

3.2 Predictive Quality – Data Analytics in produzierenden Unternehmen

R. H. Schmitt, R. Kurzhals, M. Ellerich, G. Nilgen, P. Schlegel, E. Dietrich, J. Krauß, A. Latz, J. Gregori, N. Miller

Gliederung

1	Einleitung	228
2	Predictive Quality	229
2.1	Data Analytics in produzierenden Unternehmen	229
2.2	Bedeutung für die Qualität: Predictive Quality	230
2.3	Potenziale von Predictive Quality	232
3	Produktbezogene Anwendungsbeispiele	233
3.1	Digital Diagnosis Assistance für Kundendiensttechniker	234
3.2	Predictive Maintenance – Dynamisierung von Kalibrierintervallen	237
4	Prozessbezogene Anwendungsbeispiele	240
4.1	Ausschussprognosen in Produktionsketten	240
4.2	Datengetriebene Dynamisierung von Stichproben	242
4.3	Price Tagging – Kostenprognosen für Meilensteine	245
5	Voraussetzungen für die Realisierung	247
6	Herausforderungen bei der Umsetzung	249
6.1	Technische Herausforderungen	249
6.2	Unternehmenskulturelle und betriebswirtschaftliche Herausforderungen	249
7	Zusammenfassung und Ausblick	250

Kurzfassung

Predictive Quality – Data Analytics in produzierenden Unternehmen

Zunehmende Produktkomplexität und -vielfalt, komplexere Herstellungsprozesse und steigende Nachhaltigkeitsforderungen stellen zentrale Herausforderungen für die kontinuierliche Verbesserung der prozess- und produktbezogenen Qualität dar. Predictive Quality beschreibt in diesem Zusammenhang die Befähigung des Anwenders zur Optimierung der produkt- und prozessbezogenen Qualität durch die Nutzung datengetriebener Prognosen als Entscheidungsgrundlage für Handlungsmaßnahmen. Indem der Anwender in die Lage versetzt wird, zukünftige qualitätsbeeinflussende Ereignisse in seinem Sinne zu steuern, lassen sich in der Praxis vielfältige Potenziale realisieren. Im Rahmen des vorliegenden Beitrags wird anhand von fünf Anwendungsbeispielen aus unterschiedlichen Branchen und Domänen exemplarisch gezeigt, wie sich durch die Anwendung prädiktiver Data Analytics Methoden konkrete Mehrwerte für produzierende Unternehmen schaffen lassen.

Abstract

Predictive Quality - Data Analytics in manufacturing enterprises

Increasing product complexity and variety, more complex manufacturing processes and rising sustainability requirements are major challenges for the continuous improvement of process- and product-related quality. In this context, predictive quality describes the empowerment of the user to optimize product and process-related quality by using data-driven predictions as a basis for decision-making and action. By enabling the user to control future quality-influencing events in his or her interest, a wide range of potentials can be realized in practice. In this paper, five use cases from different industries and domains are presented to show how the application of predictive data analytics methods can create actual added value for manufacturing companies.

1 Einleitung

Um im Wettbewerb produzierender Unternehmen auf globalen Märkten dauerhaft eine Vorreiterrolle einzunehmen, ist die größtmögliche Realisierung von Potenzialen der Digitalisierung unabdingbar. Über eine starke Hebelwirkung zur kontinuierlichen *Verbesserung der produkt- und prozessbezogenen Qualität* verfügt die konsequente Nutzung des Wissens, welches in den exponentiell ansteigenden Datenmengen steckt. Gleichzeitig kann so durch eine qualitätsgetriebene Optimierung des Ressourceneinsatzes den stetig zunehmenden Nachhaltigkeitsforderungen aus Bevölkerung und Politik begegnet werden. Der rasante *Anstieg an Datenverfügbarkeit* liegt zum einen an einer immer stärkeren Vernetzung von Lieferanten, Produzenten und Kunden, zum anderen an der Nutzung einer steigenden Anzahl unterschiedlicher Informationskanäle von integrierter Sensorik bis zu online Produktreviews.

Um die für das Unternehmen, die Prozesse und die Produkte richtigen Entscheidungen zu treffen, gilt es im Rahmen entsprechender Datenanalysen die für den Anwendungsfall relevanten Prognosen zu treffen. Hierbei liegen die größten Herausforderungen neben der kontextspezifischen Datenauswahl und Aufbereitung vor allem in der *Datenintegration* im Sinne einer lückenlosen Verknüpfung verschiedener Datenpunkte und dem Referenzieren auf individuelle Entitäten wie z. B. das physische Produkt. Um diesen Herausforderungen zu begegnen und die Potenziale zu heben, forcieren eine Vielzahl an Unternehmen die Anwendung systematisierter *Data Analytics* Ansätze.

Dabei beschreibt *Predictive Quality* (dt. prädiktive Qualität) die Befähigung des Anwenders zu einer datengetriebenen Vorhersage der produkt- und prozessbezogenen Qualität in der Herstellung und Nutzung physischer Produkte. Predictive Quality verfolgt so das übergeordnete Ziel, den Anwender in die Lage zu versetzen *auf Basis prädiktiver Analysen präskriptiv zu handeln* und so zukünftige qualitätsbeeinflussende Ereignisse in seinem Sinne zu steuern. Inwiefern der zunehmende Einsatz von Data Analytics in der Qualität bestehende Prinzipien und Methoden ergänzt oder sogar ersetzt ist bisher nur unzureichend geklärt. Der vorliegende Beitrag geht dieser Fragestellung nach und stellt Lösungsansätze für die erfolgreiche Realisierung von Predictive Quality vor. Auf Basis einer Untersuchung der vielfältigen *Potenziale* von Predictive Quality wird die Realisierung dieser durch *konkrete Anwendungsbeispiele* aus unterschiedlichen Branchen exemplarisch vorgestellt. In diesem Zusammenhang werden neben den Potenzialen auch Risiken und Einschränkungen bei der Implementierung beleuchtet. Aufbauend darauf werden die zugrundeliegenden *Voraussetzungen* für eine erfolgreiche Umsetzung von Predictive Quality abgeleitet und die größten *Herausforderungen* bei der Umsetzung herausgearbeitet.

Der Beitrag ist wie folgt strukturiert: Im Rahmen von Kapitel 2 wird der Begriff Predictive Quality definiert und durch die Untersuchung der Potenziale motiviert. Eine Darstellung von Anwendungsbeispielen mit Fokus auf der Steigerung der produktbezogenen Qualität erfolgt in Kapitel 3. Dagegen werden in Kapitel 4 Anwendungsbeispiele prädiktiver Data Analytics Methoden mit Fokus auf der prozessbezogenen Qualität thematisiert. Die beschriebenen Anwendungsbeispiele entstammen unterschiedlichen Branchen und werden in verschiedenen Phasen des Produktlebenszyklus verortet. Hierdurch wird sowohl die branchenübergreifende Relevanz als auch die breite Anwendbarkeit der entwickelten Methoden verdeutlicht.

Ausgehend von den vorgestellten Anwendungsbeispielen werden in Kapitel 5 konkrete Voraussetzungen für eine erfolgreiche Umsetzung von Predictive Quality Ansätzen abgeleitet. Hierbei liegt der Fokus sowohl auf der Datenbasis selbst als auch auf dem Men-

schen als Nutzer und Wissensträger. Anschließend werden in Kapitel 6 die größten technischen sowie unternehmenskulturellen und betriebswirtschaftlichen Herausforderungen bei der Umsetzung diskutiert. Kapitel 7 fasst die Ergebnisse zusammen und gibt einen Ausblick auf weitere Entwicklungen.

2 Predictive Quality

2.1 Data Analytics in produzierenden Unternehmen

Um das Verständnis von Produkten und Prozessen zu verbessern und Entscheidungen zu unterstützen, sollen relevante Informationen aus Rohdaten extrahiert und Wissen abgeleitet werden [1, 2]. Um diese Entscheidungen im Unternehmen auf Basis des in den Daten enthaltenen Wissens zu treffen, ist Data Analytics als Werkzeug zur Untersuchung von großen Datenmengen von fundamentaler Bedeutung. Data Analytics beschreibt dabei den Prozess der *Datenuntersuchung*, des *Datenverständnisses* und des *Erkenntnisgewinns*. Das Ziel von Data Analytics ist die Identifizierung von unbekanntem Mustern und Zusammenhängen zwischen verschiedenen Variablen durch die Analyse von Rohdaten [3].

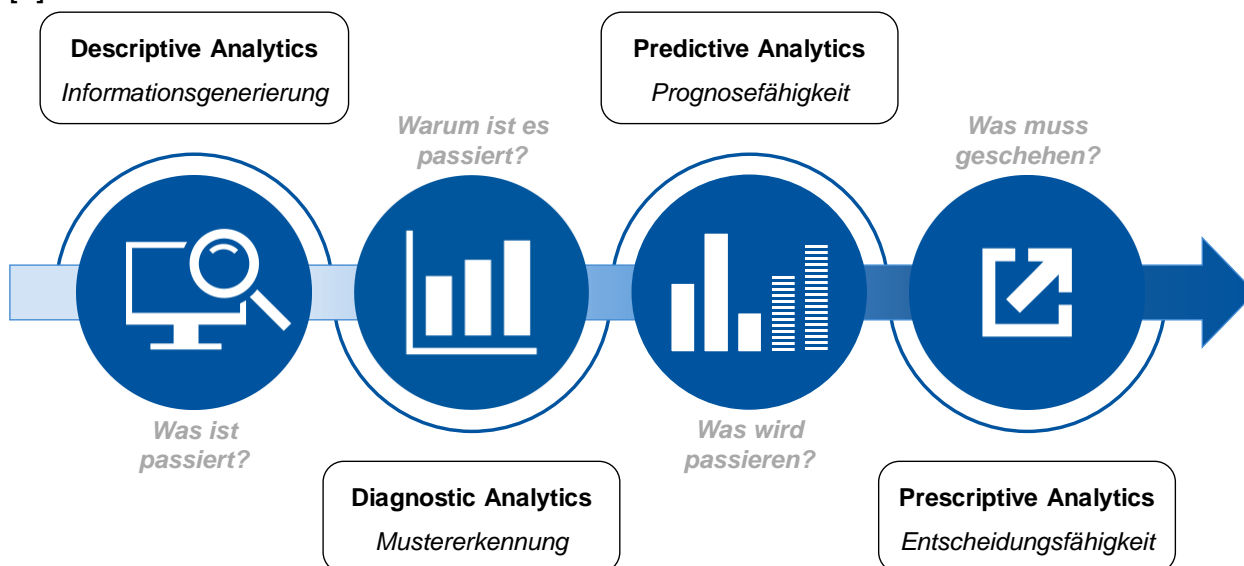


Bild 1: Data Analytics in produzierenden Unternehmen

Bei der Umsetzung dieser Entscheidungsunterstützung in Form von lernenden Assistenzsystemen erfolgt die Datenauswahl und -aufbereitung sehr anwendungsspezifisch. Auch der Umfang und die Komplexität der eingesetzten Verfahren der Datenanalyse hängen stark von verschiedenen Faktoren wie z.B. Einsatzzweck, Expertise und verfügbaren Ressourcen ab. Entsprechend vielfältig ist die Menge an potenziellen Verfahren, welche sich von statistischen Methoden bis hin zu komplexen Machine Learning-Modellen erstrecken (ML-Modelle). Prinzipiell unterscheidet man zwischen vier unterschiedlichen, teilweise aufeinander aufbauenden Stufen der Datenanalyse: *Descriptive Analytics*, *Diagnostic Analytics*, *Predictive Analytics* und *Prescriptive Analytics* [4]. Die einzelnen Stufen sind in Bild 1 dargestellt [5].

Descriptive Analytics beschreibt die Interpretation historischer Daten mit dem Ziel, ein besseres Verständnis eines in der Vergangenheit liegenden Prozesses aufzubauen. Das generierte Wissen lässt sich beispielsweise zur Erstellung und Auswertung von Kenn-

zahlen nutzen. *Diagnostic Analytics* hat zum Ziel, auf Basis historischer Daten Wirkbeziehungen zwischen bestimmten Ereignissen zu ermitteln. Kennzeichnend ist analog zu *Descriptive Analytics* ein rückwärts gerichteter Blick, mit dem Unterschied, dass eine Ursachenfindung angestrebt wird. Während sich die beiden ersten Data Analytics Stufen auf einen nicht mehr beeinflussbaren Zeitpunkt und damit ausschließlich auf historische Vorkommnisse beziehen, liegt der Fokus von *Predictive Analytics* nun auf der Betrachtung von zukünftig mit einer bestimmten Wahrscheinlichkeit eintretenden Ereignissen. Auf Basis des gewonnenen Wissens werden nun zukünftige Ereignisse oder Zustände prognostiziert. *Prescriptive Analytics* ermöglicht es dann, aufbauend auf den Erkenntnissen der Prognosemodelle, automatisiert Entscheidungen und Maßnahmen abzuleiten. Jede Stufe der Datenanalyse zielt letztendlich darauf ab den Anwender zu präskriptivem Handeln und damit zu einer zielgerichteten Beeinflussung von Prozessen zu befähigen. Die Unterscheidung liegt im Wissensgehalt, mit dem die Informationen dem Anwender zur Verfügung gestellt werden.

Die Einsatzmöglichkeiten und Potenziale von Data Analytics sind im Sinne einer datenbasierten Entscheidungsfindung in produzierenden Unternehmen so enorm wie vielfältig (vgl. Kapitel 2.3), wobei der Grad der tatsächlichen Umsetzung stark von der jeweiligen Unternehmensgröße und Industriebranche abhängt [6]. So sind laut einer Studie des McKinsey Global Institute (MGI) in der industriellen Fertigung nur etwa 20 bis 30 Prozent des Potenzials in der Anwendung von Data Analytics Methoden ausgeschöpft [7]. Zu den Anwendungen gehören beispielsweise der Einsatz von Data Analytics in der Produktionsplanung zur Steigerung der Termintreue und Lieferfähigkeit oder der Einsatz in der Auftragsabwicklung zur softwaretechnischen Unterstützung der Angebotserstellung und Beschaffung durch Analyse und Prognose relevanter Daten [6, 8]. Predictive Maintenance ist ein weiteres prominentes Anwendungsbeispiel, durch dessen Einsatz beispielsweise das Unternehmen Trumpf verbesserte Prozesstransparenz, Produktivitätssteigerung und optimierte Serviceeinsätze erzielen konnte [9].

