



# Datenbasierte Entscheidungsunterstützung

Wie Qualität durch die Nutzung geeigneter Analysemethoden optimiert wird

Der Aufwand, ein Unternehmen zu digitalisieren, eine passende vertikale sowie horizontale Infrastruktur aufzubauen und die erhobenen Daten in geeigneter Qualität zu Verfügung zu stellen, ist groß. Umso wichtiger ist es, das Potenzial der Informationsgenerierung vollumfänglich zu nutzen. In diesem Artikel wird beschrieben, wie Predictive Quality ziel führend eingesetzt wird und welche Vorteile im Vergleich zu herkömmlichen Methoden bestehen.

Nils Klasen, Louis Huebser, Julian Haller, Robert H. Schmitt

**M**it der zunehmenden Nutzung von Sensorik, der erweiterten Vernetzung von Akteuren entlang der gesamten Wertschöpfungskette und der Verbreitung von Onlineangeboten steigt die Datenverfügbarkeit rasant. Zudem werden Produkte und deren Herstellungsprozesse stetig komplexer. Im selben

Zuge steigt auch die Anzahl der Wechselwirkungen zwischen Prozessparametern, die eine Fehlererkennung und -rückverfolgung zunehmend erschweren. Um trotz der wandelnden Rahmenbedingung konkurrenzfähig zu bleiben, ist es für Unternehmen unabdingbar, die Potenziale der Digitalisierung und die damit verbundenen

Möglichkeiten der Datenanalyse auszu schöpfen.

Herkömmliche Analysemethoden oder auf Intuition und Erfahrungswerten basierende Handlungsentscheidungen stehen konträr zu diesem Zielbild. Daten aus der Produktion werden häufig nur stichprobenartig erhoben und mit langjährig bestehen-




Bild 1. Visualisierung der Prozessparameter. Quelle: WZL der RWTH Aachen © Hanser

den und im hochkomplexen Produktionsumfeld zunehmend ungeeigneten Methoden ausgewertet. Diese setzen überwiegend statistische Verteilungsmodelle voraus und lassen lediglich univariate Analysen zu, wodurch sich die Anwendung in den meisten Fällen auf einzelne Prozessschritte ohne deren Interaktionen beschränkt.

Da jene Wechselwirkungen in Anbetracht der steigenden Prozesskomplexität zunehmend an Bedeutung und Einfluss gewinnen, ist eine ganzheitliche Analyse der vorhandenen Datenquellen notwendig. Ein Ansatz hierfür ist die systematische Integration von *Predictive Quality* (*Qualitätsvorhersage*). Definiert ist dieser Begriff als „Die Befähigung des Anwenders zur Optimierung der prozess- und produktbezogenen Qualität durch die Nutzung datenbasierter Prognosen als Entscheidungsgrundlage für Handlungsmaßnahmen.“ (R. Schmitt et al.)

Methoden des *machine learning* (dt. maschinelles Lernen), die bei der technischen Implementierung von Predictive Quality zum Einsatz kommen, ermöglichen die

multivariate Analyse von Prozessparametern in Echtzeit. Es werden zuvor unbekannte Muster und Zusammenhänge aufgedeckt, die maßgeblich zur Handlungsunterstützung beitragen. Durch Predictive Quality werden präventive, statt reagierende Maßnahmen in Bezug auf die Produkt- und Prozessqualität ermöglicht.

**Woran es in Unternehmen häufig scheitert**

Trotz des offensichtlichen Potenzials der datenbasierten Prognose von Qualitätsmerkmalen, fällt es vielen Unternehmen weiterhin schwer, die dafür nötige Transformation voran zu treiben. Die Gründe hierfür sind vielfältig:

**Technische Herausforderungen**

Bestehende Insellösungen für einzelne Unternehmensbereiche, die nicht miteinander kommunizieren, geschweige denn Daten systemübergreifend zur Verfügung stellen, verhindern ganzheitliche Analysen. Die von einzelnen Anwendungen erhobenen Daten landen in Datensilos. Ein Lösungsrahmen

diese Datensilos aufzubrechen, ohne den Betriebsablauf zu unterbrechen, ist das *Internet of Production* (IoP). Es sieht den Einsatz einer Middleware vor, die Zugriff auf die einzelnen proprietären Systeme hat und somit die Daten unternehmensweit zugänglich macht. Neben der Datenakquise, -aufbereitung und -analyse, ist die Qualität der Rohdaten von zentraler Bedeutung. In vielen produzierenden Unternehmen steht bereits eine ausreichende Datenmenge zur Verfügung, diese kann jedoch aufgrund mangelnder Qualität nicht sinnvoll analysiert werden („garbage in, garbage out“).

