



# Predictive Quality in der Produktion

## Wie die operative Integration von Predictive Quality in der Produktion gelingt

Datenbasierte Ansätze zur Entscheidungsunterstützung werden zunehmend anwendungsorientierter und zugänglicher. Über neuartige Analysekonzepte und -verfahren lassen sich große Datenmengen bezogen auf einzelne Prozesse oder entlang der Wertschöpfungskette analysieren, um wichtige Erkenntnisse über das Produkt oder den Prozess abzuleiten und diese zu optimieren. Damit die entwickelten Ansätze allerdings ihr volles Potenzial entfalten können, müssen diese erfolgreich in die Produktion und das unternehmerische Handeln integriert werden.

Daniel Buschmann, Louis Huebser, Tobias Schulze, Robert H. Schmitt

Die rasanten Entwicklungen in den Bereichen Big Data und künstlicher Intelligenz (KI) der vergangenen Jahre hat auch in produzierenden Unternehmen große Erwartungen geweckt. Heutige Ansätze versprechen ein enormes Potenzial, die umfangreichen prozess- und qualitätsbezogenen Daten der Produktion zielgerichtet auszuwerten und zur Steige-

rung der prozess- und produktbezogenen Qualität zu nutzen. In einer Vielzahl an industriellen Pilotprojekten konnte dies bereits branchenübergreifend unter Beweis gestellt werden.

Trotz des Fortschritts gibt es aber nach wie vor Hindernisse und Herausforderungen bei der operativen Einführung von datenbasierten Methoden in Unternehmen.

Die Ursachen hierfür erweisen sich dabei als vielfältig. Neben den klassischen Herausforderungen bei der Datenanalyse, beispielsweise bei der Modellbildung (sowohl bezogen auf Vorhersagegenauigkeit als auch bezüglich geforderter Berechnungslaufzeit und Speicherplatzanforderungen) hängt die erfolgreiche unternehmerische Implementierung im maßgeblichen Um-



fang von weiteren Faktoren der prozessualen und organisationalen Integration ab. Die Faktoren können dabei auf verschiedenen Ebenen verortet werden (Bild 1)

### Integration auf prozessualer Fertigungsebene

Zur lückenlosen Überwachung von Fertigungs- und Montageprozessen ist eine durchgehende und qualitativ abgesicherte Datenaufnahme von immanenter Bedeutung für die Richtigkeit der Modellaussagen. Produktionsprozesse müssen demnach mit entsprechender Sensorik oder manueller Dateneingaben ausgestattet, sowie deren Log- und Eventsignale der Maschinenebene mitgeschrieben werden. Unter Umständen ist eine Anpassung der Produktionsprozesse notwendig, um eine korrekte Datenerfassung zu ermöglichen (z.B. zusätzlicher Prozessschritt zur Bauteilvermessung oder Nutzung eines standardisierten Eingabeinterfaces).

Eine grundlegende Digitalisierung auf Unternehmensebene sowie Kompetenzen bezüglich Datenverwaltung sind hierbei

unerlässlich. Ferner müssen Mitarbeiter, die in der Datenerfassung eingebunden sind, geschult werden, um Verzerrungen während der automatisierten Datenaufnahme oder Unstimmigkeiten bei der manuellen Dateneingabe zu vermeiden. Solche Unstimmigkeiten entstehen unter anderem bei einer fehlenden Operationalisierung der manuellen Dateneingabe, beispielsweise ob Aufträge für ungeplante Maschinenreparaturen zu Beginn oder nach Beendigung in das IT-System übertragen werden. Die Absicherung der erforderlichen Datenqualität beginnt somit bereits auf dem Shop Floor.

### Integration auf Ebene des Datenmanagements

Auf der Ebene des Datenmanagements müssen Aspekte bezüglich der technischen Infrastruktur, der Datenstrukturlogik sowie der Datenverfügbarkeit betrachtet werden. Hinsichtlich der technischen Infrastruktur können Unternehmen entweder ihre Daten lokal und selbstständig verwalten oder externe Cloud-Lösungen in Anspruch nehmen. Entscheidungsfaktoren diesbezüglich fallen vielfältig aus und müssen individuell betrachtet werden (z.B. Unternehmensgröße, -kompetenzprofil und -strategie).

In Bezug auf die Datenstrukturlogik können Daten als unstrukturierte Rohdaten in sogenannten „Data Lakes“ oder in aufbereiteter Form in „Data Warehouses“ gespeichert und verwaltet werden. Eine Wahl für eine Speichertechnologie muss individuell getroffen werden, obgleich eine Kombination ebenso möglich ist. Entsprechende Architekturen für Datenvorverarbeitungsalgorithmen werden maßgeblich von dieser Entscheidung mitbeeinflusst.