Die erfolgreiche Umsetzung von Data Analytics Methoden in produzierenden Unternehmen geht jedoch weit über die reine Algorithmik hinaus. Neben der eigentlichen Datenauswertung muss für die erfolgreiche Akquise, Vorverarbeitung und Analyse im Unternehmen auch eine entsprechende *Infrastruktur* geschaffen werden. Des Weiteren müssen geeignete Schnittstellen geschaffen werden, um das gewonnene Wissen dem Menschen als Entscheidungsunterstützung zugänglich zu machen. Eine solche Infrastruktur bietet das *Internet of Production* (IoP). Dieses beschreibt über die Definition von Aggregationsebenen die Veredelung von Rohdaten hin zu aufbereitetem Wissen, welches für den Menschen unmittelbar nutzbar ist [10]. Auch für eine erfolgreiche Umsetzung von Data Analytics in der Qualität und dem damit verbundenen Einsatz datengetriebener prädiktiver Methoden bietet das IoP die notwendige IT-Infrastruktur.

2.2 Bedeutung für die Qualität: Predictive Quality

Die Qualität eines Produktes hängt maßgeblich vom Zusammenspiel der einzelnen Produktionsschritte und dem Zustand der jeweilig verwendeten Komponenten ab. Aufgrund steigender Komplexität in den Produktionsabläufen steigt die Anzahl der immanenten Wechselwirkungen einzelner Prozesse an. Darüber hinaus führt die steigende Individualisierung der Produkte zu einer deutlichen Erhöhung der Prozessvarianz. Ein datengetriebener prädiktiver Ansatz ermöglicht durch den Blick in die Zukunft eine genauere Betrachtung der qualitätsrelevanten Faktoren. Anstatt einer reinen Beurteilung anhand der Prozessdaten können auch vorhandene Informationen über Zwischenerzeugnisse und die individuelle Baugruppe berücksichtigt werden. Predictive Quality erweitert den Fokus

der Datenanalyse darüber hinaus, sodass neben der Herstellung auch die Produktnutzung als weitere Datenquelle und Anwendungsfeld mit in den Betrachtungsrahmen aufgenommen wird. Der Einsatz von Data Analytics in der Qualität ermöglicht so neben der Optimierung von Prozessen in Herstellung und Nutzung auch die Verbesserung des Grads mit welchem das Produkt die Kundenanforderungen erfüllt. [11, 12]

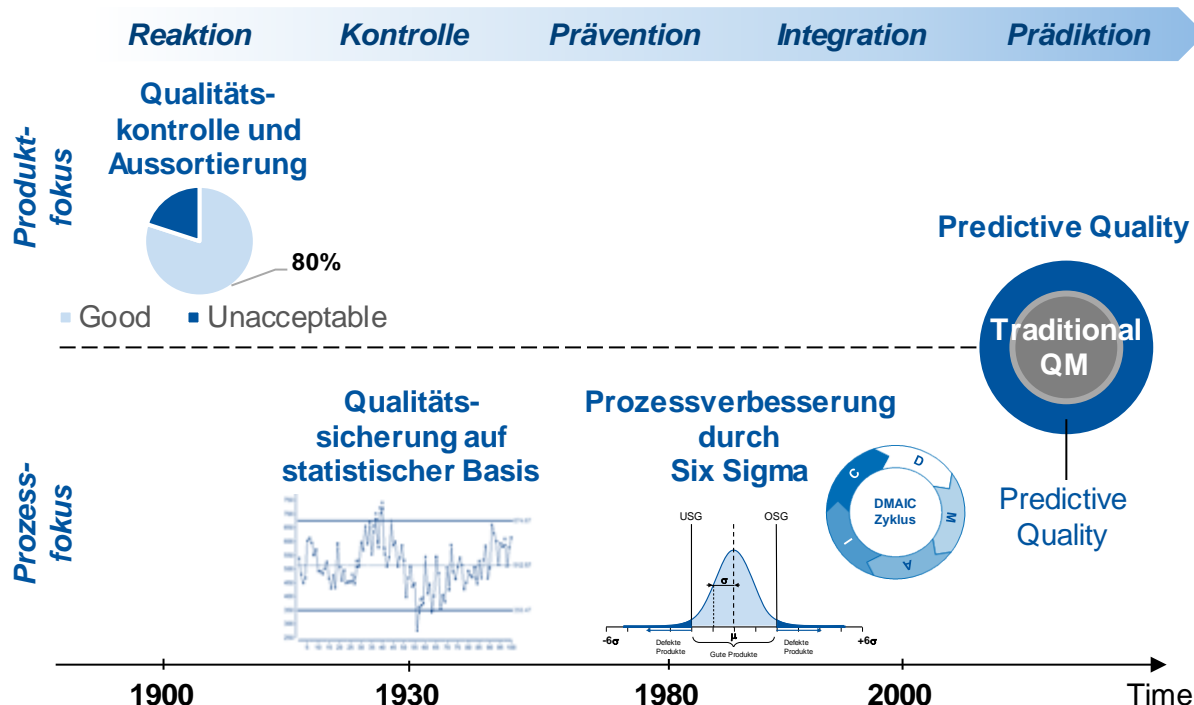


Bild 2: Evolution der Qualität in produzierenden Unternehmen

Mit dem in Bild 2 dargestellten Schwerpunktwechsel von reaktiv hin zu prädiktiv, beginnt eine neue Entwicklungs-Ära in der Qualität, in welcher aktuell ein erneuter Paradigmenwechsel vollzogen wird. Dieser Paradigmenwechsel ist dabei nicht als eine Ablösung zu verstehen, sondern vielmehr als eine Ergänzung zu bestehenden Methoden. Mit der effektiven Nutzung der heutzutage vorhandenen Daten und speziell der zunehmenden Verfügbarkeit von fertigungs- und nutzungsspezifischen Informationen zu jedem produzierten Produkt, rückt der *Produktfokus* wieder stärker in den Mittelpunkt. Zentrale Voraussetzung ist in diesem Zusammenhang die Nachverfolgbarkeit einzelner Produkte in den Daten von der Produktion bis zum Kunden, sodass die Datenpunkte sinnvoll miteinander verknüpft und analysiert werden können.

Predictive Quality befähigt somit den Anwender zu einer datengetriebenen Vorhersage der prozess- und der produktbezogenen Qualität. Übergeordnetes Ziel ist dabei die *Optimierung von produkt- und prozessbezogener Qualität* durch die Nutzung der Vorhersage als Entscheidungsgrundlage für Maßnahmen. Dies schließt sowohl die Ableitung von Handlungsmaßnahmen durch den Anwender selbst als auch die präskriptive Bereitstellung von Handlungsempfehlungen durch ein lernendes Assistenzsystem ein. Die beiden Zielgrößen sind dabei interdependent, so ist eine hohe Prozessqualität eine notwendige, aber nicht hinreichende Bedingung für eine hohe Produktqualität. Der Wert von Predictive Quality liegt also nicht in den Daten selbst, sondern in den Erkenntnissen, da diese unmittelbar in die Entscheidung miteinfließen.

Von zentraler Bedeutung ist hierbei der angestrebte *Prognosehorizont*, mit dessen zunehmender Länge die Reaktionsmöglichkeiten zwar zunehmen, gleichzeitig jedoch die

Prognosegüte stark abnimmt. Die genaue Positionierung innerhalb dieses Spannungsfelds hängt stark vom jeweiligen Anwendungsfall ab, prinzipiell ist jedoch ein Vorhersagezeitpunkt mit möglichst hoher Prognosegüte anzustreben, an dem mittels geeigneter Korrekturmaßnahmen noch reagiert werden kann.

Analog zum Umsetzungsgrad von Data Analytics in anderen Unternehmensteilen werden auch im Rahmen der Qualität bisher nur vereinzelte Lösungen aktiv genutzt [13]. Für Predictive Quality sind exemplarisch einige Anwendungsbeispiele zu nennen. So ermöglicht z. B. eine systematische Verwertung von Online-Kundenfeedback Daten, das eigene Produktverständnis zu verbessern und akute Qualitätsprobleme schneller zu ermitteln als dies über herkömmliche Reklamations- und Feedbackschleifen erfolgen kann. Darüber hinaus können die gesammelten Informationen als Indikator für die Kundenmeinung genutzt werden, um zukünftige Ziele zu formulieren [14]. Die Nutzung von Qualitätsdaten in Form von systematischen Vorhersagen auf Basis von Messwerten aus Qualitätssensoren und vor allem von funktionsübergreifenden Daten dient als Basis für präventive Qualitätsmaßnahmen sowie einer Deduktion von optimalen Parametern [11]. Durch die Verwendung historischer Festigkeits- und Zuverlässigkeitsdaten lassen sich sowohl Testpläne kontrollieren und dynamisch anpassen als auch zukünftige Leistungs- und Garantiekosten vorhersagen.

Mit Blick auf das *Aachener Qualitätsmanagementmodell* wird deutlich, dass ein Großteil der Aktivitäten innerhalb des Qualitätsmanagements einen datenorientierten Charakter aufweisen [15]. Nahezu alle Entscheidungsprozesse im Qualitätsmanagement beruhen auf einer umfangreichen Datenerhebung und -analyse. Predictive Quality ist somit keinesfalls als eine Ablösung zu verstehen, sondern vielmehr als eine *Ergänzung* zu herkömmlichen Methoden.

2.3 Potenziale von Predictive Quality

Die Optimierung von produkt- und prozessbezogener Qualität lässt sich in der Praxis durch die *Realisierung von Potenzialen* in den vielfältigen Anwendungsszenarien erreichen. Durch die Befähigung des Anwenders zu einer datengetriebenen Vorhersage der Qualität können diese Prognosen als Entscheidungsgrundlage für Maßnahmen genutzt werden. Um Problemstellungen in der Praxis mithilfe eines solchen Ansatzes zu begegnen, sind einige zentrale Fragen im Vorfeld zu adressieren:

- Welches Wissen (und damit welche Daten) ist relevant für die zu treffende Entscheidung?
- Wie muss das Wissen für die Entscheidung aufbereitet werden?
- Welche Prognosegüte wird benötigt, um basierend darauf die Entscheidung zu treffen?

Im Falle von zeitkritischen Anwendungen werden die angeführten Punkte noch erweitert um die Fragestellung inwieweit das Wissen mit ausreichendem Vorlauf extrahiert werden muss (vgl. Abbildung Spannungsfeld Prognosehorizont).

Konkret liegen die Potenziale des Ansatzes vor allem in den *Mehrwerten*, die sich beim Adressieren aktueller Problemstellungen gegenüber dem Einsatz klassischer Qualitätsmethoden ergeben. Eine Quantifizierung der Mehrwerte ist häufig komplex und sehr kontextspezifisch. Mögliche Vorgehensweisen hierfür werden exemplarisch in Anwendungsbeispielen in den Kapiteln 3 und 4 vorgestellt. Unabhängig von konkreten Einzelanwendungen wurden im Dialog mit produzierenden Unternehmen sowohl produkt- als auch prozessbezogene übergeordnete Potenziale identifiziert.

Durch den immer stärker werdenden Verbund informatischer, softwaretechnischer Komponenten mit mechanischen und elektronischen Teilen kommt es zu einer zunehmenden Produktkomplexität und -vielfalt. Predictive Quality verfügt über das Potenzial eine *hohe Produktverfügbarkeit* trotz steigender Komplexität beim Kunden sicherzustellen. So kann der Kunde bspw. durch Condition Monitoring oder prädiktive Wartung (Predictive Maintenance) vor negativen Erfahrungen mit dem Produkt geschützt werden. Hieraus lassen sich wiederum Wettbewerbsvorteile generieren und höhere Preise rechtfertigen. Predictive Quality wird so langfristig zum Enabler für neue Geschäftsmodelle wie die Subskription, indem anstatt für das Produkt selbst für dessen Verfügbarkeit bezahlt wird.

Eng verknüpft mit der steigenden Produktkomplexität und -vielfalt ist die *zunehmende Komplexität der Herstellungsprozesse*. Hinsichtlich der prozessbezogenen Qualität liegen die Potenziale von Predictive Quality somit hauptsächlich in einer besseren Beherrschung komplexer Prozesse sowie der Einsparung von Unternehmensressourcen. Letzteres betrifft u. a. die Reduzierung von Qualitätskosten verursacht durch Renommeeverluste, interne und externe Nacharbeit sowie Qualitätsprüfungen. Durch die Bereitstellung der relevanten Informationen birgt Predictive Quality hier auch das Potenzial, die Mitarbeiterinnen und Mitarbeiter in Bezug auf qualitätsgetriebene Kostenverursachung zu sensibilisieren.

Darüber hinaus sehen sich produzierende Unternehmen mit *zunehmend konkreteren Nachhaltigkeitsforderungen* aus Bevölkerung und Politik konfrontiert. Auch hier bietet Predictive Quality Potenziale zur Steigerung der unternehmerischen Nachhaltigkeit. So können z. B. Produkte ressourcensparender gestaltet, Ausschuss verringert und eine allgemeine Reduktion der aufgewendeten Ressourcen aufgrund von besser beherrschbaren Prozessen erzielt werden.

In den nachfolgenden Kapiteln 3 und 4 werden exemplarisch Ansätze vorgestellt wie die beschriebenen Potenziale realisiert werden können.