**Unternehmenskultur und Organisationsstrukturen**

Oft fehlt es am Bewusstsein für die Bedeutung von Daten und deren Nutzung, befähigt durch Analysen für die Produktion der Zukunft. Für die Transformation von intuitiven Entscheidungen und deskriptiven Analysen hin zu datenbasierten, prädiktiven Unterstützungssystemen ist ein umfassendes Change Management erforderlich. Hierbei wächst mitunter die Bedeutung der Modernisierung und Digitalisierung des eigenen Wertschöpfungsnetzwerks und der Entwicklung digitaler Geschäftsmodelle.

Auch die gezielte Kompetenzentwicklung der Mitarbeitenden spielt eine entscheidende Rolle. Denn auch wenn bei der Implementierung von hochkomplexen Modellen des Maschinellen Lernens auf existierende Bibliotheken zurückgegriffen werden kann, ist für die Nutzung und Interpretation der Analyseergebnisse grundlegendes fachliches Verständnis notwendig.

**Anwendungsfall: Validierung der Qualitätsvorhersagen**

Nach diesem pragmatischen Blick auf die aktuellen Herausforderungen zur Nut- >>>


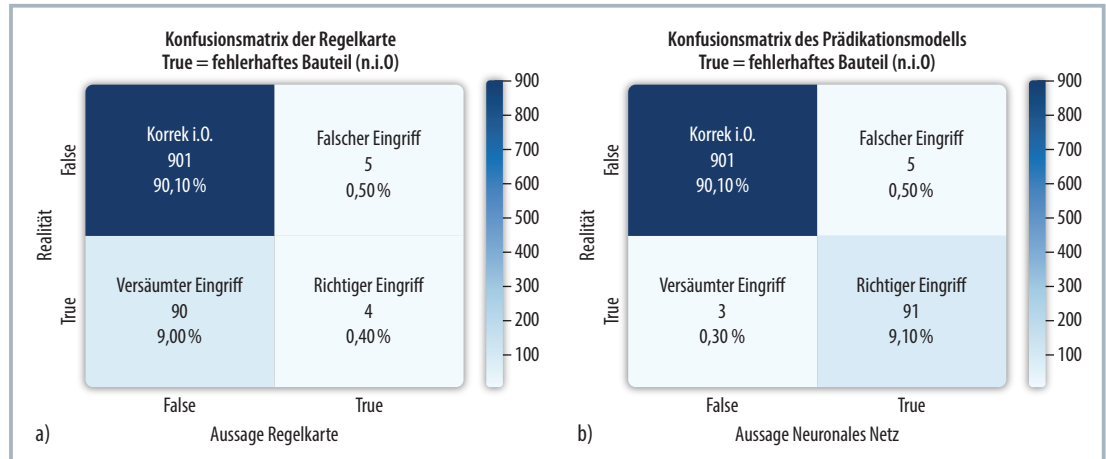


Bild 2. Wirkzusammenhänge zwischen den Prozessparametern.

Quelle: WZL der RWTH Aachen © Hanser

Bild 3. Konfusionsmatrizen der Bewertungsmodelle (a) Regelkarte (b) Predictive Quality. Quelle: WZL der RWTH Aachen © Hanser



zung von Predictive Quality wird nun die praktische Umsetzung beschrieben. Anhand eines Anwendungsbeispiels aus der Ge-

triebwellenproduktion wird dargestellt, wie Prozessdaten mittels einfach anzuwendender Methoden des Maschinellen Lernens gewinnbringend zur Qualitätsvorhersage genutzt werden können. Die Ergebnisse der Analyse werden mit den Ergebnissen konventioneller Prozessregelkarten verglichen. Der Fokus liegt bewusst auf der Anwendungsseite der Methoden, ausgehend von einem bereits aufbereiteten Datensatz. Zudem ist die Komplexität des betrachteten Anwendungsfalls stark eingeschränkt, um das Verständnis und die Nachvollziehbarkeit der Analysen zu erleichtern.

Der für die Analyse verwendete Datensatz umfasst bauteilbezogene Prozessparameter und Qualitätsmerkmale aus der Getriebewellenfertigung, reduziert auf die Prozessschritte Drehen und Bohren. Für den Prozessschritt des Drehens liegen Informationen über die durchschnittliche Schnittgeschwindigkeit sowie über den durchschnittlichen Wellendurchmesser nach der Bearbeitung vor. Die Messdaten zum Prozessschritt Bohren umfassen die durchschnittliche Drehzahl. Als Qualitätsmerkmal liegt die Kategorisierung in Gut- oder Schlechteile am Ende der Produktionskette vor. Die Datengrundlage wurde synthetisch, basierend auf einer realitätsnahen Simulation der physikalischen Zusammenhänge, erstellt. Der Datensatz umfasst 5411 Bauteile, 9,17 % davon sind Schlechteile.