Neben der Strukturiertheit hinsichtlich der Speichertechnologie, müssen Unternehmen frühzeitig eine grundlegende Datenontologie festlegen, sprich eine Vereinheitlichung der Datenrelationen, -benennungen und -mindestanforderungen, um Inkompatibilitäten zwischen Datensätzen zu vermeiden beziehungsweise ganzheitliche und unternehmensweite Analyse zu ermöglichen. Schlussendlich müssen Aspekte der abteilungsübergreifenden Datenverfügbarkeit sowie der allgemeinen Datensicherheit betrachtet werden, um einen schnellen und sicheren Datenzugriff zu er-

#### Fernstudium Six Sigma Green Belt

Kostengünstig und staatl. geprüft. Beginn jederzeit!

FERNSCHULE WEBER  
Tel. 0 44 87 / 263 - Abt. 168

[www.fernschule-weber.de](http://www.fernschule-weber.de)

#### INFORMATION & SERVICE

##### QUELLEN

- Singh, J.; Cupreet, S.; Singh Bhati, B.: The Implication of Data Lake in Enterprises: A Deeper Analysis, IEEE, 2022
- Quiñero-Candela, J.; Sugiyama, M.; Schwaighofer, A.; Lawrence, N. D.: Dataset Shift in Machine Learning, MIT Press, 2009
- Frazzetto, D.; Dyhre Nielsen, T.; Bach Pedersen, T.; Šikšnyš, L.: Prescriptive analytics: a survey of emerging trends and technologies, The VLDB Journal, 2019
- Davenport, T. H.: The AI advantage. How to put the artificial intelligence revolution to work, MIT Press, 2019
- Iansiti, M.; Lakhani, K. R.: Competing in the Age of AI, Harvard Business Review, 2020. Online verfügbar unter

##### AUTOREN

**Daniel Buschmann M. Sc.** Arbeitet als Gruppenleiter und wissenschaftlicher Mitarbeiter am Werkzeugmaschinenlabor (WZL) der RWTH Aachen

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

**Tobias Schulze M. Sc.** Arbeitet als 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)

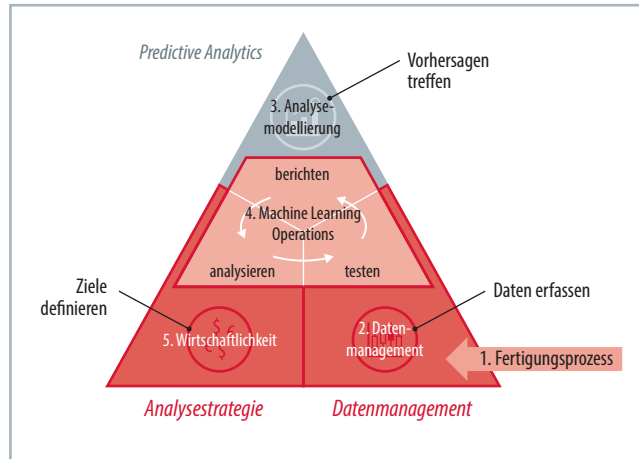
##### KONTAKT

Daniel Buschmann  
[d.buschmann@wzl.rwth-aachen.de](mailto:d.buschmann@wzl.rwth-aachen.de)



Bild 1. Verortung von prozessuellen und organisationalen Einflussfaktoren bei der Integration von Predictive Quality-Modellen.

Quelle: RWTH Aachen © Hanser



möglichen und somit eine datengetriebene Arbeitsweise zu fördern. Eine ausführliche Betrachtung dieser Faktoren wurde in „Daten sind Gold Wert“ (QZ 05/2022) veröffentlicht.

### Integration der Analysemodelle

Predictive Quality-Modelle bedürfen in der Regel gesonderter Datenaufbereitungsalgorithmen (z.B. Standardisierung der Eingabewerte auf den Wertebereich  $[0, 1]$ , Entfernen von Rauschsignalen etc.). Demzufolge ist eine Orchestrierung der Datenabfrage auf Datenmanagementebene und der Vorschaltung von Datenaufbereitungsalgorithmen sowie der eigentlichen Predictive Quality-Modelle und der Ergebnisausgabe notwendig.

Nach dem Training des Modells muss dieses zunächst in die Produktivumgebung integriert werden. Verschiedene Optionen reichen hier von der Integration in die Maschinensteuerung bis hin zur Implementierung in einer App für separate Dienstleistungen. Entscheidungen diesbezüglich müssen für jedes Predictive Quality-Modell individuell, basierend auf der vorhandenen IT-Landschaft und dem Anwendungsfall des Modells, getroffen werden. So müssen beispielsweise Modelle zeitkritischer Anwendungen, wie einer Maschinenregelung nah am eigentlichen Prozess integriert werden.

