

# Manufacturing Analytics in der Herstellung

## Komplexe Probleme der Qualitätssicherung erkennen

Amir Cviko und  
Tobias Böing, Königen

„Big Data“ und Business Analytics sind in der deutschen Wirtschaft keine Fremdworte mehr. Viele Unternehmen aus allen Branchen werten Daten aus, auch in den herstellenden Industrien. Allerdings geschieht dies oft beispielsweise nur für Marketing oder Sales. In der Produktion dagegen liegen immer noch sehr viele Daten brach und werden nicht für eine Verbesserung der Wertschöpfung eingesetzt.

Ein typisches Beispiel: Ein OEM in der Automobilindustrie hatte Probleme in der Lackiererei. Deutlich sichtbare Fehler auf der Farboberfläche waren mit gängigen Qualitätstechniken nicht in den Griff zu bekommen. Zwar sammelte der OEM alle relevanten Daten, doch jeweils in eigenen Datenbanken pro Prozess. Zudem enthielten die Daten weder Zeitstempel der Herstellung noch die Seriennummern der individuellen Karosserie, sodass eine Auswertung unter Berücksichtigung aller beeinflussenden Prozesse schwierig war.

### Manufacturing Analytics

Kurz gesagt: Das Unternehmen hatte alle Daten, die es auf die Spur seiner Qualitätsprobleme bringen konnten, nutzte sie aber nicht. Hier ist der Ansatzpunkt für Manufacturing Analytics – also für die statistische und ganzheitliche, prozessübergreifende Analyse von Produktionsdaten. Ziele dabei sind, die Prozesse und Produktionsabläufe genauer zu verstehen sowie diese zu verbessern. Darüber hinaus sollen mit der Datenanalyse Pro-

Analytics auf der Basis von Big Data verbreitet sich in den Unternehmen. Doch meist wird es in Vertrieb, Marketing oder Buchhaltung eingesetzt. Manufacturing Analytics ist selten, trotz des großen Potenzials. Datenanalysen in der Herstellung machen den Produktionsprozess transparent, entdecken Ursachen für Störungen sowie Qualitätsprobleme und treffen Vorhersagen mit Machine Learning. Höchste Zeit für die Industrie, ihre verborgenen Datenschätze ans Tageslicht zu fördern.

zessveränderungen schnell erkannt bzw. prognostiziert werden, bevor es zu Auswirkungen auf Qualität, Durchlaufzeit oder Kosten kommt [1].

Ein genauer Blick auf die Produktionsdaten ermöglicht Einblicke in die Ursachen und Wirkungszusammenhänge, die nicht offensichtlich sind. Im Falle der Lackiererei konnte Manufacturing Analytics dem Fehler erfolgreich auf den Grund gehen: Im Laufe der Zeit veränderte sich die Einrichtung der Maschinen minimal, sodass der Farbauftrag nicht mehr optimal war. Da Manufacturing Analytics auch das Auftreten von Fehlern vorhersagen und eine automatische Neujustierung auslösen kann, würde sein Einsatz Probleme dieser Art künftig gar nicht erst auftreten lassen.

### Erkenntnis ja, Einsatz nein

Welche Möglichkeiten Datenanalysen der Automobilbranche im Produktionsprozess für das Qualitätsmanagement bieten, hat die Staufen-Tochter Staufen Quality Engineers GmbH (S.QE) in einem Forschungsprojekt gemeinsam mit dem Institut für Produktionsmanagement, Technologie und Werkzeugmaschinen (PTW) der Technischen Universität Darmstadt untersucht.

Das Ergebnis: „Manufacturing Analytics ist in allen produzierenden Unternehmen der Automobilindustrie noch immer selten, obwohl [...] es in jedem Unternehmen mögliche Anwendungsfälle gibt. Im Allgemeinen erkennen Unternehmen jedoch, dass sie die Analyse ver-

bessern müssen, um ihre Daten besser nutzen zu können. Damit komplexe Qualitätsprobleme in der Produktion nachhaltig und effizient zu lösen sind, muss Manufacturing Analytics eingesetzt werden.“ [2]

### Vorhandene und unsichtbare Datenquellen

Wenn Unternehmen Manufacturing Analytics nutzen wollen, müssen sie zuerst eine möglichst umfassende Datenerhebung sicherstellen. Hierfür sollten sie alle vorhandenen Datenquellen erfassen und auch unsichtbare Datenquellen berücksichtigen, beispielsweise bisher nicht gemessene Maschinendaten. Üblicherweise werden für Big-Data-Analysen fünf unterschiedliche Datenkategorien eingesetzt [3]:

