



Besseres Verständnis

Analyse von Produktionsprozessen mit Predictive-Quality-Ansätzen

In großen Datenmengen verbergen sich gerade für produzierende Unternehmen viele Informationen. Inzwischen können qualitätsrelevante Faktoren mit Predictive-Quality-Ansätzen analysiert werden. Die Erkenntnisse daraus eröffnen den Ingenieuren neue Entscheidungsspielräume.

Sebastian Beckschulte, Louis Huebser, Christian Schumacher, Robert H. Schmitt und Reiner Kurzhals

Das allgemeine Qualitätsverständnis reduziert die Qualitätswissenschaft zumeist auf die Produktqualität. Diese ist vor allem stark beeinflusst durch kontrollierbare Prozesse und qualitativ abgesicherte Rohmaterialien und Halbzeuge. Auch wenn möglichst gleichbleibende Prozesse erwünscht sind, drängt eine steigende kundenindividualisierte Produktion die Unternehmen zur Erhöhung der Prozessvarianz.

Für diese Zunahme an Verflechtungen aus Material, Prozess und Kundenwunsch wurden klassische QM-Werkzeuge und Vorgehensweisen ursprünglich nicht konzipiert [1]. Diese stoßen zunehmend an ihre Grenzen, denn eine eindeutige Identifizierung der qualitätsrelevanten Faktoren wird mithilfe von klassischen Methoden (z. B. faktorielle Versuche, Regressionsanalysen

und Qualitätsregelkarten) immer schwieriger und ressourcenzehrender.

Wo solche Methoden nur lineare Zusammenhänge aufdecken und eine eingeschränkte Beurteilung zulassen, können weitere vorhandene Informationen mithilfe von Predictive Quality berücksichtigt werden. Darüber hinaus können neben den klassischen Produktionsdaten auch Zwischenergebnisse, Informationen zu individuellen Baugruppen oder komplexe Prozessdaten mit einer Vielfalt weiterer Daten kombinierbar gemacht werden. Sogar die Produktnutzung wird als weitere Datenquelle und Anwendungsfeld mit in den Betrachtungsrahmen aufgenommen. Durch einen datengetriebenen und vorhersehbaren Ansatz kann ein Blick in die Zukunft (Prädiktion) eine genauere Betrachtung der qualitätsrelevanten Faktoren ermöglichen.

Nichtsdestotrotz lassen sich in Produktionsdaten vielfältige Verflechtungen wiederfinden. Gerade moderne Ansätze der Datenanalytik ermöglichen es, den bisher verborgenen Erkenntnisschatz zugänglich zu machen. Der Einsatz von Data Analytics in der Qualität ermöglicht so eine frühzeitige Vorhersage von Abweichungen, sodass kontrolliert gegengesteuert werden kann. Komplexe Prozesse werden nicht nur effizienter, sondern auch kontrollierbar [2, 3].

Ein solcher Paradigmenwechsel von präventiv hin zu prädiktiv ist deshalb keinesfalls als Ablösung zu verstehen, sondern vielmehr als eine gezielte Ergänzung zu bestehenden Methoden. Mit der effektiven Nutzung der heutzutage vorhandenen Daten und der zunehmenden Verfügbarkeit von produktions- und nutzungsspezifischen Informationen zu jedem produzier-

ten Produkt rückt der Produktfokus wieder stärker in den Mittelpunkt, besonders im Kontext der stückgenauen Rückverfolgbarkeit. Der Wert von Predictive Quality liegt folglich nicht in den Daten selbst, sondern in den Erkenntnissen, da diese neue Entscheidungsspielräume eröffnen.

Fehler und Wechselwirkungen blieben unerkannt

In einem Pilotprojekt eines Getriebewellenherstellers und des Werkzeugmaschinenlabors Aachen (WZL) wurden Fertigungsdaten eines Drehprozesses zur Wellenherstellung aufgenommen und ausgewertet. Im Zuge von steigenden Dokumentationspflichten und damit einhergehend steigenden Aufwänden wurde angenommen, dass der bisherige Ansatz, je Messmerkmal eine separate Statistische Regelkarte zu führen, unzureichend ist. Somit ergab sich die Vermutung, dass ein Großteil der Fehler nicht zuverlässig aufgezeigt werden konnte und Wechselwirkungen unerkannt blieben.