3 Produktbezogene Anwendungsbeispiele

Ziel der im Folgenden vorgestellten Anwendungsbeispiele ist das Treffen präskriptiver Entscheidungen zur *Verbesserung der Produktqualität und -verfügbarkeit* auf Basis datengetriebener Vorhersagen über das Produktverhalten. Beide Anwendungsbeispiele lassen sich in der Nutzungsphase verorten (vgl. Bild 3). Während mit der Erhöhung der Produktverfügbarkeit bei gleichzeitiger Kostenreduktion die Zielgrößen der beiden Ansätze einen hohen Überdeckungsgrad aufweisen, unterscheiden sich sowohl die konkrete Vorgehensweise zur Zielerreichung als auch der Implementierungsfortschritt voneinander. Weitere Unterschiede liegen in den Anforderungen der Lösungsansätze an die Echtzeitverfügbarkeit der Vorhersagen sowie im Prognosehorizont.

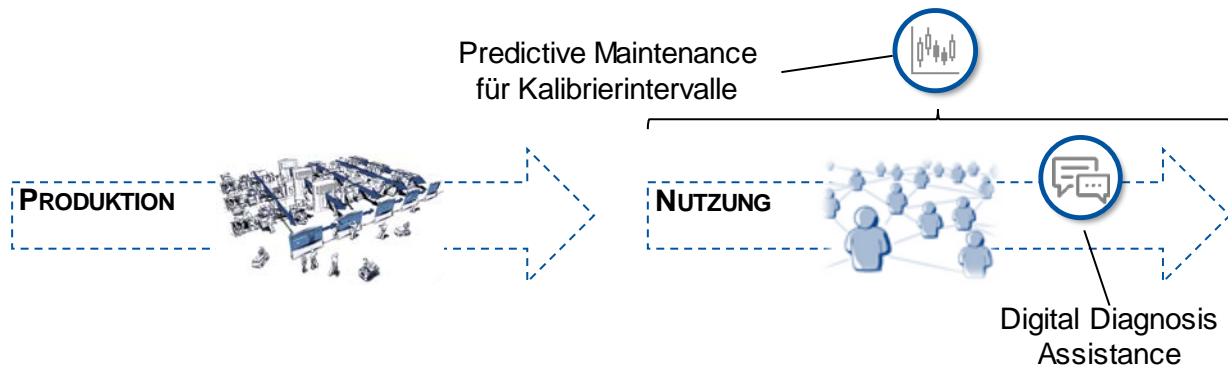


Bild 3: Verortung der produktbezogenen Anwendungsbeispiele

Das erste der beiden Anwendungsbeispiele entstand in Zusammenarbeit mit dem Unternehmen Miele & Cie. KG, einer der führenden Hersteller von Haushalts- und Gewerbegeräten. Hierin wird die Befähigung des Kundendiensttechnikers zu einer schnellen, datenbasierten Fehlerbehebung vor Ort beim Kunden durch ein *Digital Diagnosis Assistance* System beschrieben. In Kooperation mit der IconPro GmbH, einem Softwareentwickler und Digitalisierungs-Enabler für produzierende Unternehmen, entstand das zweite Anwendungsbeispiel. Darin wird der Aufbau einer *Predictive Maintenance Plattform* zur datenbasierten Prognose der Kalibrierintervalle von Koordinatenmessgeräten und einer entsprechenden Dynamisierung der Kalibrierung beschrieben.

3.1 Digital Diagnosis Assistance für Kundendiensttechniker

Ausgangssituation, Zielstellung und Potenziale

Die Miele & Cie. KG ist ein weltweit führender Anbieter von Premium-Hausgeräten und -Elektrogeräten für den gewerblichen Einsatz. Mit über 20.000 Mitarbeitern erwirtschaftete er im letzten Geschäftsjahr 2018/2019 einen Umsatz von 4,16 Mrd. Euro. Für den Fall, dass Wartungen für die Geräte im Feld anfallen, stellt Miele ein umfangreiches Netz an Kundendiensttechnikern (KD-Techniker) bereit, die in entsprechenden Fällen Fehler beheben und Reparaturen durchführen. Üblicherweise gestaltet sich der Service-Einsatz beim Kunden wie folgt:

1. Verbale Fehlerbeschreibung durch den Kunden entgegennehmen (ggf. Abgleich mit Auftragsdaten des Kundendienst-Centers, bei dem der Kunde vorher anrief)
2. Überprüfung der Anwendungs- und Einbausituation des Gerätes, Ablesen des Gerätedisplays mit Fehlercodeangabe
3. Verbindung des Gerätes mit Kundendienst-Laptops, Auslesen von Fehlerspeicher und Sensordaten
4. Diagnose des Problems unter Berücksichtigung des Techniker-spezifischen Wissens und seiner Erfahrung

Dieser Prozess bietet die Gefahr der Fehldiagnose, wodurch falsche oder zu viele Komponenten getauscht werden oder ein weiterer Kundendiensteinsatz vor Ort erforderlich wird.

Mit dem Einsatz eines datengetriebenen, kontinuierlich lernenden Assistenzsystems (Digital Diagnosis Assistent, DDA) soll die Wahrscheinlichkeit eines Fehltausches verringert und damit auch unabhängig vom Erfahrungswissen des KD-Technikers die Erst-Erledigungsquote bei den Einsätzen erhöht werden. Der DDA wird dazu mit historischen Daten

von Service-Einsätzen trainiert und kann so vom Kundendiensttechniker genutzt werden, um bei Reparaturenentscheidungen unterstützt zu werden.

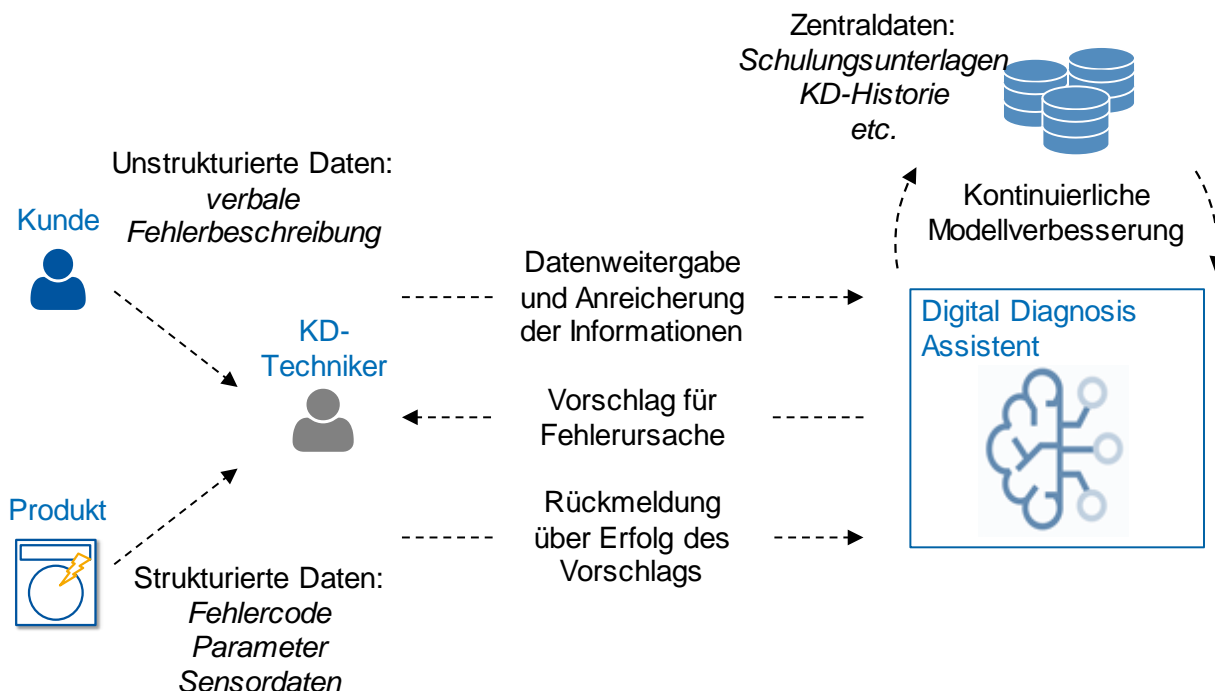


Bild 4: Konzept des DDA der Miele & Cie. KG (Quelle: Miele)

Wie in Bild 4 dargestellt bekommt der Kundendiensttechniker als Diagnoseergebnis eine Vorschlagsliste darüber, welcher Komponententausch mit welcher quantitativen Wahrscheinlichkeit („Prädiktion“) das Problem behebt. Die Prädiktionsqualität des Systems wird laufend verbessert, indem der Kundendienst-Techniker unmittelbar nach Komponententausch den Erfolg oder Misserfolg des Vorschlags bei der Fehlerbehebung dem DDA direkt rückmeldet.

Vorgehen und erzielte Mehrwerte

Von zentraler Bedeutung für den Erfolg des DDA ist die Auswahl einer qualitativ wie quantitativ ausreichenden Datenbasis, die für das Training eines entsprechenden Modells genutzt werden kann. Im konkreten Fall liegen sowohl strukturierte als auch unstrukturierte Daten vor. Diese Daten lassen sich unterteilen in solche, die vor Ort während des Einsatzes aufgenommen werden und solche, die unabhängig vom Einsatz zentral vorliegen. Beispiele hierfür sind:

Vor-Ort-Daten/Einsatz-Daten:

- Verbale Fehlermeldung (z.T. dokumentiert durch Servicecenter bei Auftragsannahme), unstrukturiert
- Beobachtungen d. KD-Technikers (v.a. zu Umgebung und Einbau des Gerätes), unstrukturiert
- Fehlercode, strukturiert
- Angaben aus Fehlerspeicher und Sensordaten, strukturiert
- Rückmeldung des KD-Technikers über Erfolg des Vorschlags, strukturiert

Zentraldaten (Datenbankpflege):

- Angaben aus KD-Berichten vergangener Einsätze, auch anderer Kollegen, teilw. strukturiert
- Montagehinweise, Schulungs- und Expertenwissen, teilw. strukturiert

Diese Daten laufen in der Kundendienst-Zentrale zusammen, werden dort konsolidiert und für die Verbesserung der DDA-Lösung kontinuierlich genutzt.

Die DDA-Lösung wurde in Form eines Proof of Concepts realisiert, das in Form eines Feldexperimentes mit 80 Kundendiensttechnikern unterschiedlichen Alters und Erfahrung, verteilt über ganz Deutschland, durchgeführt wurde. Produktseitig wurden zu Beginn Daten von zwei Pilotgeräten genutzt und diese über mehrere Monate mit weiteren Daten angereichert. Die eine Hälfte der Techniker nutzte die DDA-Lösung, wohingegen die andere Hälfte entlang des klassischen Prozesses agierte.

Als KPI für den Vergleich der beiden Gruppen wurde primär die Effizienz, also die Zielgenauigkeit der Assistenz- bzw. der Technikerprognose herangezogen. Diese Zielgenauigkeit bewertet den Erfolg der Problembehebung infolge von KD-Einsätzen. Das Ergebnis ist in Bild 5 dargestellt, in welcher der inverse Wert, also nicht erfolgreiche Kundendienstesätze infolge von Prognoseungenauigkeiten durch Techniker bzw. Assistenzsystem, über die Monate des Vergleichs aufgetragen sind. Am letzten Balkentupel für den Durchschnitt zeigt sich, dass sich die Zielgenauigkeit der Prognose bei der Gruppe „mit DDA“ im Vergleich zu den Technikern ohne DDA-Lösung um knapp die Hälfte (47%) verbessert hat (dunkelblaue Säulen). Eine anhand von Aufzeichnungen durchgeführte Nachbetrachtung der DDA-Prognosen an sich, also der reinen Systemempfehlung, zeigte, dass bei 100%iger Beachtung sogar eine Steigerung der Zielgenauigkeit der Prognose bis zu 85% möglich gewesen wäre (gelbe Säulen).

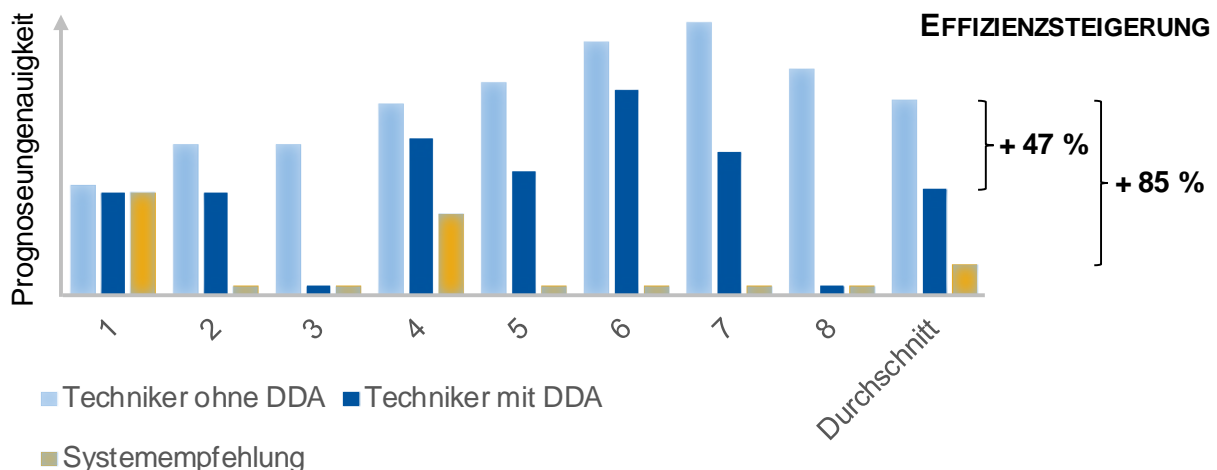


Bild 5: Vergleich der Prognoseungenauigkeit der unterschiedlichen Gruppen (Quelle: Miele)

Trotzdem ist es für die Akzeptanz durch die KD-Techniker und damit den Erfolg des DDA wichtig, den Assistenz- und Vorschlagscharakter des Systems zu betonen. Miele wird auch in Zukunft weder auf die Erfahrung der Techniker noch deren persönlichen Kontakt mit dem Kunden verzichten.