- *Managementdaten* stammen aus den IT-Systemen der Fertigung, beispielsweise Manufacturing Execution Systems (MES) oder Enterprise Resource Planning (ERP). Sie beziehen sich unter anderem auf die Produktplanung oder Maschinenwartung.
- *Maschinendaten* sind Echtzeit-Daten über die Leistung und Betriebsbedingungen von Maschinen und Anlagen. Sie werden durch IoT-Technologien im Rahmen von Smart-Factory-Ansätzen gesammelt.
- *Benutzerdaten* werden in Internetquellen und sozialen Netzwerken gesammelt. Dazu gehören demografische Angaben und Präferenzen von Kunden oder Benutzern.

- **Produktdaten** sind Leistungsdaten, die sich aus der Anwendung ergeben und für die Funktion von Bedeutung sind. Sie werden durch IoT-Technologien im Rahmen von smarten Produkten und Services gesammelt.

Für Manufacturing Analytics werden in erster Linie Managementdaten, Maschinendaten und Produktdaten eingesetzt. Dazu gehören Maschinendaten über unterschiedliche Maschinenzustände sowie Daten über die physikalischen Prozessparameter, wie z.B. Temperatur, Druck, Fügekräfte, elektrischer Widerstand und ähnliches. Auch Performancedaten einer Wertschöpfungskette wie Zyklus- und Taktzeiten oder spezifische Qualitätsdaten sind wichtig. Letzteres können beispielsweise auch Bilder sein, die Fehler und Qualitätsprobleme zeigen.

In den meisten Fällen werden diese Daten mindestens gemessen und zudem häufig über Steuerungssysteme (SCADA, SPS, MES) ausgelesen sowie gespeichert. Doch in einigen Fällen können zur Verbesserung der Produktionsqualität auch zusätzliche Daten, etwa durch Sensoren, erhoben werden. Ein Beispiel hierzu: Ein Hersteller von Turbinen hat einige seiner Anlagen bei den Kunden nachgerüstet, um dort mit IoT-gestützten Sensoren Vibrationen zu messen. Durch Auswertung dieser Daten kann frühzeitig eine Materialermüdung erkannt werden. Solche Nachrüstungen („Retrofitting“) sind auch für Produktionsanlagen möglich und können den Datenpool für die Analyse verbessern.

### Die vier Reifegrade der Datenanalyse

Im Forschungsprojekt zeigte sich, dass die meisten Unternehmen bei Manufacturing Analytics nur einen sehr geringen Reifegrad erreicht haben. Basis für diese Einschätzung ist das Reifegradmodell [4] für Industrie 4.0, dessen vier letzte Stufen auf den Einsatz von Manufacturing Analytics übertragen werden können. Hierbei werden folgende vier Stufen nach ansteigendem Reifegrad unterschieden:

- **Descriptive Analytics** zielt auf Transparenz im Produktionsprozess und erfasst dafür Rahmenbedingungen, Umgebungs- und Betriebsparameter.
- **Diagnostic Analytics** untersucht Ursache-Wirkungs-Beziehungen und deckt die Gründe für Qualitätsprobleme oder Geräteausfälle auf.

- **Predictive Analytics** ermöglicht Vorhersagen über das Auftreten von Störungen, Ausfällen und Herstellungsfehler. Dabei werden Echtzeit-Daten unter Verwendung statistischer Modelle auf der Grundlage historischer Daten analysiert.
- **Prescriptive Analytics** erlaubt darüber hinaus die Identifizierung und im Idealfall auch automatisierte Ausführung von Maßnahmen, die Produktionsergebnisse verbessern oder Probleme beheben.

Diese vier Stufen bauen aufeinander auf. Viele Unternehmen befinden sich lediglich auf der ersten Stufe (Descriptive Analytics), bei der es vor allem um die Zusammenfassung und übersichtliche Präsentation von Daten geht. Dabei können unter Umständen bereits einfache statistische Zusammenhänge erkannt werden, beispielsweise vermehrtes Auftreten von Qualitätsproblemen zu bestimmten Zeiten oder an bestimmten Standorten.