Bevor die Analysepotenziale von Predictive Quality im Vergleich zu herkömmlichen univariaten Analysemethoden dargestellt werden, wird eine erste Visualisierung der bauteilabhängigen Prozessparameter und deren Qualitätsmerkmale durchgeführt (Bild 1). Es ist zu erkennen, dass die den

Schlechtteilen zugehörigen Messwerte bezogen auf die durchschnittliche Drehzahl beim Bohren und der durchschnittlichen Schnittgeschwindigkeit beim Drehen hohe Abweichungen vom Mittelwert in positive (Bohren) und negative (Drehen) Richtung aufweisen. Eine eindeutige Abgrenzung zwischen Gut- und Schlechteilen lässt sich jedoch in keinem der Fälle identifizieren.

Im Folgeschritt der Datensichtung werden die Prozessparameter gemeinschaftlich visualisiert. Der hierfür aufgespannte, dreidimensionale Raum (Bild 2) zeigt eine gut erkennbare Trennung der Parameter Räume von Gut- und Schlechteilen durch eine Hyperebene. Eine der Stärken bei der Anwendung von Predictive Quality-Methoden ist es, diese Hyperebene zu identifizieren, die die Auswirkung von gemeinschaftlich auftretenden Parameterausprägungen auf ein Merkmal abbildet.

### Analyse der Bauteilqualität mittels Prozessregelkarten

Um einen Vergleichswert für die Validierung der Predictive Quality-Anwendung zu schaffen, werden Prozessregelkarten erstellt, die in der industriellen Praxis als Standardtool zur statistischen Prozessanalyse gelten. Die für die Datensichtung erstellten Datenpunktwolken werden hierfür um ihre 3-Sigma Eingriffsgrenzen in Relation zum Mittelwert ergänzt. Eine optische Analyse zeigt, dass ein Großteil der als Schlechteil markierten Bauteile innerhalb der Eingriffsgrenzen liegt. Eine detaillierte Auswertung der übereinandergelegten Regelkarten anhand eines zufälligen Testdatensatzes von 1.000 Bauteilen zeigt 90 versäumte Eingriffe sowie 5 falsche Eingriffe. Es werden lediglich 4 der

## INFORMATION & SERVICE

### QUELLEN

- Schmitt R.H. et al.: Daten sind Gold wert. Warum Datenmanagement für Unternehmen zum Erfolgsfaktor wird. QZ 5/2022, Seiten 22-25
- Aggarwal, C.: Neural networks and deep learning. Springer Cham, 2018
- Ge, Z.; Song, Z.; Ding, Steven X.; Huang, B.: Data Mining and Analytics in the Process Industry: The Role of Machine Learning. IEEE, 2017
- Pfeifer, T.; Schmitt, R: Masing Handbuch Qualitätsmanagement. Hanser, 2021
- Iansiti, M; Lakhani, K. R.: Competing in the Age of AI. Harvard Business Review, 2020. <https://hbr.org/2020/01/competing-in-the-age-of-ai>
- Géron, A, Praxiseinstieg Machine Learning mit Scikit-Learn und TensorFlow. O'Reilly, 2017

### AUTOREN

**Nils Klases M. Sc.** ist wissenschaftlicher Mitarbeiter am Werkzeugmaschinenlabor (WZL) der RWTH Aachen

**Louis Huebner M. Sc.** ist wissenschaftlicher Mitarbeiter am Werkzeugmaschinenlabor (WZL) der RWTH Aachen.

**Julian Haller M. Sc.** ist wissenschaftlicher Mitarbeiter am Werkzeugmaschinenlabor (WZL) der RWTH Aachen.

**Prof. Dr.-Ing. Robert H. Schmitt** ist Direktor am WZL der RWTH Aachen sowie Mitglied des Direktoriums am Fraunhofer-Institut für Produktionstechnologie (IPT).