Nächste Schritte

Die Ergebnisse zeigen, dass sich durch den Einsatz des DDA neben der Effizienz auch die Quote der Ersterledigungsfahrten, also der Anteil, den die Anzahl Ersterledigungsfahrten an der Anzahl aller Kundendienstfahrten einnimmt, noch einmal steigern lässt („noch einmal“, weil sich diese Quote bereits vorher schon auf einem im Branchenvergleich hohen Niveau befand). Mittelbar verringert sich durch den Einsatz einer solchen datengetriebenen Lösung der Carbon Footprint der Kundendienstflotte und leistet damit einen wichtigen Beitrag zur Nachhaltigkeitsstrategie von Miele. In den nächsten Schritten wird Miele daher das erfolgreiche Proof of Concept auf weitere Produkte und Unternehmensbereiche übertragen, um eine Breitenwirkung der Mehrwerte zu erzielen.

Basierend auf diesem Szenario ist zukünftig eine weitere Stufe der Prädiktion denkbar, die eine Fehlervermeidung statt der Fehlerbehebung unterstützt. In einer Welt der vernetzten Hausgeräte ist hierzu ein kontinuierlicher Datenstrom zwischen Endgerät und DDA notwendig, wobei dazu die erforderlichen datenschutzrechtlichen Rahmenbedingungen gegeben sein müssen und gleichzeitig das Einverständnis des jeweiligen Endkunden zu einer solchen Datennutzung vorliegen muss. In einem solchen Szenario könnte dann der DDA nach Auswertung und Interpretation der Daten Empfehlungen für einen Komponententausch oder ein Softwareupdate aussprechen, bevor das Hausgerät in Störung geht. Diese Empfehlung wird dann in der Kundendienstzentrale in ein konkretes Auftragsangebot für den Kunden zum präventiven Tausch oder das Aufspielen eines Softwareupdates umgewandelt. Mit diesem Ansatz ließen sich sogar neue Geschäftsmodelle entwickeln.

3.2 Predictive Maintenance – Dynamisierung von Kalibrierintervallen

Ausgangssituation, Zielstellung und Potenziale

Insbesondere industrielle Messprozesse sind für qualitativ hochwertige Produkte von großer Relevanz. Für jeden Anwendungsfall muss nachgewiesen werden, dass die jeweiligen Messprozesse geeignet sind. Dies ist in der Regel eine temporäre Untersuchung, die nichts über die Messbeständigkeit (Stabilität) des Messprozesses über einen längeren Zeitraum aussagt. So werden Koordinaten-Messgeräte (KMG) in der Regel ohne Rücksicht auf deren Nutzungsgrad einmal jährlich gewartet und neu kalibriert. Durch das Trainieren eines entsprechenden lernenden prädiktiven Modells mit historischen Daten, kann neues Wissen über das Verhalten des Messgerätes gewonnen werden und so die Wartungs- bzw. Kalibrierintervalle dynamisiert werden:

- So kann es erforderlich sein, dass bei einer hohen Auslastung oder aufgrund von Abnutzungen oder Beschädigungen das Gerät früher als im jährlichen Rhythmus gewartet und kalibriert werden muss. Dies erhöht zwar die Kosten, die aber den Ausfallzeiten und den damit verbundenen Unannehmlichkeiten (z.B. Stillstandzeiten, falsch gemessene Teile usw.) gegenzurechnen sind.
- Andererseits werden die Geräte zu oft gewartet und neu kalibriert, obwohl dies nicht erforderlich wäre, so dass sich Wartungs- und Kalibrierkosten einsparen lassen.

Um den in Bild 6 kostenoptimalen Bereich zu erreichen, muss das Verhalten von Messprozessen mit geeigneten Verfahren beobachtet werden. Anschließend soll auf Basis historischer Daten ein prädiktives ML-Modell (Machine Learning) zur Erkennung von frühen Abweichungssignalen trainiert werden. Mit diesen Erkenntnissen können die Prüf- bzw. Kalibrierintervalle variabel gestaltet werden, ohne an Sicherheit bzgl. der Messbeständigkeit zu verlieren bzw. diese sogar noch zu erhöhen.

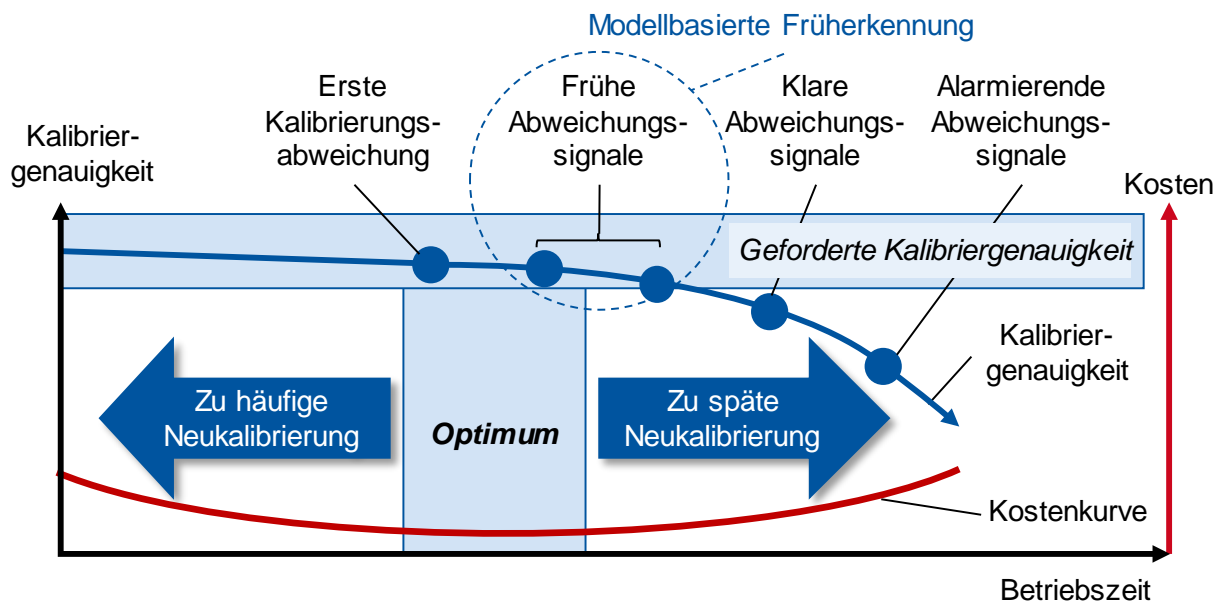


Bild 6: Predictive Maintenance für kostenoptimale Kalibrierung von KMGs (Quelle: IconPro)

Vorgehen und erzielte Mehrwerte

Die Anforderungen, Messbeständigkeit bzw. Messunsicherheit nachzuweisen, sind in mehreren Standards und Richtlinien als Vorgaben beschrieben. Deren Einhaltung wird in Audits überwacht:

- DIN EN ISO 10012 „Messmanagementsysteme – Anforderungen an Messprozesse und Messmittel“,
- der in der Automobilindustrie angewandten IATF 16949,
- Eignungsnachweisen wie der DIN EN ISO 14253 und der GUM („Guide to the Expression of Uncertainty in Measurement“), die sich mit der Bestimmung und Angabe von Unsicherheiten beim Messen auseinandersetzen.

Um die geforderte Eignung von Messprozessen nachzuweisen bzw. deren Messunsicherheit bestimmen zu können, werden dagegen folgende Normen und Richtlinien herangezogen:

- MSA Measurement System Analysis der AIAG (Automotive Industry Action Group)
- VDA5 Prüfprozesseignung
- DIN ISO 22514 – Statistische Verfahren im Prozessmanagement: Fähigkeit und Leistung – Teil 7: Fähigkeit von Messprozessen

Diese Standards und Richtlinien kommen allerdings nur temporär zum Tragen, um den prinzipiellen Nachweis des Messprozesses für den jeweiligen Einsatzfall zu erbringen. Aus diesem Grund sind zusätzliche Verfahren zur Überwachung der Messbeständigkeit bei Koordinaten-Messgeräten auszuwählen:

- Automatisierte Stabilitätsüberwachung mittels Normale
- Überwachung von internen Parametern
- Überwachung über externe Sensoren

Daraus lassen sich die unterschiedlichen Datenquellen, Datenflüsse sowie eine Architektur ableiten, welche in Bild 7 dargestellt ist. Die Mess- und Maschinendaten werden lokal aufgenommen und in regelmäßigen Abständen in eine Cloud-Architektur übertragen. Die Q-DAS Software solara.MP liefert auf Basis der Messdaten die aktuellen MSA/ VDA 5 Ergebnisse. Basierend auf einem anhand historischer Daten trainierten und mit den aktuellen Maschinendaten bzw. MSA/ VDA 5 Ergebnissen gefütterten ML-Modells lassen sich Vorhersagen zu Kalibrierzeitpunkten erstellen. Diese Vorhersagen werden in Form von Empfehlungen für das nächste Kalibrierdatum neben dem Status der Messsystemeignung dem Nutzer über ein Web Dashboard zur Verfügung gestellt. Dadurch werden Servicetermine besser planbar und die erforderlichen Ersatzteile können vorbereitet werden.

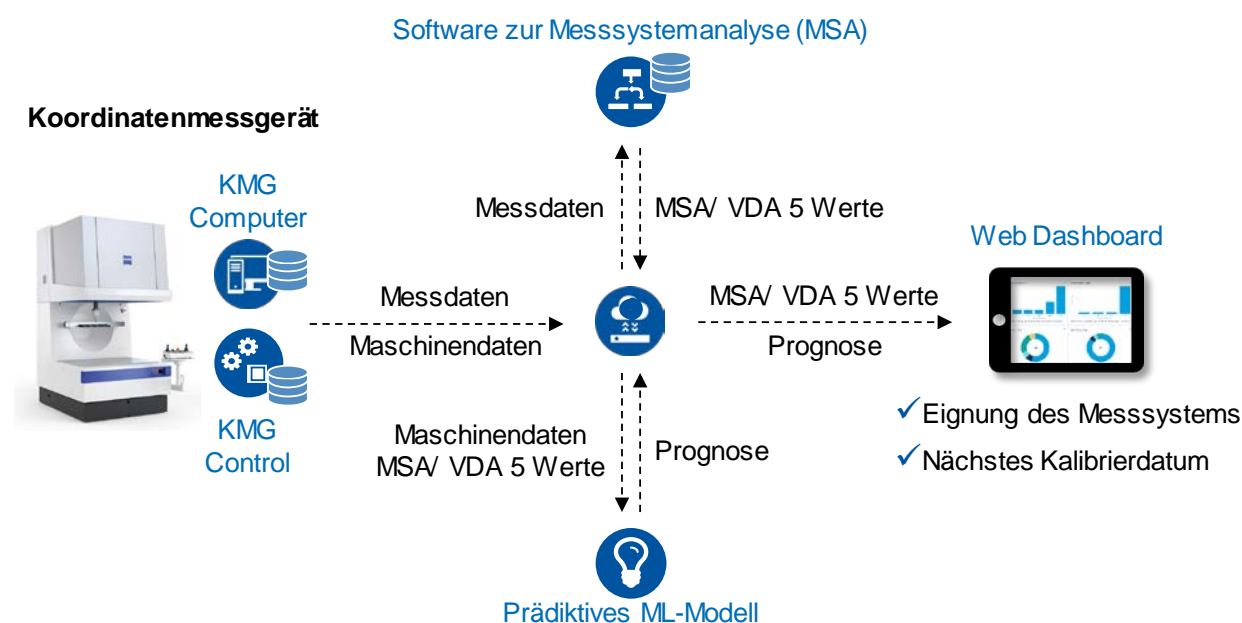


Bild 7: Infrastruktur und Datenflüsse bei der Dynamisierung von Kalibrierintervallen (Quelle: IconPro)

Nächste Schritte

Zunächst wurde die entsprechende Datenaufnahme an den KMGs verschiedener Anwendungspartner realisiert und eine automatisierte Datenübertragung zur zentralen Cloud-Plattform implementiert. Im nächsten Schritt werden im Rahmen von Software-Piloten sowohl die Bewertung und Visualisierung der Messsystemeignung als auch die ML-basierte Kalibrierprognose umgesetzt. Darüber hinaus soll eine eigene IconPro Cloud-Plattform zur Anwendung kommen, welche dann kundenindividuell zur Verfügung gestellt werden kann. Diese Plattform kann als public aber auch als private Cloud genutzt werden. Während dieser Pilotphase werden testweise interne Parameter miterfasst, um nach einem entsprechenden Lernprozess direkt aus diesen Daten die kontinuierliche Eignung nachweisen zu können. Da nicht herstellerübergreifend auf relevante Daten zugegriffen werden kann, empfiehlt es sich mittels externer Sensoren diese erforderlichen Informationen zu erfassen und signifikante Änderungen des Messprozesses zu signalisieren.

4 Prozessbezogene Anwendungsbeispiele

Präskriptive Entscheidungen auf Basis von datengetriebenen Vorhersagen über das *Prozessverhalten* zu treffen ist das übergeordnete Ziel der im Folgenden vorgestellten Anwendungsbeispiele. Ihrer prozessbezogenen Definition entsprechend lassen sich die Anwendungsbeispiele in der Phase der Produktherstellung bzw. der Auftragsabwicklung verorten (vgl. Bild 8). Analog zum vorangegangenen Kapitel unterscheiden sich die vorgestellten Lösungen sowohl in der Vorgehensweise zur Zielerreichung als auch im Implementierungsfortschritt stark voneinander. Weitere Unterschiede liegen in den Anforderungen der Lösungsansätze an die Echtzeitverfügbarkeit der Vorhersagen sowie im Prognosehorizont. Neben den genannten Unterschieden ähneln sich jedoch die Zielgrößen der individuellen Anwendungsbeispiele wie z. B. Ausschussminimierung und Steigerung der Prozessrobustheit sehr stark.