Diese Korrelationen sind aber oft keine Ursache-Wirkung-Beziehungen. Häufig gibt es dahinterliegende Ursachen, die nicht so einfach aufzudecken sind. Sobald diese Ursachen mit Data Mining erkannt sind, können mit Machine-Learning-Algorithmen Vorhersagemodelle aufgestellt werden, die beispielsweise eine vorausschauende Wartung erlauben. Dabei werden Maschinenstörungen

frühzeitig erkannt, bevor es zu tatsächlichen Ausfällen in den Anlagen kommt. Die beiden erwähnten Verfahren gehören zu den wichtigsten Methoden für Datenanalysen.

**Data Mining** ist ein Oberbegriff für die systematische Anwendung statistischer Methoden auf große Datenbestände, durch die Querverbindungen, Trends und Kausalzusammenhänge aufgedeckt werden können. Dazu gehören Klassifizierungsverfahren, Entscheidungsbäume sowie Regressions- und Clusteranalyse. Die Verfahren werden üblicherweise auf große Mengen an vorhandenen Daten („Big Data“) angewendet und richten den Blick eher in die Vergangenheit.

**Machine Learning** ist ein Oberbegriff für lernfähige Algorithmen, die komplexe und nichtlineare Muster in Rohdaten (wieder)erkennen. Diese Verfahren werden häufig in zwei Schritten angewendet: Zuerst werden sie mit historischen Daten trainiert und erst anschließend auf aktuelle, bisher unbekannte Daten angewendet. Im Unterschied zu Data Mining sind diese Algorithmen lernfähig und führen über die Zeit hinweg zu stetig besseren Ergebnissen.

**Deep Learning** ist eine besondere Form von maschinellem Lernen, das neuronale Netzwerke einsetzt. Es eignet sich besonders für Muster- und Bilderkennung, beispielsweise beim Erkennen von Materialfehlern auf Fotos.

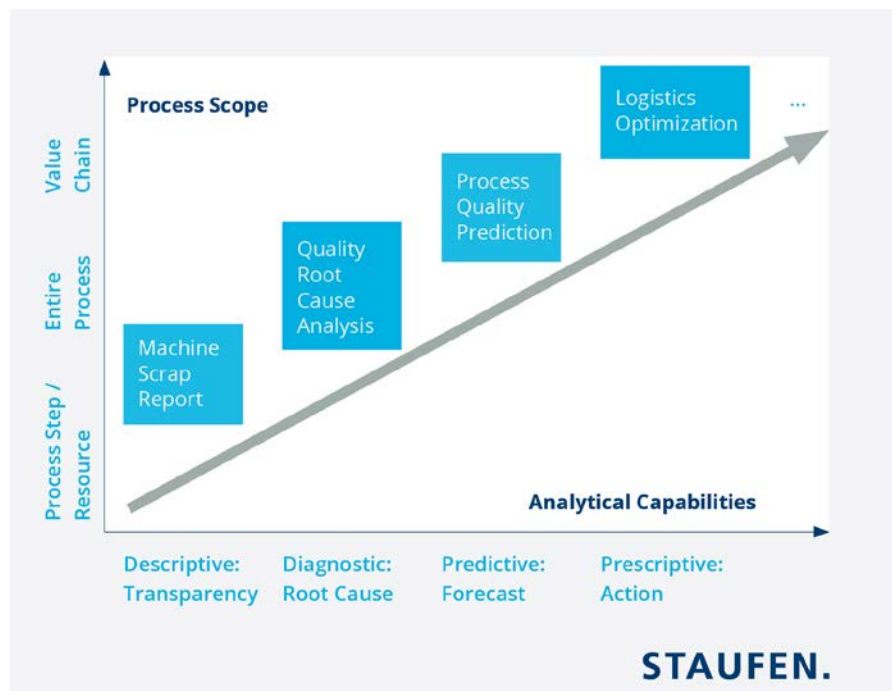


Bild 1. Die vier Reifegrade von Analytics-Anwendungen [5]