Im Mittelpunkt der Betrachtung standen die Parameter der Schnittgeschwindigkeit des Prozesses, die während des Eingriffs automatisiert aufgenommen und gemittelt wurden, und die gefertigten Wellendurchmesser, die manuell und pro Teil gemessen werden mussten. Zur Validierung der Ergebnisse wurden über einen längeren Zeitraum zusätzlich zu den laufenden Messungen für die Regelkarten 100-Prozent-Prüfungen der Endprodukte

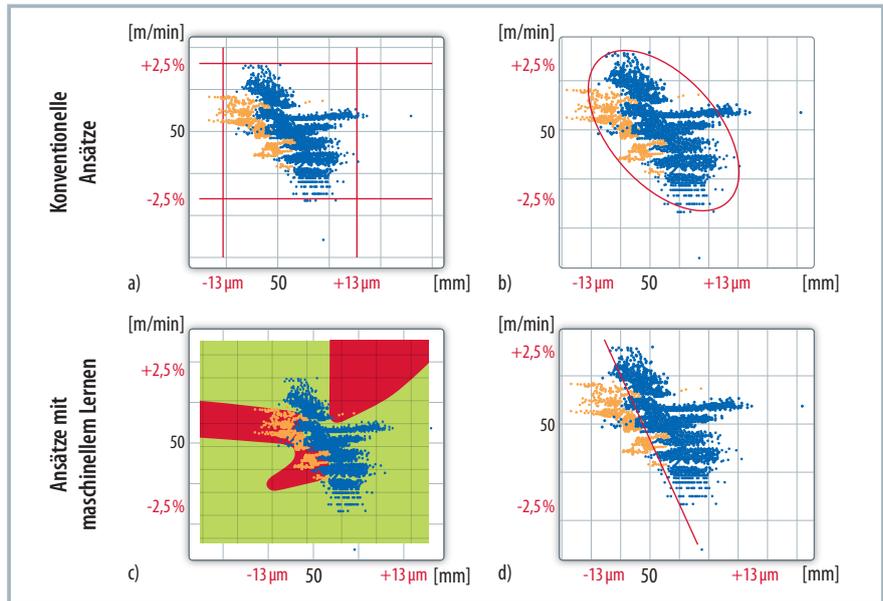


Bild 1. a) Separate Betrachtung von Regelkarten entspricht einer Rechteckgrenze im Streudiagramm, b) 99,73 % Streuungsellipse zur Identifikation von Ausreißern durch unnatürliche Streuung, c) rote Bereiche zeigen Schlechteil-, grüne Bereiche Gutteilvorhersagen des Neuronalen Netzes, d) vereinfachte Entscheidungsregel Quelle: RWTH Aachen, Grafik: © Hanser

durchgeführt. Mittels der zusätzlichen 100-Prozent-Prüfung konnte ermittelt werden, dass das Überschreiten der aktuell benutzten Regelkarten nur in den seltensten Fällen einen Fehler identifiziert. Eine Nutzung als alleinstehende Qualitätslenkungsmethode im täglichen Produktionsprozess ist somit nicht zielführend.

Die separate Betrachtung der Messmerkmale trägt der Produktionskomplexität nur unzulänglich Rechnung. Demnach wurde ein Ansatz verfolgt, bei dem beide

Messmerkmale simultan betrachtet werden. Innerhalb eines Streudiagramms, das beide Messmerkmale je gemessenen Produkt darstellt, wurde in einem vorläufigen Ansatz eine Ellipse angepasst, die 99,73 % aller Messungen umfasst. Dies entspricht dem Grundkonzept der eindimensionalen Regelkarte, unnatürliche Streuungsmuster zu erkennen.

Ein Abgleich mit den vorhandenen 100-Prozent-Prüfungsergebnisse zeigte jedoch, dass auch dieser Ansatz nur unzuverlässig Produktionsausreißer erkennt und somit für eine frühzeitige Warnung abnehmender Prozessqualität ungeeignet ist. Eine nähere Betrachtung des Streudiagramms gab Aufschluss darüber, dass Produktausreißer über gängige, auf Linearität und Normalverteilung basierende QM-Methoden nicht hinreichend genau erfasst werden können.