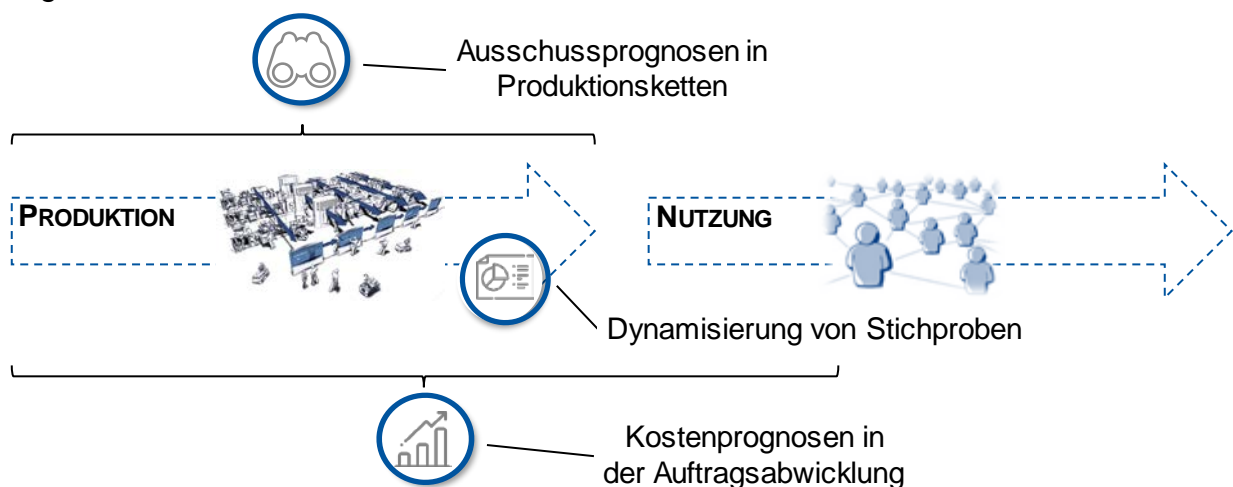


Bild 8: Verortung der prozessbezogenen Anwendungsbeispiele

Das erste der drei Anwendungsbeispiele entstand in Kooperation mit der Lumileds Germany GmbH, einer der führenden Hersteller von Automobilbeleuchtung und LED Komponenten. Die Zielstellung beschreibt primär die *Senkung der Ausschussrate* in der Produktion von Autolampen durch das Training und Deployment prädiktiver Grey-Box-Modelle zur Ermittlung optimaler Prozessparameter. Durch eine Kooperation der Unternehmen TCG Unitech GmbH, einem österreichischen Automobilzulieferer, und der Q-DAS GmbH, einem der führenden Anbieter von Statistik-Software und Dienstleistungen für die Qualitätssicherung in der industriellen Produktion, entstand ein weiteres Anwendungsbeispiel. Der Fokus liegt hierbei auf einer *datenbasierten Dynamisierung von Stichproben* in der Montage zur Reduzierung des Prüfaufwandes und einer damit verbundenen Kosteneinsparung. Das dritte Anwendungsbeispiel wurde in Zusammenarbeit mit der Krones AG entwickelt, einer der weltweit führenden Hersteller von Anlagen und Maschinen für die Produktion, Abfüllung und Verpackung von Getränken und flüssigen Nahrungsmitteln. Der vorgestellte Lösungsansatz verfolgt eine *Steigerung der Prozessrobustheit durch Kostenprognosen* (sog. Price Tags) für die Meilensteine des Auftragsabwicklungsprozesses auf Basis historischer Daten.

4.1 Ausschussprognosen in Produktionsketten

Ausgangssituation, Zielstellung und Potenziale

Die Lumileds Germany GmbH ist einer der führenden Hersteller von Automobilbeleuchtung und LED Komponenten. Am Standort Aachen entwickelt und produziert Lumileds in

einem mehrstufigen Fertigungsprozess ca. 100.000.000 Autolampen pro Jahr. In der jüngeren Vergangenheit kam es vermehrt zu Schwankungen in der Maschinenverfügbarkeit sowie einer Erhöhung der Ausfallraten bestimmter Teile ohne Identifikation der Hauptursachen. Aufgrund einer kontinuierlichen Akquise von Prozess- und Produktdaten entlang der Fertigungslinie steht über das MES eine breite Datenbasis für die Anwendung von Data Analytics Methoden zur Verfügung. Das sog. „Softlabeling“ der Daten erlaubt eine Betrachtung der Fertigungshistorie auf Produktebene, d.h. jedem individuellen Produkt lassen sich die zugehörigen Datenpunkte zuordnen. Aktuell wird die Datenbasis bereits für eine SPC einzelner Messwerte angewandt, jedoch ohne Betrachtung der gesamten Fertigungskette.

Im Rahmen des Lösungsansatzes wird auf Basis der MES-Daten der gesamten Fertigungskette ein prädiktives Grey-Box Modell trainiert (vgl. Bild 9). Ziel ist die Bildung eines Prognosemodells zur Vorhersage von Ausschussteilen im letzten Prozessschritt der Fertigungskette, da diese im Vergleich zur Entstehung in früheren Schritten teuer sind. Mit Hilfe dessen lassen sich die Haupteinflussgrößen entlang der Prozesskette auf die Ausschussrate im letzten Fertigungsschritt identifizieren und erste Handlungsempfehlungen ableiten. Durch die Identifikation der Einflussgrößen ergeben sich Potenziale, die sich wie folgt zusammenfassen lassen:

- Ableitung allgemeiner Handlungsempfehlungen für die Parametereinstellung in allen Fertigungsschritten
- Vermeidung von teurerem Ausschuss in späten Phasen der Produktion durch Anpassung von Grenzwerten (z. B. Anpassung von Prozessparametern in vorgelagerten Fertigungsschritten)
- Erhöhung der Reaktionsgeschwindigkeit bei Prozessschwankungen (Voraussetzung ist eine online-Auswertung durch das Modell)

● Prognose i.O. mit Wahrscheinlichkeit y ● Prognose n.i.O. mit Wahrscheinlichkeit x

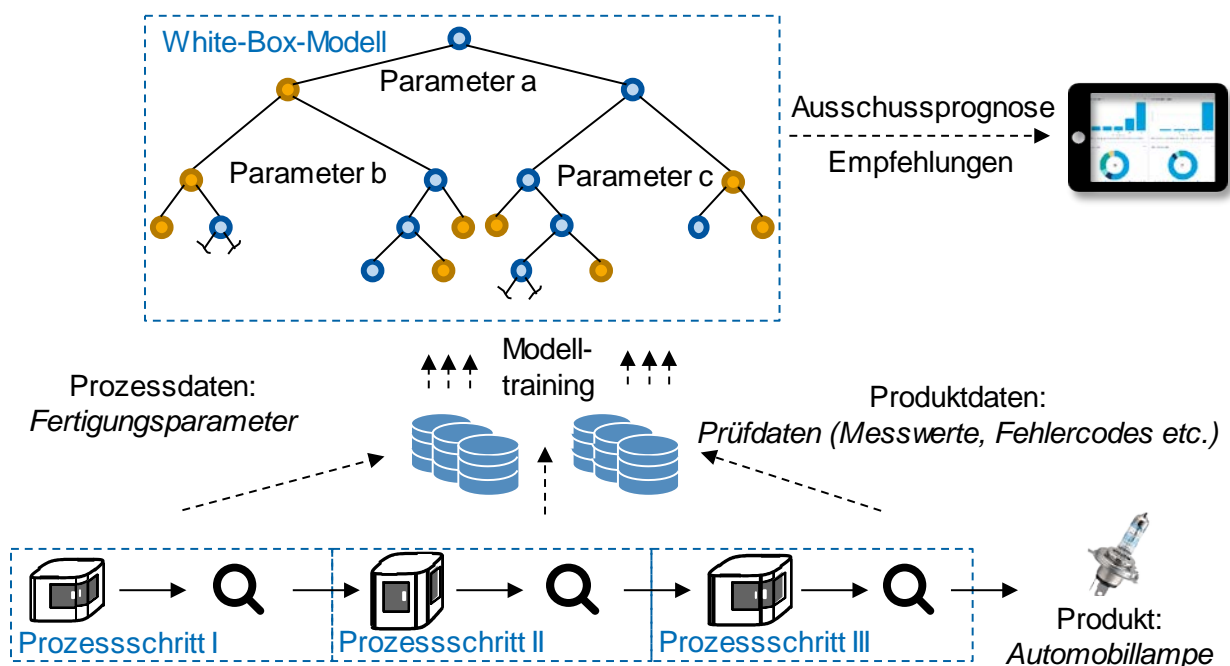


Bild 9: Ausschussprognosen in Produktionsketten am Beispiel eines Entscheidungsbaums

Vorgehen und erzielte Mehrwerte

Grundsätzlich herrscht im vorliegenden Anwendungsfall die komfortable Ausgangssituation, dass die zu analysierenden Daten zum einen bereits gesammelt in einem System (MES) gespeichert sind und sich größere Datenintegrationsaufwände erübrigen. Zum anderen lässt sich jeder Datenpunkt aufgrund des eingangs erwähnten Softlabelings mit individuellen Werkstücken verknüpfen. Dies bildet eine Grundvoraussetzung für die prädiktive Analyse der Daten hinsichtlich der Zielgröße „Fertigungsausbruch“. Das angewendete Vorgehen basiert im Kern auf dem Analyseprozess des CRISP-DM, dem „Cross Industry Standard Process for Data Mining“:

1. Festlegen des Betrachtungsrahmens: Der Analysezeitraum wird festgelegt und die häufigsten Fehlertypen im letzten Fertigungsschritt werden als Zielgrößen ausgewählt.
2. Sichtung der Daten: Es findet eine Überprüfung der Qualität und Reliabilität der Produkt- und Prozessdaten aus dem MES statt.
3. Datenvorverarbeitung: Es wird ein Datensatz als Basis für die Modellbildung zusammengestellt.
4. Modellierung: Aufgrund guter Interpretierbarkeit wird der Entscheidungsbaum als Analysemethode ausgewählt. Während des Trainings findet eine iterative Anpassung der Parameter statt.
5. Evaluation der gebildeten Modelle: Über 75 % der Ausfälle können durch das Modell abgebildet werden (Recall der Klasse „Fehler“ > 75 %), wodurch der Anwender theoretisch in die Lage versetzt wird diese Ausfälle zu eliminieren.
6. Ableitung von Handlungsempfehlungen: In Abhängigkeit vom jeweiligen Fehlertyp lassen sich durch das Prognosemodell konkrete Einstellungsempfehlungen für verschiedene Prozessparameter ableiten (vgl. Bild 9).

Die Untersuchung der langfristigen Auswirkungen auf die Ausschussquote durch Anwendung in der realen Produktionsumgebung befindet sich in der aktuellen Umsetzung.

Nächste Schritte

Das weitere Vorgehen umfasst mehrere Schritte. Dies betrifft zum einen das Schließen von Lücken in der Datenaufnahme entlang der Fertigungskette wie z. B. die Erfassung von Mitarbeiterinflüssen durch manuelles Einrichten des Fertigungsprozesses. Darüber hinaus wird die Weiterentwicklung der Visualisierung in Form eines „prozesszentrierten“ Entscheidungsbaums, dessen Knotenpunkte sich an der Struktur des Fertigungsprozesses orientieren, zu einer anwendungsfreundlicheren Entscheidungsunterstützung führen. Da Entscheidungsbäume aufgrund ihrer Beschaffenheit weder besonders robust bei zeitabhängigen Zusammenhängen, noch besonders geeignet für den Einsatz in automatisierten Anwendungen sind, stellt das Testen von Black-Box-Modellen als Alternative einen weiteren nächsten Schritt dar. Unter der Voraussetzung, dass die Datenqualität weiter verbessert wird, verspricht man sich vom Training und Deployment solcher Modelle eine erhöhte Prognosegenauigkeit. Die Umsetzung in konkrete Handlungsempfehlungen gestaltet sich aufgrund fehlender Transparenz jedoch deutlich komplexer.

4.2 Datengetriebene Dynamisierung von Stichproben

Ausgangssituation, Zielstellung und Potenziale

Die TCG Unitech GmbH ist ein österreichischer Automobilzulieferer, welcher unter anderem Druckguss- sowie Spritzgussteile entwickelt und produziert. Die hohen Kundenanforderungen an Produktqualität und Liefertreue stellen dabei eine besondere Herausforderung für die kontinuierliche Qualitätssicherung dar. Anhand eines konkreten Beispiels

bedeutet dies, dass für besondere Merkmale eines Abschlussdeckels von Kundenseite eine Null-ppm-Absicherung gefordert wurde. Dies ließ sich zum damaligen Zeitpunkt nur durch eine 100%-Prüfung mittels 3D-Koordinatenmessgerät (3D-KMG) realisieren, welche wiederum mit hohen Prüfaufwänden und Kosten verbunden ist [16].

Hier setzt der Lösungsansatz der Prüfdynamisierung an, welcher in einem Kooperationsprojekt mit der Q-DAS GmbH für eine Fertigungslinie erfolgreich umgesetzt wurde. Die Prüfdynamisierung basiert auf der Anwendung der Statistical Process Control (SPC), also der kontinuierlichen Überwachung bestimmter Qualitätsmerkmale mittels statistischer Prozessregelung. Hierzu werden definierte Produktmerkmale regelmäßig gemessen und im Falle von Abweichungen wird korrigierend in den Prozess eingegriffen.