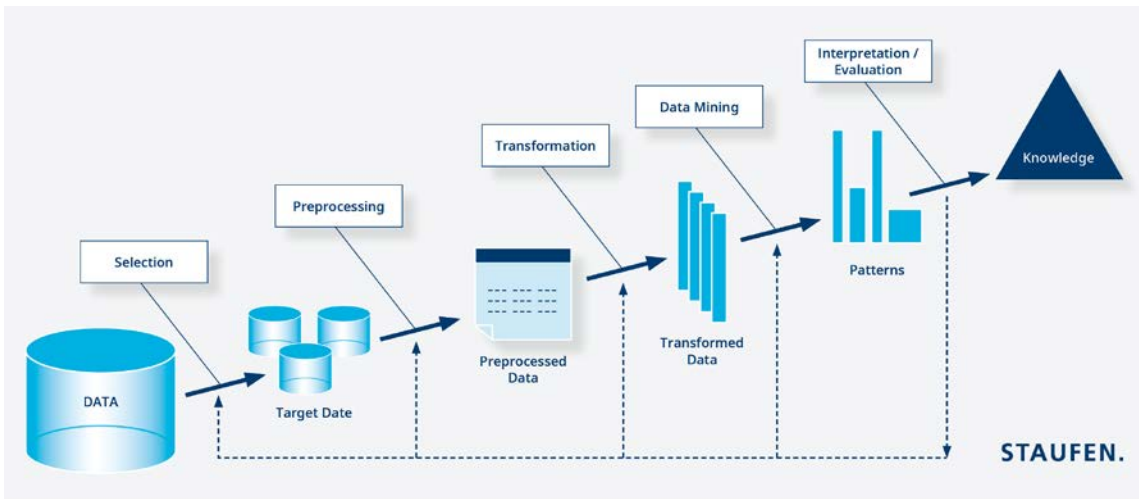


Bild 2. Von den Daten bis zum Wissen: der KDD-Prozess [6]

### Manufacturing Analytics in der Praxis

Grundlegend für den praktischen Einsatz von Manufacturing Analytics ist ein Prozess, der „Knowledge Discovery in Databases“ (KDD-Prozess) genannt wird. Er ist die Basis aller weiteren Maßnahmen und besteht aus folgenden fünf Schritten, die jeweils unterschiedlichen Arbeitsgängen oder Unterprozessen entsprechen:

- **Datenauswahl**  
Der KDD-Prozess benötigt eine Fragestellung bzw. ein Ziel, das aus Kundensicht definiert werden muss. Hinzu kommt ein Verständnis der Anwendungsdomäne sowie relevantes Hintergrundwissen. Auf dieser Basis werden die notwendigen Daten ausgewählt, immer unter Berücksichtigung der Fragestellung.
- **Datenbereinigung**  
Die Daten müssen bereinigt und vorverarbeitet werden. Dafür müssen inkorrekte, veraltete, redundante, inkonsistente, unplausible oder falsch formatierte Daten korrigiert oder entfernt werden. Kurz: Die Datenqualität muss erhöht werden.
- **Datenreduktion**  
Die effektive Datenmenge sollte möglichst verringert werden. Bereits bei der Datenbereinigung kann dies durch eine Duplikat-Erkennung geschehen sein. Weitere Beispiele dafür sind das Entfernen weniger nützlicher Attribute, das Senken der Anzahl und Dimension der Variablen durch Zusammenfassung oder der Einsatz eines speichereffizienten Datenformats.

- **Datenanalyse**  
In diesem Schritt erfolgt nun die Auswahl der Algorithmen und statistischen Verfahren sowie die eigentliche Analyse mit Data Mining und Machine Learning. Die Datenaufbereitung in den Schritten 2 und 3 sollte dabei immer mit dem Ziel geschehen, die eingesetzte Analysesoftware effizient und ohne Leistungsverluste zu nutzen.
- **Interpretation**  
Im letzten Schritt werden die erkannten Muster und Kausalzusammenhänge interpretiert und visualisiert. Dazu gehört auch die Weitergabe der Informationen oder die Überführung der Ergebnisse in ein anderes System für weitere Maßnahmen, beispielsweise Wissensmanagement oder Qualitätssicherung.

Es ist durchaus möglich, dass ein erster Durchlauf keine verwertbaren Ergebnisse erzielt. Der häufigste Grund dafür sind fehlende Daten, die zunächst durch eine penible Analyse der Datensammlung identifiziert werden sollten. Zudem müssen die aus den Ergebnissen abgeleiteten Schlussfolgerungen in der Praxis bestätigt werden, um sicherzustellen, dass die Ursache korrekt identifiziert ist. Auch hier können wieder fehlende Daten oder nicht ausreichende Analysemethoden der Grund sein.

### Analytics-Anwendungen in der Industrieproduktion

Diese Überlegungen zeigen, dass Manufacturing Analytics eine komplexe und umfangreiche Aufgabe ist, aber auch zu verblüffenden Erfolgen führen kann.