Aufbauend auf den vorangegangenen Kenntnissen wurde eine Methode des Maschinellen Lernens angewandt. Anhand der vorhandenen Messungen wurde ein sogenanntes Feedforward-Neuronales Netz antrainiert, das in den zugrunde liegenden Daten nicht lineare und komplexe Zusammenhänge erfasst. Die Genauigkeit des Neuronalen Netzes bezogen auf die bekannten 100-Prozent-Prüfungen betrug 94,02 %. Somit konnte über Bereiche im Streudiagramm, in denen keine >>>

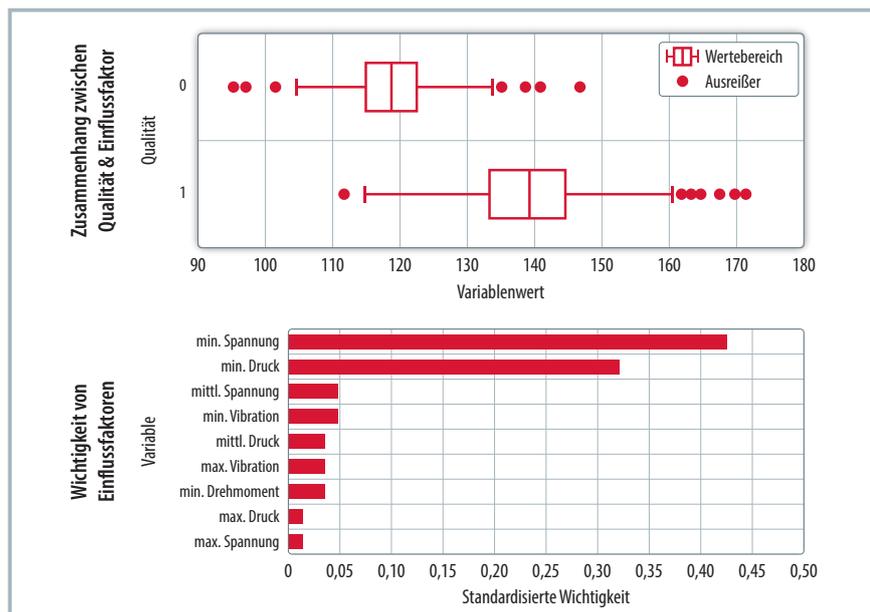


Bild 2. Zusammenhang zwischen Qualität (0: ausreichende Qualität, 1: gute Qualität) und Einflussfaktor sowie Wichtigkeit von möglichen Einflussfaktoren Quelle: RWTH Aachen, Grafik: © Hanser

Intelligent Testing
Für Werkstoffe, die die Welt verändern

Zwick / Roell

www.zwickroell.com AllroundLine bis 250 kN

Die Herausforderungen an neue Materialien sind enorm: Geringeres Gewicht bei höheren Festigkeitskennwerten. Die AllroundLine hilft Ihnen bei diesen Herausforderungen für Composites: 21 Prüfungen, 115 Normen, 320 ° Temperaturbereich mit nur einer Prüfmaschine.



INFORMATION & SERVICE

PROJEKT

Das Projekt wurde durch die Deutsche Forschungsgemeinschaft (DFG) im Rahmen der Exzellenzstrategie des Bundes und der Länder – EXC-2023 Internet of Production – 390621612 gefördert.

LITERATUR

- 1 **Schmitt, R. H.:** Potentiale Künstlicher Intelligenz für die Qualitätswissenschaft. Bericht zur QW-Jahrestagung 2018 in Nürnberg, Springer Vieweg, 2020
- 2 **Refflinghaus, R.; Kern, Ch.; Klute-Wenig, S. (Hrsg.):** Qualitätsmanagement 4.0 – Status quo! Quo vadis? Bericht zur QW-Jahrestagung 2016 in Kassel, kassel university press
- 3 **Manyika, J., et al.:** Jobs lost, jobs gained: Workforce transitions in a time of automation. McKinsey Company Global, 2017

AUTOREN

M. Sc. Sebastian Beckschulte und **M. Sc. Louis Huebser** sind wissenschaftliche Mitarbeiter am Werkzeugmaschinenlabor (WZL) der RWTH Aachen.
Dr. Christian Schumacher arbeitet als Senior Data Scientist in der Westphalia DataLab GmbH (WDL), Münster, im Bereich Supply Chain & Manufacturing.
Prof. Dr.-Ing. Robert H. Schmitt ist Direktor am WZL der RWTH Aachen sowie Mitglied des Direktoriums am Fraunhofer-Institut für Produktionstechnologie IPT.
Prof. Dr. Reiner Kurzhals ist Professor an der Münster School of Management sowie Mitbegründer der WDL.