Im Gegensatz zur herkömmlichen SPC, bei der im Falle von stabilen Prozessen keine weiteren Maßnahmen automatisiert eingeleitet werden, erfolgt im Rahmen der Prüfdynamisierung nach DIN ISO 2859 – Teil 3 die Prüfung stabiler Merkmale gezielt seltener. Das Hauptziel dieses sog. Skip-lot-Stichprobenverfahrens ist es, durch den Verzicht auf die Prüfung eines Merkmals oder des ganzen Teils den Gesamtprüfaufwand zu verringern [17]. Die Ziele der Prüfdynamisierung lassen sich wie folgt zusammenfassen (vgl. Bild 10):

- Reduktion der Prüfhäufigkeit von stabilen Merkmalen (Auslassen von Merkmalen)
- Erhöhung der Prüfhäufigkeit von instabilen Merkmalen
- Messungen werden ausgelassen (Skip)
- Gewährleistung des ppm-Ziels „Null Fehler“

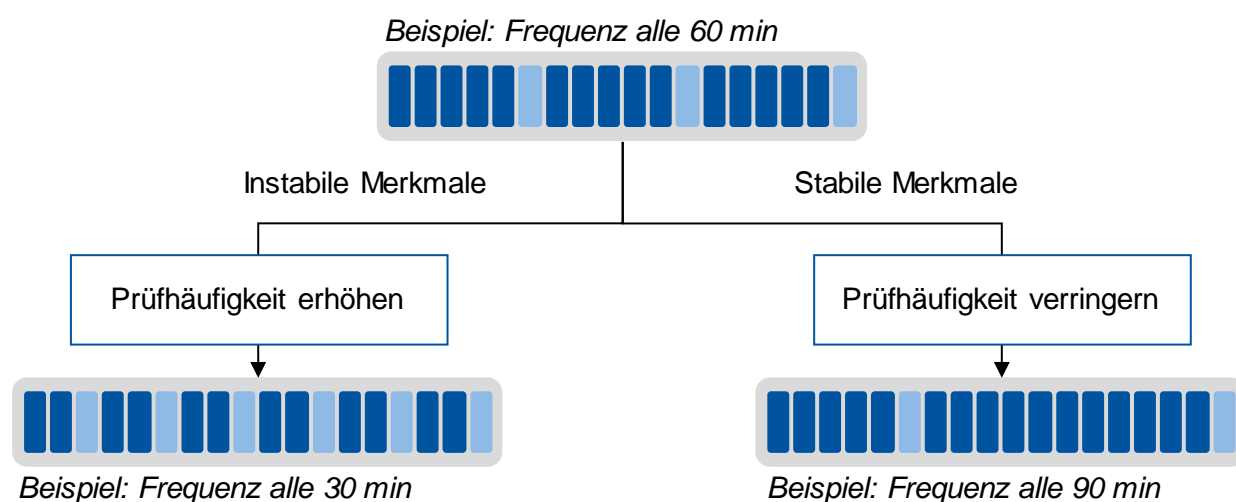


Bild 10: Prinzip der dynamischen Anpassung der Prüfhäufigkeit (Quelle: Q-DAS)

Durch den Einsatz des Verfahrens lassen sich Kosteneinsparungen sowohl in Bezug auf die Erstinvestitionen als auch im laufenden Messbetrieb realisieren. Darüber hinaus können Wartungsaufwände durch ungeplante Anlagenstopps reduziert und Anlagenpersonal effizienter eingesetzt werden. Durch den Fokus auf besonders problembehaftete Merkmale lässt sich außerdem die Transparenz bezüglich der Prozessqualität erhöhen.

Vorgehen und erzielte Mehrwerte

Das Verfahren zur Dynamisierung basiert auf der DIN ISO 2859 – Teil 3. Wie in Bild 11 dargestellt, wird zunächst mit der sog. Grundqualifizierung begonnen, in welcher geprüft wird wie „stabil“ die Merkmalsausprägung der untersuchten Teile ist. Nach einer definierten Anzahl von geprüften Teilen und sobald die statistischen Anforderungen an die

Grundqualifizierung erfüllt sind, beginnt die nächste Phase der Optimierung. In dieser Phase werden weitere Teile geprüft und erst im Falle, dass die Stabilität der Merkmale auch weiterhin bestätigt wird, beginnt das Skippen, also das Auslassen von Prüfungen.

Eine Rückkehr in den Ausgangszustand der Grundqualifizierung wird durch unterschiedliche dynamisierungsrelevante Störeevents getriggert (vgl. Bild 11). Zum einen erfolgt dies durch eine Verletzung der Eingriffsgrenzen, welche sich aus den Messdaten des 3D-KMGs ergeben. Zum anderen werden auch Daten aus den vorgelagerten Prozessschritten, der Fertigung und Reinigung des Bauteils, erhoben und hinsichtlich ihrer Relevanz für die Prüfdynamisierung analysiert. Dynamisierungsrelevante Informationen aus der Fertigung im CNC Bearbeitungszentrum kommen u. a. von Werkzeugbruchsensoren, der Auflagenkontrolle und Sensorik zur Messung der MMS.

Um die Verknüpfung verschiedener dynamisierungsrelevanter Störeevents mit dem individuellen Bauteil zu schaffen war es initial notwendig eine Integration der Prozessdaten aus unterschiedlichen Systemen zu realisieren. Neben der Migration des bestehenden Datenbestandes aus dem Altsystem gehörte hierzu die Schaffung von Systemschnittstellen sowie eine zentrale Datenhaltung über die Prozesskette hinweg.

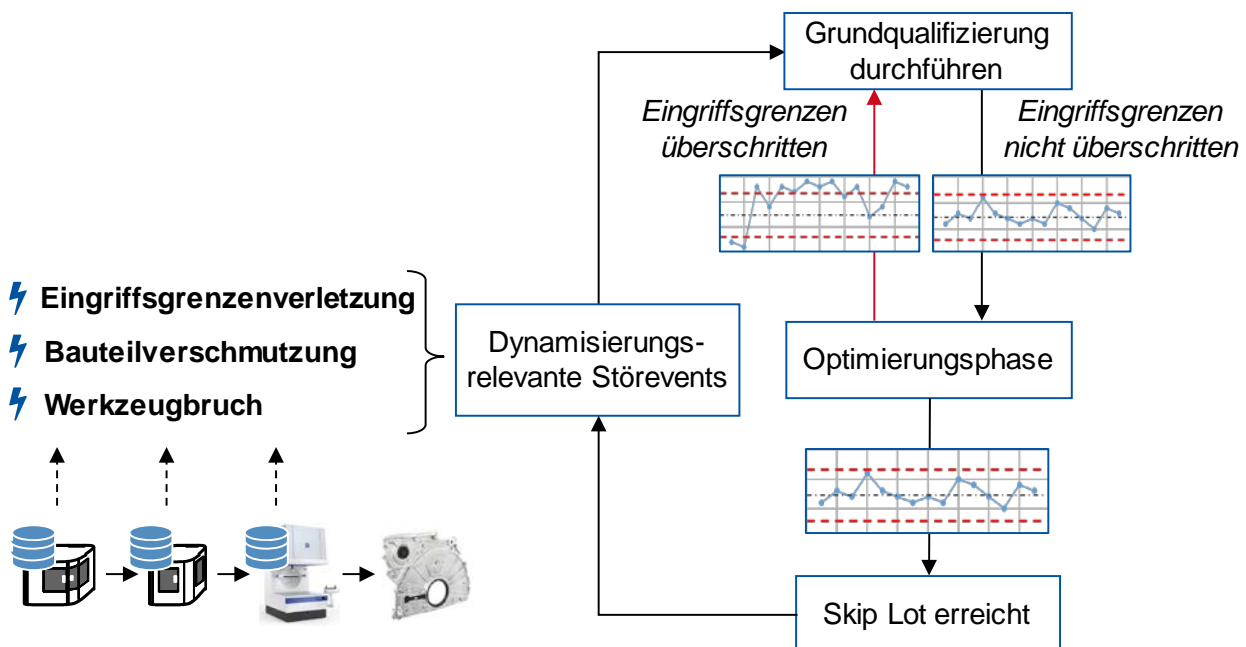


Bild 11: Das Verfahren der dynamisierten Stichprobenprüfung (Quelle: TCG Unitech)

Das vorgestellte Anwendungsbeispiel bietet eine statistisch abgesicherte Vorhersage auf Basis von Prozessdaten, inwieweit von einer i. O. Prüfung bestimmter Prüfmerkmale ausgegangen werden kann. Hierzu wird die klassische SPC durch Vernetzung der Prozessschritte und Analyse von dynamisierungsrelevanten Daten sinnvoll ergänzt. Die Entscheidungsunterstützung des Menschen erfolgt durch eine konkrete Empfehlung ab wann die Prüfung bestimmter Merkmale bzw. Bauteile ausgelassen werden kann. Darüber hinaus wird die Aufmerksamkeit auf besonders instabile Prüfmerkmale gelenkt, wodurch die Transparenz der Prozessqualität erhöht wird. Neben der Schonung von Ressourcen in Bezug auf Messtechnik und Personal ergeben sich auch rein monetäre Mehrwerte. So konnten ca. 240.000 € bei Erstinvestitionen und ca. 20.000 € laufende Kosten pro Jahr eingespart werden. [16]

Nächste Schritte

Neben der Übertragung des Systems zur Prüfdynamisierung vom Piloten auf weitere Fertigungslinien steht die automatisierte Weiterverarbeitung der Statistikergebnisse und damit die Datenrückführung in die Fertigungsanlage im Fokus des weiteren Vorgehens [16]. So sollen im Rahmen kommender Projekte basierend auf den Statistikergebnissen Korrektur- und Kompensationswerte prognostiziert werden. Anschließend ist die Realisierung eines Feedback-Loops zur automatisierten Übertragung dieser Werte in die Fertigungsanlage geplant, um so qualitätssteuernd in den Fertigungsprozess eingreifen zu können. Durch die Automatisierung des präskriptiven Handelns soll die Entscheidungsunterstützung des Menschen so weiter verbessert werden.

4.3 Price Tagging – Kostenprognosen für Meilensteine

Ausgangssituation, Zielstellung und Potenziale

Die Krones AG ist einer der weltweit führenden Hersteller von Anlagen und Maschinen für die Produktion, Abfüllung und Verpackung von Getränken und Flüssignahrung. Aufgrund der Vielfältigkeit in der Zusammensetzung der Anlagen sowie der unterschiedlichen Umgebungsbedingungen vor Ort, handelt es sich bei den Anlagen um hochindividualisierte Sonderanlagen mit hoher Varianz. Neben dem Umgang mit dieser Varianz sind folgende Herausforderungen bei der Auftragsabwicklung zu nennen:

- Häufig fehlende Informationen, z.T. aufgrund langer Vorlaufzeit zwischen der Maschinen-/Anlagenbestellung und der Feinplanung
- Schnittstellenproblematiken in der Maschinen- und Anlagenauslegung z. B. aufgrund von Anbindung an bestehende Altsysteme oder Fremdmaschinen
- Aufwand vs. Termin-Abwägungen

In der Folge ist der Auftragsabwicklungsprozess bei der Krones AG geprägt von einer komplexen Klärungsphase bezüglich der Anlagenspezifikation. Wie in Bild 12 dargestellt zieht sich die finale Klärung der Spezifikationen in der Auftragsabwicklung teilweise bis zum Versand bzw. der Außenmontage der Anlagenkomponenten.

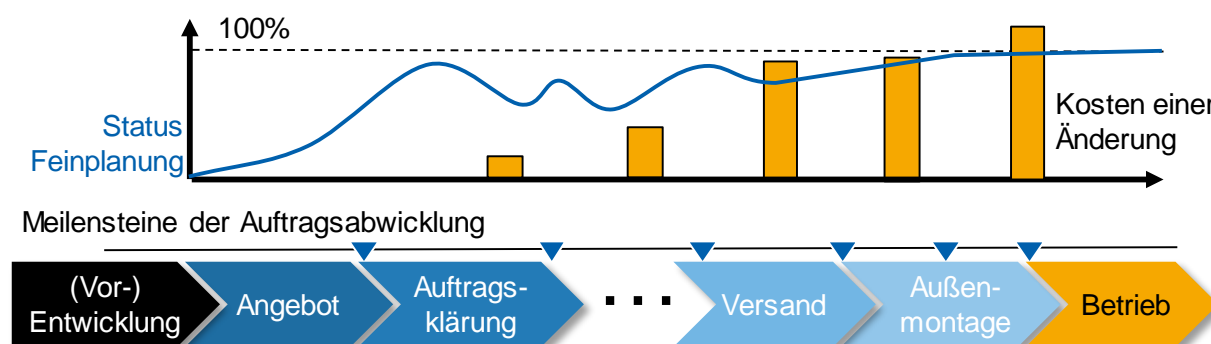


Bild 12: Auftragsabwicklung bei der Krones AG (Quelle: Krones)

Problematisch wird dies, wenn z. B. zu bestimmten Meilensteinen im Auftragsabwicklungsprozess trotz Klärungsmängel Entscheidungen getroffen werden müssen. Entstehende Folgekosten aufgrund späterer Änderungen oder sogar bauseitiger Nachbesserungen sind zum jeweiligen Entscheidungszeitpunkt schwer abzuschätzen. Folglich werden diese Entscheidungen aufgrund fehlender Transparenz über diese Folgekosten i.d.R. im Hinblick auf die Termintreue und Ressourcenverfügbarkeit getroffen.

An dieser fehlenden Transparenz knüpft der Lösungsansatz des „Price Tagging“ an. Durch die Analyse historischer Daten werden für die Meilensteine des Auftragsabwicklungsprozesses Kostenprognosen (sog. Price Tags) geschaffen, die Vorhersagen über potenziell entstehende Kosten bei fehlenden oder verzögerten Informationen treffen. In der Folge sorgen diese Kostenprognosen für eine höhere Transparenz und somit zu bewussteren Entscheidungen in frühen Phasen der Auftragsabwicklung (vgl. Bild 13). Um ein kostenorientierteres Handeln zu fördern, steht die Akzeptanz der Methodik und nicht die Genauigkeit der Kostenprognose im Vordergrund.