Folgendes Beispiel verdeutlicht dies: Ein Zulieferer von Hochdruckpumpen für Pkw-Motoren bekam zu einer in Großserie hergestellten Pumpe negative Rückmeldungen. Bei einigen Pumpen komme es nach einiger Zeit zu Abrieb an einem rotierenden Teil, sodass die Fahrer vorzeitige Reparaturen an ihren Wagen hatten.

In der Linienprüfung war dieses Problem nicht erkannt worden. Zudem war es nicht möglich, anhand der Maschinen- und Bauteilgeometrie die Ursache zu erkennen. Wesentliche Hilfe brachten erst eine umfangreiche Datenerhebung und der Einsatz von Verfahren der Predictive Analytics. Mit Machine Learning konnte Staufen Quality Engineers GmbH ein Vorhersagemodell entwickeln, das fehlerhafte Pumpen zuverlässig erkennt.

Ein weiteres Beispiel zeigt, dass Manufacturing Analytics auch schwer einzuschätzende Herstellungsfehler aufdeckt. Ein Spezialist für Lenksysteme hatte in einem seiner Produkte Qualitätsprobleme, die bei den Fahrern der Autos für subjektives Missempfinden sorgen: Sie beschwerten sich über Geräusche und schwergängiges Lenkverhalten durch „Reibung“. In der Herstellung messbar sind solche Qualitätsprobleme nicht.

Da ein Lenksystem ein sehr komplexes Produkt ist, ist auch der Herstellungsprozess komplex – einfache Qualitätstechniken helfen hier nicht weiter. Das Unternehmen setzte verschiedene Verfahren von Diagnostic Analytics ein, um den Kausalzusammenhang zwischen Herstellungsprozessen und Qualitätsproblemen aufzudecken. Dies gelang dem



Unternehmen, und in einem weiteren Schritt könnte die Firma nun dazu übergehen, mit Machine Learning (Predictive Analytics) das Auftreten von Fehlern vorherzusagen.

## Sechs grundlegende Best Practices für Manufacturing Analytics

Der Weg zu solchen Verbesserungen in der Produktionsqualität ist allerdings steinig, einfache Lösungen sind kaum möglich. Unternehmen in der herstellenden Industrie sollten deshalb bei der Einführung von Manufacturing Analytics schrittweise und strategisch vorgehen. Bewährt haben sich die folgenden „Best Practices“:

### ■ Zielbild

Das Unternehmen braucht eine genaue Vorstellung davon, welches Ziel es mit den Daten verfolgt. Will es Transparenz schaffen, Anomalien erkennen, Störungen vorhersagen oder Fehlerbehebungsprozesse automatisieren?

### ■ Datenbilanz

Entscheidend ist ein genaues Wissen darüber, welche Daten bereits vorhanden sind, wo sie sich befinden und welche möglicherweise zusätzlich neu ermittelt werden müssen – etwa durch Sensorik.

### ■ Datenbank

Die genutzte Technologie und die Struktur der für die Analyse genutzten Datenbank hängt stark von den genutzten Systemen ab. Hier muss jedes Unternehmen eine individuelle Entscheidung treffen. Wenn sich die relevanten Daten in unterschiedlichen Datenbanken mit voneinander abweichenden Formaten befinden, ist es sinnvoll, eine übergreifende Datenbankarchitektur zu definieren und die Daten in das neue Format zu konvertieren.

### ■ Infrastruktur

Die IT-Infrastruktur muss an die gewünschte Einsatzbreite von Manufacturing Analytics angepasst werden. So sind für Sensoren Cloud-basierte IoT-Plattformen notwendig. Empfehlenswert ist der Einsatz von RPA-Anwendungen (Robotic Process Automation), um zeittressende Handarbeit bei der Datenaufbereitung zu eliminieren.

### ■ Software

Kern von Manufacturing Analytics ist eine Plattform, die sämtliche Daten

auswerten kann. Entscheidend für die Auswahl der Software ist die Eignung für die Industrieproduktion. Für die Automobilbranche empfiehlt S.O.E die AppliedIT-Plattform. Gründer und Entwickler verfügen über langjährige Erfahrung und Spezialwissen in der technischen Problemlösung für Großunternehmen.

