorhersage-Apps sind seit März 2023 im produktiven Einsatz.



Abbildung 2. Erfolgreiche Implementierung bei Siemens Energy