Weiterhin muss die Ergebnisausgabe an den jeweiligen Anwendungsfall angepasst und auf die entsprechende Nutzergruppe zugeschnitten werden. So benötigt ein Prozessingenieur zumeist andere Informationen als ein Mitarbeitender auf dem Shop Floor. Da das Verständnis der Predictive Quality-Modelle oftmals spezifische

Kenntnisse benötigt, sind trotz zugeschnittener Ausgaben entsprechende Schulungen zum Kompetenzaufbau und zur Systemeinführung notwendig.

### Integration von ML Ops

Machine Learning (ML) Ops sind für die operative Umsetzung und kontinuierliche Ausführung von Predictive Quality-Modellen verantwortlich. In der Regel ändern sich Produktionsdaten graduell über die Zeit, womit darauf aufbauende Analysemodelle an Aussagekraft verlieren können. Durch ein kontinuierliches Sammeln neuer Trainingsdaten aus dem laufenden Produktionsprozess und regelmäßiges, erneutes Training bzw. Anlernen der Modelle, kann ein Degradieren der Aussagekraft verhindert oder zumindest vermindert werden.

Das erneute Anlernen kann kontinuierlich erfolgen (Online Training) oder nach einem festgelegten Zeitplan (Offline Training). Ferner ist es vorteilhaft, parallel zum laufenden Produktionsprozess und dem

sich im Einsatz befindlichen Analysemodell, weitere Modelle basierend auf alternativen Algorithmenarchitekturen als Schattenmodelle laufen zu lassen. Je nach Algorithmus sind hierfür Anpassungen in der Datenvorverarbeitung erforderlich. Sobald eines der Schattenmodelle eine höhere Performance aufweist als das sich im Einsatz befindliche Modell (bspw. in Bezug auf die Vorhersagegenauigkeit), kann dieses entsprechend ausgetauscht werden (Bild 2).

Grundlage für dieses Vorgehen sind:

- eine saubere und akkurate Softwareversionierung,
- eine ausreichend performante Infrastruktur zum Training bzw. Anlernen der Algorithmen (lokal oder als externe Dienstleistung) sowie
- eine datengetriebene und experimentieroffene Unternehmenskultur.

### Wirtschaftlichkeit und organisationale Verankerung der Integration

Vor der Projektierung eines Predictive Quality-Ansatzes ist eine sinnvolle und ergebnisorientierte Selektion eines passenden Anwendungsfalls notwendig. Anwendungsfälle können nach ihrem jeweiligen Ziel unterschieden werden.

Explorative Anwendungen (Descriptive Analytics) nutzen in der Regel Cluster-Algorithmen, die eigenständig Zusammenhänge aus den vorliegenden Daten extrahieren, welche darauf von Prozessexperten interpretiert werden müssen.

Dagegen verwenden Anwendungen, deren Ziel die Exploitation ist, in der Regel Klassifikations- und Regressionsalgorithmen. Solche Algorithmen können entwe-

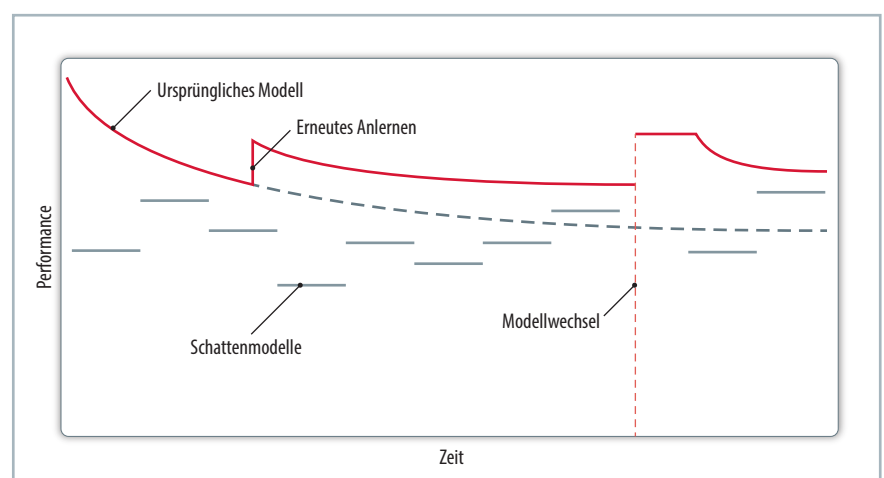


Bild 2. Einfluss von erneutem Anlernen und der Berücksichtigung von Schattenmodellen auf die Performance. Quelle: RWTH Aachen © Hanser