### ■ Schulung

Wissen und Fähigkeiten der Mitarbeiter sind entscheidend für den Erfolg von Manufacturing Analytics. Alle mit dem Projekt befassten Mitarbeiter benötigen das entsprechende Domänenwissen, ein genaues Verständnis aller Prozesse und eine gute Kenntnis sämtlicher eingesetzter Softwarewerkzeuge. Erfolgsentscheidend ist darüber hinaus die Anwendung einer gemeinsamen Methodik, die das Team strukturiert und systematisch durch die Datenanalyse begleitet. Hier sind Problemlösungsmethoden wie Six Sigma oder Shainin als Beispiele für komplexe Problemstellungen zu nennen.

## Manufacturing Analytics verbessert die Produkt- und Prozessqualität

Die vier Reifegrade von Manufacturing Analytics bauen aufeinander auf. Die entsprechenden Anwendungen schaffen Transparenz, erkennen Ursachen, treffen Vorhersagen und automatisieren Reaktionen. Unternehmen können damit komplexe Probleme in der Qualitätssicherung aufdecken. Der Einsatz bewährter Qualitätstechniken wird aber nicht obsolet. Manufacturing Analytics ist eher als digitale Ergänzung und Erweiterung zu verstehen. Es kann jedoch der effizienten Produktion und der Produktqualität einen deutlichen Schub geben. In der Vergangenheit waren viele Störungen und Fehler nur mühsam aufzudecken oder mussten sogar hingenommen werden – teure Produktionsstillstände und Rückrufaktionen waren die Folge. Diese können mithilfe von Manufacturing Analytics künftig vermieden werden.

### ■ Literatur

1. Halvorsen, L.: A Comprehensive Model For Manufacturing Analytics. Presented at the WBF North American Conference Atlanta, GA March 5-8, 2006
2. Beßle, J.: Manufacturing Analytics for Quality Enhancement in Manufacturing Companies. Masterthesis, TH Darmstadt 2018

3. Tao, F. et al.: Data-driven Smart Manufacturing. *Journal of Manufacturing Systems* 48 (2018), S. 157 – 169  
DOI: 10.1016/j.jmsy.2018.01.006
4. Schuh, G. et al. (Hrsg.): *Industrie 4.0 Maturity Index. Die digitale Transformation von Unternehmen gestalten.* acatech STUDIE, Herbert Utz Verlag, München 2017
5. Gröger, Chr.: *Building an Industry 4.0 Analytics Platform.* *Datenbank-Spektrum* 18 (2018) 1, S. 5 – 14
6. Fayyad, U.; Piatetsky-Shapiro, G.; Smyth, P.: *From Data Mining to Knowledge Discovery in Databases.* *AI Magazine* 17 (1996) 3, S. 37–54

### ■ Die Autoren dieses Beitrags

Amir Cviko unterstützt Kunden als Berater weltweit in Projekten bei Lean Production und technischen Problemlösungen. Fachliche Schwerpunkte sind die Restrukturierung und die Gestaltung von ganzheitlichen Produktions- und Logistikprozessen und der Aufbau und die Entwicklung von Qualitätssystemen – insbesondere die reaktive und präventive technische Problemlösung. Ein weiterer Schwerpunkt seiner Arbeit ist die Vermittlung von praxisnahem Methodenwissen in Schulungen und Coaching. Amir Cviko leitet seit 2014 das Team der Staufen Quality Engineers GmbH und ist seit 2018 Geschäftsführer der Tochtergesellschaft der Staufen AG.

Tobias Böing hat bereits während seines Studiums Erfahrungen und Kenntnisse zu Lean Methoden und Produktionsplanung in der Zuliefererindustrie bei Continental und bei Bosch Rexroth gesammelt. Durch seine Masterarbeit am Institut für Produktionsmanagement, Technologie und Werkzeugmaschinen an der Technischen Universität Darmstadt über Industrie 4.0 und Problemlösungsprozesse hat er sich ein wissenschaftlich fundiertes Fachwissen in diesen Themengebiete angeeignet. Seit 2018 arbeitet Tobias Böing als Berater bei der Staufen AG.

### ■ Summary

**Manufacturing Analytics in Production – Identifying Complex Quality Assurance Problems.** Manufacturing Analytics (MA) is the holistic, cross-process analysis of production data to understand and improve production processes. To do this, companies need a comprehensive data collection that captures all existing data sources and also takes invisible data into account. The analytic methods create transparency, identify causes, make predictions and automate reactions. Companies thus uncover complex problems in quality assurance.

### Bibliography

DOI 10.3139/104.112063

ZWF 114 (2019) 4; page 230–233

© Carl Hanser Verlag GmbH & Co. KG

ISSN 0032-678X