### KONTAKT

Nils Klases  
T 0151 72921985  
n.klases@wzl.rwth-aachen.de

94 Schlechteile im Testdatensatz richtig klassifiziert (Bild 3a).

### Analyse der Bauteilqualität mittels Predictive Quality

Im Folgenden wird ein Modell des Maschinellen Lernens erstellt. Besonders zur Analyse komplexer Prozesszusammenhänge mit hoher Anzahl an Einflüssen kommen dabei Neuronale Netze zum Einsatz, deren Stärke hier zu verorten ist. Ein Neuronales Netz besteht aus einer anwendungsabhängigen Vielzahl künstlicher Neuronen, die nichtlineare Transferfunktionen enthalten. Transferfunktionen sind Funktionen, die eine Eingangsgröße in eine gewünschte Ausgangsgröße umrechnen. Durch die Verschachtelung der Transferfunktionen innerhalb des Neuronalen Netzes können Zusammenhänge funktional abgebildet werden. Dies wird dadurch begünstigt, dass jeder Neuroneneingang mit einem Gewichtungsfaktor multipliziert, sowie mit einem Schwellenwert addiert wird (Netzparameter). Um die Wirkzusammenhänge zwischen verschiedenen Prozessparametern zu erlernen und darauf basierend Aussagen über die dazugehörigen Qualitätsmerkmale zu treffen, wird das Netz anhand historischer Daten trainiert. Hierbei werden Prognosen, die auf anfänglich zufällig initialisierten Netzparametern basieren, mit den dazugehörigen Realwerten verglichen. Durch die iterative Anpassung der

Netzparameter (Backpropagation) wird die Fehlerfunktion zwischen Prognose und Realität solange minimiert, bis das Netz die funktionalen Zusammenhänge ausreichend abbildet.

Da es sich bei der Unterscheidung zwischen Gut- und Schlechteil um ein binäres Klassifikationsproblem handelt, wird ein *MLP Classifier* verwendet, aufgebaut aus einem neuronalen Netz mit zwei verdeckten Schichten bestehend aus 12 bzw. 6 Neuronen. Schichten- sowie Neuronenanzahl werden erfahrungsbasiert initialisiert und optional durch eine Hyperparameteroptimierung angepasst.

Angewandt auf denselben Testdatensatz, der bei der Regelkarte zum Einsatz gekommen ist, zeigt das neuronale Netz eine bessere Kategorisierungsgüte. Lediglich 3 Schlechteile werden nicht identifiziert, 5 Bauteile werden fälschlicher Weise als Schlechteile kategorisiert. 91 der 94 Schlechteile werden richtig erkannt (Bild 3b).

Ein Vergleich der beiden Konfusionsmatrizen (Prozessregelkarte vs. Prädiktionsmodell) zeigt die Überlegenheit von Ansätzen des Predictive Quality im Vergleich zu herkömmlichen Methoden innerhalb des aufgezeigten Use-Case.

**Fazit:** Um die Überlegenheit des Predictive Quality Ansatzes zu verdeutlichen, werden die Auswirkungen der beiden Analyseergebnisse im Rahmen der Qualitätssicherung verglichen. Von großem Interesse ist hierbei

die Anzahl der fälschlicherweise als Schlechteil kategorisierten Bauteile (-Fehler) und der fälschlicher Weise als Gutteil kategorisierten Fehler (-Fehler). Unter der Annahme, dass fehlerhaft kategorisierte Bauteile nicht weiter geprüft oder nachgearbeitet werden, führt ersteres zu Ausschuss, letzteres zur Retoure und zum anschließendem Ausschuss. Neben den zusätzlichen Retourenkosten impliziert jedes fehlerhaft ausgelieferte Teil monetär nicht zu bewertende Auswirkungen auf die Zufriedenheit der Kund\*innen. Diese Kosten sind bei der Qualitätsvorhersage durch Predictive Quality mit 3 fehlerhaft ausgelieferten Bauteilen im Vergleich zu den 90 nicht identifizierten Schlechteilen durch die Regelkarten um 96 % geringer.

**Ausblick:** Die vorangestellten Ergebnisse zeigen, dass die Integration von Predictive Quality zur Qualitätssicherung bei stetig steigender Prozesskomplexität langfristig alternativlos ist. Die Möglichkeit zur ganzheitlichen Analyse der vorhandenen Datengrundlage sowie die Fähigkeit, komplexe Wirkzusammenhänge zwischen einzelnen Prozessparametern und deren Auswirkungen auf die Produktqualität zu analysieren, zeigt die signifikanten Vorteile zu herkömmlichen Methoden.

Wie sich die dargestellten Potenziale umsetzen lassen, stellen wir in einem weiteren Beitrag zu den unternehmerischen Aspekten einer erfolgreichen Integration von Predictive Quality vor. ■

## Qualität spricht für sich!

Überzeugen Sie Ihre Kunden mit Ihren Produkten und Dienstleistungen nachhaltig – mit bester Qualität. Ein strategisch aufgestelltes Qualitätsmanagement unterstützt Sie dabei. Nutzen Sie diesen wirkungsvollen Hebel für Ihren Erfolg!

**Jetzt weiterbilden!**  
[taw.de/qualitaetsmanagement](http://taw.de/qualitaetsmanagement)