Bild 13: „Price-Tag“-Ansatz in der Auftragsabwicklung (Quelle: Krones)

Vorgehen und erzielte Mehrwerte

Der Kern des Lösungsansatzes bildet die Korrelation von Kosten (bedingt durch Änderungen, bauseitige Nachbesserungen und Reklamationen), Fehlerart und Anlagencharakteristika zur Bildung eines Prognosemodells für potentiell entstehende Kosten. Über die Verbindung mit der historischen Häufigkeit kann ebenso eine Auftretenswahrscheinlichkeit berücksichtigt werden. Das Vorgehen zur Bildung dieser Prognosemodelle lässt sich wie folgt beschreiben (vgl. Bild 14):

1. Die historischen Daten von Fehler- und Reklamationskosten, welche durch Auftragsänderungen und Reklamationen bedingt sind, werden aufbereitet.
2. Es werden signifikante Auftragsmerkmale in den historischen Daten als Kostentreiber identifiziert. Diese umfassen z. B. bestimmte Anlagencharakteristika (technisch und wirtschaftlich) sowie wiederkehrende Fehlerarten.
3. Die Daten werden bezüglich Fehlerhäufigkeiten und Kostenimpact geclustert.
4. Die gebildeten Cluster werden mit den Spezifikationsschritten im Auftragsabwicklungsprozess korreliert.
5. Es werden Kostenprognosen für die kritischen Zeitpunkte (Meilensteine in der Auftragsabwicklung) in Form von „Price Tags“ abgeleitet.

Das Anwendungsbeispiel befindet sich in der laufenden Umsetzung. Aktuelle Schritte sind die Analyse der Fehler- und Reklamationskosten sowie die Identifikation der größten Kostentreiber für einzelne Spezifikationsschritte.

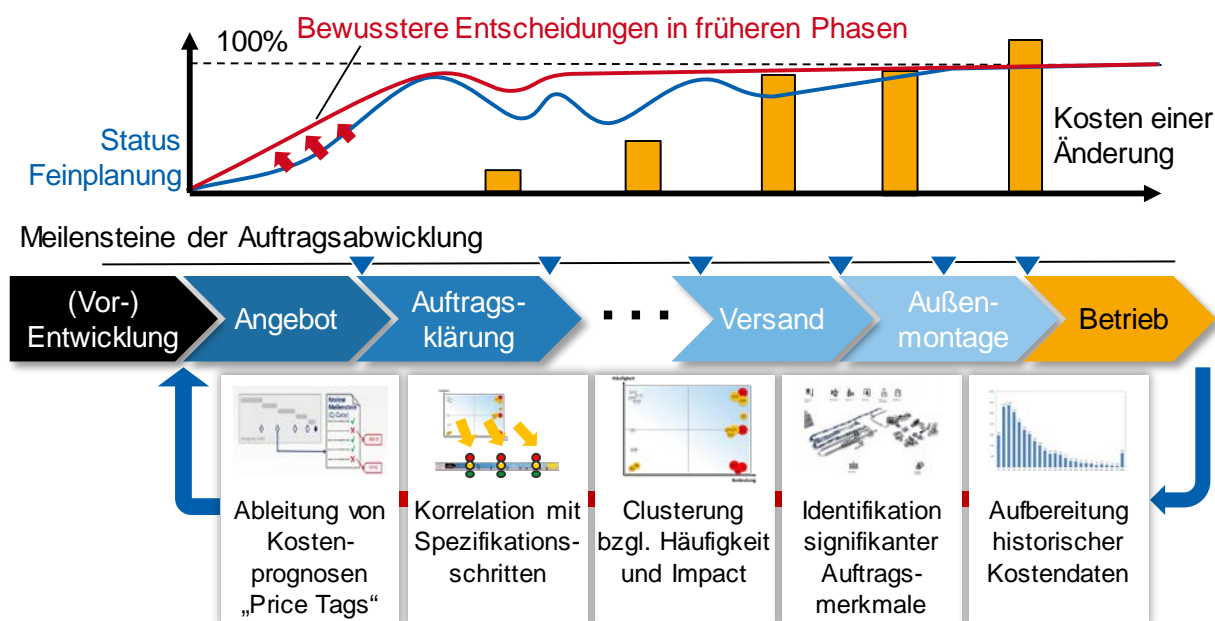


Bild 14: Vorgehen zur Bildung der Price-Tags (Quelle: Krones)

Die besondere Herausforderung bei der Modellbildung zur Kostenprognose liegt hier in der Clustering und Verknüpfung relevanter Fälle, da die Wiederholhäufigkeit und damit die statistische Signifikanz der Analyse im Sondermaschinen- und Anlagenbau sehr gering ist. Dem gegenüber steht der Mehrwert einer prädiktiven Entscheidungsunterstützung, welche Antworten auf die Frage liefert: Was werden fehlende Informationen zu einem bestimmten Zeitpunkt kosten? Durch die so geschaffene Transparenz wird der Nutzer zu präskriptivem Handeln befähigt.

Nächste Schritte

Das weitere Vorgehen beinhaltet die Vervollständigung der in Bild 14 dargestellten Analyseketten und die Validierung des Modelloutputs in Form von Price Tags in einem realen Anwendungsszenario. Darüber hinaus steht die Systematisierung dieser Datenanalyse im Fokus weiterer Bemühungen, um dieses zu einem vollwertigen Entscheidungsunterstützungssystem auszubauen und ein breites Roll-Out der Lösung zu ermöglichen.

5 Voraussetzungen für die Realisierung

Die dargestellten Anwendungsbeispiele zeigen, dass die Entscheidungsunterstützung des Menschen durch eine erfolgreiche Umsetzung datengetriebener Qualitätsprognosen in verschiedenen Bereichen möglich ist. Der Erfolg der Umsetzung liegt dabei in der Realisierung der in den Datenmengen steckenden Potenziale. Diese Datenmengen werden im Analysekontext häufig durch die 5 V charakterisiert: *Volume*, *Velocity*, *Variety*, *Veracity* und *Value* [18]. Für eine erfolgreiche Realisierung lassen sich aus den Anwendungsbeispielen und den charakteristischen 5 V großer Datenmengen unterschiedliche Voraussetzungen ableiten:

1. Motivation, Erwartungshaltung und Akzeptanz
2. Auswahl und Bewertung des Use Cases
3. Technische Voraussetzungen
4. Expertise & Zertifizierung

Zu Beginn ist eine klare Definition der *Motivation* des Unternehmens notwendig. Der Einsatz von Machine Learning als Teilbereich der Künstlichen Intelligenz (KI) kann beispielsweise dadurch motiviert sein, dass das Unternehmen in der Außenwirkung als innovativ wahrgenommen werden möchte. Die Zielstellungen hinter den zu entwickelnden Lösungen weichen in diesem Fall stark von anderen Motivationen wie dem Aufbau von Expertise oder der tatsächlichen Prozessverbesserung ab. Darüber hinaus scheitern Projekte durch eine unverhältnismäßige *Erwartungshaltung* darüber, was durch den Einsatz von ML erreicht werden kann, weshalb schon bei der Klärung der Motivation eine realistische Einschätzung der Möglichkeiten sichergestellt werden muss. Neben dem Verständnis zur Motivation und einer klaren Erwartungshaltung stellt die *Akzeptanz* bei den involvierten Mitarbeiterinnen und Mitarbeitern eine zentrale Voraussetzung dar: Nur, wenn von Anfang an die Vorbehalte ernst genommen werden und im besten Fall Begeisterung für das Thema geschaffen wird, kann ein entsprechendes Vorhaben erfolgreich werden.

Die zweite Säule notwendiger Voraussetzungen stellt die *Auswahl* eines erfolgversprechenden *Use Cases* dar. Die Unterschiede zwischen verschiedenen Use Cases sind teils signifikant, bspw. in Hinsicht auf die technische Realisierbarkeit oder den wirtschaftlichen Mehrwert [19]. Die strukturierte strategische und technische Bewertung der unterschiedlichen Use Cases sowie eine entsprechende Auswahl stellen daher weitere Voraussetzungen für eine erfolgreiche Umsetzung und die Generierung von *Value* dar [20, 21].

Die Performanz eines Systems zur Vorhersage der Qualität hängt im großen Maße von den technischen Voraussetzungen ab. Zunächst ist eine ausreichende *Digitalisierung und Vernetzung* der zu betrachtenden Prozesse notwendig. Hierzu zählen unter anderem verfügbare Sensorik, hardware- wie softwareseitige Schnittstellen, eine Datenbankinfrastruktur sowie Datenintegration. Soll die Produktqualität vorhergesagt werden, sind darüber hinaus ausreichend *Instanzen* der vorherzusagenden Größen in den Daten notwendig – beispielsweise ausreichend hergestellte n.i.O.- und i.O.-Produkte und zugehörige Datensätze (*Volume & Variety*). Doch selbst wenn ausreichend Instanzen, also Produkte, erzeugt worden sind, kann ein Vorhaben scheitern, wenn die *Rückverfolgbarkeit* der Daten, bspw. über eindeutige Produkt-IDs, nicht gewährleistet ist. Eine weitere technische Voraussetzung liegt in der Auswahl der Algorithmen sowie der Schaffung entsprechender Rechenkapazitäten, um die jeweils geforderte Analysegeschwindigkeit zu realisieren (*Velocity*). Das größte Hindernis für Unternehmen stellt allerdings noch immer die Datenqualität dar (*Veracity*). Die entsprechende Aufbereitung der Daten erzeugt den größten Arbeitsanteil in der Projektdurchführung - trotz unterschiedlicher Unterstützungsansätze, wie verschiedene Softwareumgebungen. [22]

Für die erfolgreiche Entwicklung eines Systems zur Qualitätsvorhersage ist eine Domänenexpertise bspw. zu den Produktionsabläufen und Produkten unabdingbar. Auf der anderen Seite ist *Expertise* aus dem Bereich *Data Science* notwendig, die entweder unternehmensintern aufgebaut oder zunächst über externe Partner abgebildet werden kann [23]. Selbst wenn alle erwähnten Voraussetzungen erfüllt sind, ein erfolgreiches Proof of Concept erarbeitet und ein Demonstrator entwickelt wird, kann das Vorhaben scheitern. Die Ursache hierfür liegt in der eingeschränkten Transparenz und damit einhergehenden Problemen in der *Zertifizierung* der Prozesse und Produkte [24]. Aus diesem Grund werden derzeit verschiedene Ansätze erarbeitet, wie durch ML unterstützte Produkte und Prozesse weiterhin zertifiziert werden können [25, 26]. Gleichzeitig wird an der Transparenzerhöhung lernender Assistenzsysteme zur besseren Erklärbarkeit und Nachvollziehbarkeit gearbeitet [27]. Für den jeweiligen Use Case ist daher zu prüfen, ob es durch die entwickelte Lösung zu Problemen bei der Zertifizierung kommen kann.

6 Herausforderungen bei der Umsetzung

Die übergeordneten Herausforderungen bei einer erfolgreichen Umsetzung datengetriebener Entscheidungsunterstützung durch Qualitätsprognosen lassen sich in *technische* und *unternehmenskulturelle bzw. betriebswirtschaftliche Herausforderungen* untergliedern.

6.1 Technische Herausforderungen

Im Zentrum der technischen Herausforderungen steht dabei die *Datenakquise* von Rohdaten aus verschiedenen Domänen. Diese umfasst zum einen die Akquise und Integration unterschiedlicher Datentypen (strukturiert vs. unstrukturiert) ohne den Verlust von kontext-relevanten Metainformationen. Zum anderen bringt die Extraktion von Daten aus verschiedenen heterogenen Datenquellen selbst einige Stolpersteine mit sich. Hier sieht das Aachener Internet of Production für die Verwaltung des Datenzugriffs auf verschiedene proprietäre Systeme eine sogenannte Middleware+ vor, um letztendlich einen Data Lake als Grundlage für anwendungsspezifische Analysen zu schaffen [10]. Um gezielt fehlende Daten auf dem Shopfloor aufzuzeichnen, kann auch Retrofitting von veralteter Technik oder Fremdmaschinen notwendig sein.

Aufbauend auf der Datenakquise bringt die *Datenanalyse* weitere Herausforderungen mit sich. Diese umfassen neben der Auswahl der richtigen Daten die Anwendung von Data Analytics Methoden selbst. Die Tatsache, dass häufig nicht alle relevanten Informationen in den Daten abgebildet sind, stellt eine weitere Hürde für den erfolgreichen Einsatz prädiktiver Modelle dar. Die zentrale Herausforderung für Unternehmen steckt in der Nutzbarmachung des Wissens, welches den Mitarbeiterinnen und Mitarbeitern inhärent ist. Die zentrale Herausforderung ist dabei die technische Umsetzung der Überführung von Mitarbeiterwissen in prädiktive Modelle bzw. Assistenzsysteme.

Die *Ableitung geeigneter Maßnahmen* aus den durch die Datenanalyse gewonnen Erkenntnissen stellt die Unternehmen ebenfalls vor Herausforderungen. Dabei liegt die größte Schwierigkeit in der Übersetzung der Prognosen in konkrete Handlungsempfehlungen, solange diese nicht präskriptiv durch ein lernendes Assistenzsystem bereitgestellt werden. Weitere Herausforderungen liegen in der Übertragbarkeit der Erkenntnisse auf ähnliche Produkte oder Anwendungen sowie der Interpretation im Falle von intransparenten Prognosemodellen mit Black-Box Charakter.

6.2 Unternehmenskulturelle und betriebswirtschaftliche Herausforderungen

Unternehmensintern stehen die größten Herausforderungen in direktem Zusammenhang mit der Einbindung von *Mitarbeiterinnen und Mitarbeiter*. So muss für den erfolgreichen Einsatz datengetriebener Entscheidungsunterstützung ein Umdenken bei den Mitarbeiterinnen und Mitarbeitern erfolgen. Dies kann nur über die gezielte Förderung des Vertrauens in die Leistungsfähigkeit der Systeme geschehen. Neben der Akzeptanzförderung der Mitarbeiterinnen und Mitarbeiter ist unternehmensintern häufig auch ein Nachweis des monetären Nutzens solcher Systeme zur Rechtfertigung des Investitionsvolumens zu erbringen.