KONTAKT

Sebastian Beckschulte
T 0151 729 219 57
s.beckschulte@wzl.rwth-aachen.de

oder nur wenige Messungen vorlagen, eine Vorhersage über Gut- bzw. Schlechteile getätigt werden. Anhand der hierdurch intuitiver zugänglichen Visualisierung von Schlechteilbereichen (rote Schraffierung) können somit Merkmalskombinationen identifiziert werden, die frühzeitig ein Schlechteil vorhersagen (Bild 1).

Die Implementierung eines Neuronalen Netzes hat den Prüfaufwand durch Identifikation von Schlechteilbereichen erheblich reduziert. Eine regelmäßige Wiederholung des Antrainierens des Netzes bietet zudem die Möglichkeit, zeitliche Veränderungen des Prozesses in der Betrachtung mit einzubeziehen.

Informationen werden mit Software interaktiv analysiert

Die Otto Fuchs KG produziert Teile für die Automobil- und Luftfahrtindustrie, an die hohe Qualitätsanforderungen gestellt werden. Daher führte der Hersteller an allen Teilen des untersuchten Produkts eine Stichprobe der Eigenschaften durch. Mit klassischen Methoden konnten die festgestellten Qualitätsschwankungen zwischen verschiedenen Produktionsbatches und zwischen Teilen eines Batches nicht eindeutig einem Prozessparameter zugeordnet werden. Somit konnten die Qualitätsschwankungen im Produktionsprozess nicht verringert werden.

Um hier eine effiziente Lösung für die Problematik zu finden, wurden mit KI die Einflussfaktoren auf die Produktion analysiert. Dazu kategorisierten Experten der Westphalia DataLab GmbH zuerst die Teile anhand ihrer Qualität (0: ausreichende Qualität, 1: gute Qualität). Anhand der zeit-

basierten Sensordaten wurden über 20 verschiedene Eigenschaften bestimmt, die die Zeitreihe charakterisieren. Gleichzeitig wurden die Zeitreiheneigenschaften um Informationen über Maschinentyp, Betreiber der Maschine und Qualitätsprüfer erweitert. Die Abhängigkeiten zwischen den Eigenschaften und der Qualität wurden mithilfe von Machine-Learning auf den Teilen mit bekannter Qualität gelernt. Die daraus entstehenden baumbasierten Modelle konnten für nicht getestete Teile eine Wahrscheinlichkeit für deren Qualität angeben und die Wichtigkeit der im Machine-Learning verwendeten Informationen bestimmen. Somit lassen sich auch in Zukunft problematische Parameter bzw. Prozessschritte identifizieren und Tests gezielter durchführen.

Die baumbasierten Machine-Learning-Modelle erreichten in diesem Fall eine Genauigkeit von 97 %. Für die Ingenieure wurde basierend auf diesen Ergebnissen eine Softwarelösung entwickelt, mit der sich die Einflüsse verschiedener Informationen interaktiv analysieren lassen. Sie können so einzelne Informationen oder Eigenschaftengruppen zum Trainieren der Modelle entfernen und somit überlagernde Effekte analysieren. Zudem wurden auf den komplexen Baummodellen einfache Baummodelle trainiert, um Abhängigkeiten in Diagrammen sichtbar zu machen. Zusammen mit weiteren statistischen Analysen ermöglichte die KI eine gezielte Fehlersuche und erlaubt so das Identifizieren von Teilen und Batches mit geringerer Qualität (Bild 2).

Potenziale können identifiziert werden

Vor allem die Identifizierung von produktwie auch prozessbezogenen Skalen-, Verbund- und Lerneffekten bietet große Potenziale für produzierende Unternehmen. Gegenüber klassischen QM-Methoden schneiden datengetriebene Methoden häufig in der Anfangsphase schlechter ab und leiden unter einem „Datenkaltstart“. Mit zunehmender Datengrundlage übersteigen die exponentiell wachsenden Skaleneffekte schnell die der klassischen QM-Methoden. Durch die Verknüpfung datengetriebener Services mit dem bestehenden Produktportfolio werden zunehmend Verbundeffekte erzielt (z. B. prädiktive Instandhaltung). ■