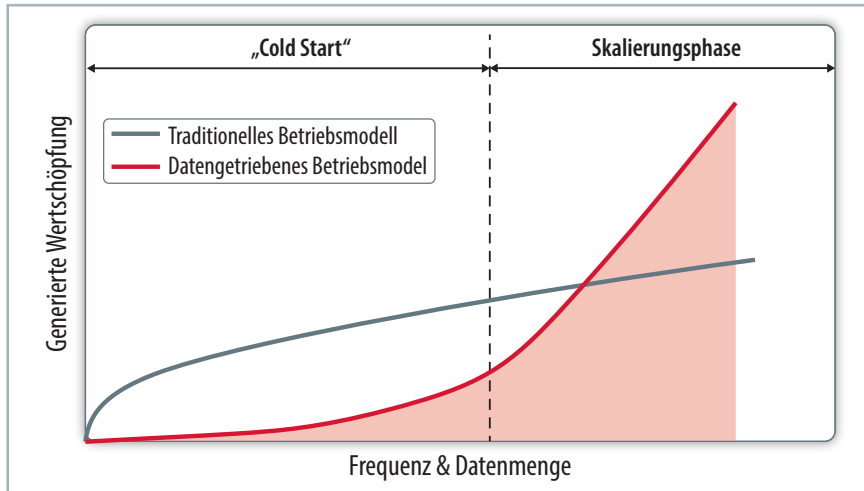


Bild 3. Einfluss der Datenmenge auf traditionelle und datengetriebene Betriebsmodelle.

Quelle: RWTH Aachen © Hanser

der präventiv (Predictive Analytics) zur Fehler- und Anomalieerkennung, oder optimierend (Prescriptive Analytics) zur Suche besserer Fertigungsparameter eingesetzt werden.

Ferner muss bei der Selektion eines Anwendungsfalls a-priori der *Interaktionsgrad* festgesetzt werden. Dies bezieht sich zum einen auf die Einbindung von Expertenwissen und Interventionsmöglichkeiten durch Mitarbeitende („Human in the Loop“), als auch auf die Adaptivität des Systems im Hinblick auf andere Anwendungsfälle. Dies können beispielsweise weitere Fertigungslinien, Prozesse oder Standorte sein. Davon abhängig bestimmt sich auch der Grad der

Automatisierung zwischen Assistenz- und vollautomatisierten Systemen, die entsprechende Geschäfts- und Prozessevents autonom auslösen.

Hinsichtlich der monetären Wirtschaftlichkeit leiden Predictive Quality-Modelle häufig unter dem Phänomen des „Cold Start“ (Bild 3). Predictive Quality-Modelle weisen zu Beginn auf Grund der noch kleinen Datenbasis eine niedrigere Aussagekraft auf, welche sich aber mit zunehmender Datenmenge sukzessiv verbessert und klassische Qualitätsmanagementverfahren schnell überholt (Skaleneffekte).

Auf Grund der vorausgesetzten Datenbasis und der notwendigen Infrastruktur

für Predictive Quality-Modelle, ergeben sich für Unternehmen zusätzliche Möglichkeiten, auf den aufgebauten Kompetenzen weitere datengetriebene Geschäftsmodelle, besonders in Richtung *Servitization*, zu etablieren (Verbundeffekte). So können beispielsweise im B2B-Geschäft Fertigungsdaten als Dienstleistung zusammen mit dem Produkt verkauft werden, um Wareneingangsprüfungen beim Kunden zu ersetzen. Während traditionelle Betriebsmodelle nur im geringen Umfang von erhöhten Datenmengen profitieren, erreichen datengetriebene Geschäftsmodelle hier ein exponentielles Wachstum (Bild 3).

**Fazit:** Die aufgeführten Faktoren zur Integration von Predictive Quality zeigen, dass die erfolgreiche Einführung nicht nur ein Thema der Datenanalyse ist, sondern vielmehr einer ganzheitlichen Betrachtung bedarf. Unternehmen stehen demnach vor der Entscheidung, welche der notwendigen Kompetenzen in-house entwickelt oder extern zugekauft werden sollen. Dies beginnt bei der sauberen Erfassung der Prozessdaten auf dem Shop Floor und reicht bis zur Operationalisierung eines Lebenszyklus für Predictive Quality-Modelle.

Zusätzlich müssen Unternehmensstrategien eine stärkere Orchestrierung von (Digitalisierungs- und Analyse-) Kompetenzen, Dienstleistern und Geschäftsmodellen im digitalen Bereich fokussieren, um wettbewerbsfähig zu bleiben. ■

## Bücher um Unternehmen neu zu denken

HANSER



ISBN 978-3-446-47248-8 | € 39,99



ISBN 978-3-446-47311-9 | € 39,99



ISBN 978-3-446-47158-0 | € 39,99