Außerhalb des eigenen Unternehmens entstehen die größten Herausforderungen bei der Einbindung des *Kunden* und des *Lieferanten*. So muss für eine domänenübergreifende Datennutzung häufig der Kunde zum Teilen seiner Daten überzeugt werden, z. B. durch Darlegen der für ihn entstehenden Mehrwerte. In diesem Zusammenhang gilt es auch rechtliche Fragen bezüglich der aufgezeichneten Daten zu klären: Wer ist der Eigentümer der Daten? Wer darf die Daten für welche Zwecke nutzen? Analog zur eigenen Beleg-

schaft muss in diesem Zusammenhang auch ein Umdenken beim Kunden durch die aktive Förderung des Vertrauens in datengetriebene Unterstützungssysteme erfolgen. Dies gilt in besonderem Maße für den Einsatz neuer Geschäftsmodelle. Neben dem Kunden stellt auch die Einbindung des Zulieferers für eine domänenübergreifende Datennutzung häufig eine Herausforderung dar. Zugriff auf die Daten des Zulieferers lassen sich durch festgeschriebene vertragliche Verpflichtungen oder durch Darlegen der entstehenden Mehrwerte für den Kunden realisieren.

7 Zusammenfassung und Ausblick

Zunehmende Produktkomplexität und -vielfalt, komplexere Herstellungsprozesse und steigende Nachhaltigkeitsforderungen aus Bevölkerung und Politik stellen zentrale Herausforderungen für die kontinuierliche Verbesserung der prozess- und produktbezogenen Qualität dar. Zur Bewältigung dieser Herausforderungen wurden in der Qualität bereits in der Vergangenheit Ansätze zur Extraktion und Nutzung des Wissens verfolgt, welches in den aufgezeichneten Daten steckt. Data Analytics bietet nun ein Werkzeug, die exponentiell ansteigende Datenmenge im Rahmen von anwendungsspezifischen Analysen noch umfangreicher zur systematischen Entscheidungsunterstützung zu nutzen. Predictive Quality beschreibt in diesem Zusammenhang die Befähigung des Anwenders zur Optimierung der produkt- und prozessbezogenen Qualität durch die Nutzung datengetriebener Prognosen als Entscheidungsgrundlage für Handlungsmaßnahmen.

Durch die Befähigung des Anwenders, zukünftige qualitätsbeeinflussende Ereignisse in seinem Sinne zu steuern, lassen sich in der Praxis vielfältige Potenziale realisieren. Unabhängig vom Anwendungsszenario lassen sich diese zusammenfassend durch die Sicherstellung einer hohen Produktverfügbarkeit, der Beherrschung komplexer Prozesse und der Schonung von unternehmensexternen wie -internen Ressourcen beschreiben. Im Rahmen des vorliegenden Beitrags wurde anhand von fünf Anwendungsbeispielen aus unterschiedlichen Branchen und Domänen exemplarisch gezeigt, wie sich durch die Anwendung prädiktiver Data Analytics Methoden konkrete Mehrwerte schaffen lassen.

In diesem Zusammenhang wurden im vorliegenden Beitrag neben den Mehrwerten datengetriebener Qualitätsprognosen auch die dafür zu schaffenden Voraussetzungen sowie Herausforderungen bei der Implementierung beleuchtet. Die für eine erfolgreiche Umsetzung identifizierten Voraussetzungen beinhalten den Faktor Mensch und dessen Expertise, Motivation und Erwartungshaltung. Weitere tragende Faktoren sind die Auswahl eines erfolgsversprechenden Use Cases sowie die Schaffung der richtigen (daten-)technischen Voraussetzungen. Die größten identifizierten technischen Herausforderungen liegen in der Akquise und Integration unterschiedlicher Datentypen aus heterogenen Datenquellen ohne den Verlust von kontext-relevanten Metainformationen. Weitere unternehmenskulturelle Herausforderungen liegen in der Förderung des Vertrauens von unternehmensexternen wie -internen Akteuren in datengetriebene Assistenzsysteme und des damit verbundenen Umdenkens.

Der Beitrag zeigt, dass Predictive Quality in seiner Funktion als datengetriebene Entscheidungsunterstützung zur Verbesserung der produkt- und prozessbezogenen Qualität bereits in unterschiedlichen Domänen und Branchen erfolgreich eingesetzt wird. Die vorgestellten Anwendungsbeispiele basieren übergreifend auf prädiktiven Analysemodellen und unterscheiden sich neben dem Realisierungsstand primär im Grad der bereitgestellten präskriptiven Handlungsempfehlungen. Es ist daher zu erwarten, dass neben einer Zunahme von Predictive Quality Pilotprojekten in produzierenden Unternehmen vor allem die Automatisierung des letzten Schritts von prädiktiv zu präskriptiv (Prescriptive Quality)

fokussiert wird. Diese verfügt über das Potenzial die kontinuierliche Verbesserung der produkt- und prozessbezogenen Qualität weiter zu beschleunigen und resilienter zu machen.

Danksagung

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

Literatur

- [1] Ge, Z.; Song, Z.; Ding, S. X.; Haung, A. B.: Data Mining and Analytics in the Process Industry: The Role of Machine Learning. In: IEEE Special Section on data-driven monitoring, fault diagnosis and control of cyber-physical systems. 5. Jg., 2017, Nr. 5, S. 20590–20616.
- [2] Schmitt, R.: Smart Quality - QM im Zeitalter von Industrie 4.0. 20. Business Forum Qualität; 12. und 13. September 2016, Aachen, Business Forum Qualität. 1. Aufl. Aachen: Apprimus, 2016.
- [3] Cattaneo, L.; Fumagalli, L.; Macchi, M.; Negri, E.: Clarifying Data Analytics Concepts for Industrial Engineering. In: IFAC-PapersOnLine. 51. Jg., 2018, Nr. 11, S. 820-825.
- [4] Lin, N.: Applied business analytics. Integrating business process, big data, and advanced analytics. 1. Aufl. Upper Saddle River: Safari Books, 2015.
- [5] Stimmel, C. L.: Big data analytics strategies for the smart grid. 1. Aufl. Leipzig: Auerbach, 2015.
- [6] Wöstmann, R.; Nöhring, F.; Deuse, J.; Klinkenberg, R.; Lacke, T.: Big Data Analytics in der Auftragsabwicklung. Erschließung ungenutzter Potenziale in der variantenreichen Kleinserienfertigung. In: Industrie Management 4.0. 33. Jg., 2017, Nr. 4, S. 7-9.
- [7] McKinsey&Company: The Age of Analytics. Competing in a data-driven World. URL: <https://www.mckinsey.com/~media/McKinsey/Business%20Functions/McKinsey%20Analytics/Our%20Insights/The%20age%20of%20analytics%20Competing%20in%20a%20data%20driven%20world/MGI-The-Age-of-Analytics-Executive-summary.ashx> [Stand: 01.05.2020].
- [8] Veigt, M.; Staar, B.; Schukraft, S.; Freitag, M.: Data Analytics in der Produktionsplanung. Einsatz von Data-Analytics-Methoden zur Identifikation von Einflussfaktoren auf die Termintreue. In: wt Werkstattstechnik online. 109. Jg., 2019, Nr. 4, S. 230-234.
- [9] Hübner, I.: Aus der Praxis: Predictive Maintenance bei Trumpf. In: Digital Factory Journal. 2. Jg., 2018, Nr. 3, S. 57–59.

- [10] Günther, S.; Stich, V.; Basse, F. H.-U.; Franzkoch, B.; Harzenetter, F.; Luckert, M.; Prote, J.-P.; Reschke, J.; Schmitz, S.; Tücks, G.; Weißkopf, J.: Change Request im Produktionsbetrieb. In: Brecher, C.; Schmitt, R. H.; Klocke, F. (Hrsg.): Internet of Production für agile Unternehmen. AWK Aachener Werkzeugmaschinen-Kolloquium 2017, 18. bis 19. Mai. Aachen: Apprimus, 2017, S. 109-131.
- [11] Refflinghaus, R.; Kern, C.; Klute-Wenig, S.: Qualitätsmanagement 4.0 - Status quo! Quo vadis? Bericht zur GQW-Jahrestagung 2016 in Kassel. (Reihe: Kasseler Schriftenreihe Qualitätsmanagement, Bd. 6). Kassel: Kassel University Press, 2016.
- [12] Schuh, G.; Riesener, M.: Produktkomplexität managen. 3. Aufl. München: Hanser, 2017.
- [13] Dirlea, V.; Kidambi, R.; Krubasik, S.; Sachseneder, C.: Quality 4.0 Preventive, Holistic, Future-Proof. Hg. v. ATKearney. URL: <https://www.atkearney.com/industrial-goods-services/article?/a/quality-4-0-preventive-holistic-future-proof> [Stand: 25.11.2019].
- [14] Schmitt, R.; Heinrichs, V.; Laass, M. C.: Die Meinung immer dabei. Wie Beiträge aus Sozialen Netzwerken Unternehmen nutzen können. In: QZ Qualität und Zuverlässigkeit. 59. Jg., 2014, Nr.6.
- [15] Pfeifer, T.; Schmitt, R.: Masing Handbuch Qualitätsmanagement, 1. Aufl. München: Hanser, 2014.
- [16] Kerbl, H.: Industrie 4.0 in Sichtweite. Kostensenkung durch Dynamisierung von Stichprobenplänen. In: QZ Qualität und Zuverlässigkeit. 64. Jg., 2019, Nr. 5, S.56-58.
- [17] DIN Deutsches Institut für Normung e.V.: Annahmestichprobenprüfung anhand der Anzahl fehlerhafter Einheiten oder Fehler (Attributprüfung). Teil 3: Skip-Lot-Verfahren 03.120.30 (2007-10-00) DIN ISO 2859-3.
- [18] Ishwarappa; Anuradha, J.: A Brief Introduction on Big Data 5Vs Characteristics and Hadoop Technology. In: Procedia Computer Science. 48. Jg., 2015, S. 319-324.
- [19] Krauß, J.; Dorißen, J.; Mende, H.; Frye, M.; Schmitt, R. H.: Machine Learning and Artificial Intelligence in Production: Application Areas and Publicly Available Data Sets. In: Wulfsberg, J. P.; Hintze, W.; Behrens, B.-A. (Hrsg.): Production at the leading edge of technology. Proceedings of the 9th Congress of the German Academic Association for Production Technology (WGP), September 30th - October 2nd, Hamburg 2019. Berlin: Springer, 2019, S. 493-501.
- [20] Fraunhofer-Gesellschaft: AI Kick-Starter Bundle. URL: https://www.bigdata.fraunhofer.de/de/geschaeftsfelder/produktion_industrie/ai-kick-starter-bundle.html [Stand: 11.02.2020].
- [21] WGP: KI-Starthilfe für Unternehmen. URL: <https://wgp.de/de/ki-starthilfe-unternehmen/> [Stand: 11.02.2020].
- [22] Krauß, J.; Frye, M.; Beck, G. T. D.; Schmitt, R. H.: Selection and Application of Machine Learning- Algorithms in Production Quality. In: Beyerer, J.; Kühnert, C.;

- Niggemann, Ol. (Hrsg.): Machine Learning for Cyber Physical Systems. Selected papers from the International Conference ML4CPS 2018. Berlin: Springer, 2019, S. 46-57.
- [23] Stockinger, K.; Stadelmann, T.; Ruckstuhl, A.: Data Scientist als Beruf. In: Fasel, D.; Meier, A. (Hrsg.): Big Data. Grundlagen, Systeme und Nutzungspotenziale. 1. Aufl. Heidelberg: Springer, 2016, S. 59-81.
- [24] Brandstätter, T. C.; Krauß, J.; Schmitt, R. H.: Certification of AI-Supported Production Processes. In: Wulfsberg, J. P.; Hintze, W.; Behrens, B.-A. (Hrsg.): Production at the leading edge of technology. Proceedings of the 9th Congress of the German Academic Association for Production Technology (WGP), September 30th - October 2nd, Hamburg 2019. Berlin: Springer, 2019, S. 553-561.
- [25] KI Bundesverband e.V.: Künstliche Intelligenz. Situation und Maßnahmenkatalog. URL: <https://ki-verband.de/wp-content/uploads/2018/06/KI-Verband-Positionspapier-25062018.pdf> [Stand: 01.05.2020].
- [26] DIN e. V.: Künstliche Intelligenz: Ohne Normen und Standards geht es nicht. URL: <https://www.din.de/de/forschung-und-innovation/themen/kuenstliche-intelligenz> [Stand: 11.02.2020].
- [27] Samek, W.; Montavon, G.; Vedaldi, A.; Hansen, L. K.; Müller, K.-R.: Explainable AI: Interpreting, Explaining and Visualizing Deep Learning. 1. Aufl. Cham: Springer, 2019.

Mitarbeiter der Arbeitsgruppe für den Beitrag 3.2:

Prof. Dr.-Ing. Robert H. Schmitt, WZL der RWTH Aachen

Dr.-Ing. Edgar Dietrich, IconPro GmbH, Aachen

Max Ellerich, WZL der RWTH Aachen

Johann Gregori, Krones AG, Neutraubling

Jonathan Krauß, Fraunhofer IPT, Aachen

Prof. Dr. Reiner Kurzhals, Westphalia DataLab GmbH, Münster

Armin Latz, Lumileds Germany GmbH, Aachen

Dr.-Ing. Norbert Miller, Scheidt & Bachmann GmbH, Mönchengladbach

Guido Nilgen, Miele & Cie. KG, Euskirchen

Peter Schlegel, WZL der RWTH Aachen