



Schlau statt groß

Smart Data zur Qualitätsabsicherung entlang des Produktlebenszyklus

Daten generieren und sammeln ist für Unternehmen kein Problem. Schwieriger ist es, aus der Menge von „Big Data“ nützliche Informationen abzuleiten und mit den Daten die Qualität präventiv abzusichern. Wissenschaftler der TU Berlin entwickeln aktuell eine Datenbank, in der Daten gesammelt und so abgelegt werden können, dass Probleme frühzeitig erkannt und standardisiert Handlungsbedarfe abgeleitet werden können.

Robert Dust, Marietta Balschun und Anja Wilde

In den letzten zwei Jahren entstanden 90 Prozent der derzeit global vorhandenen Daten. Diese großen, komplexen und dynamischen Datenmengen gilt es zu verarbeiten. Für Unternehmen ist Big Data damit ein herausforderndes Thema. Dabei

steht weniger das Speichern als vielmehr die Abrufbarkeit der Daten im Vordergrund. Eine effiziente Datenanalyse ermöglicht das Filtern der Datenmenge und schafft die nötige Transparenz für das Erkennen von Wirkungszusammenhängen.

Voraussetzung dafür ist eine valide Datenbasis, auf der die Datenanalyse erfolgen kann. Wissenschaftler der TU Berlin entwickeln derzeit ein Konzept, um Datenmanagement effizienter zu gestalten. Damit sollen Unternehmen die Potenziale >>>

von Big Data für das Qualitätsmanagement besser nutzen können.

Unternehmen speichern kontinuierlich große Datenmengen. Doch sind die erhobenen Daten die richtigen? Und was sagen diese Daten aus? Big Data kann aufgrund von irrelevanten Informationen schnell zu Datenmüll führen. Bei Smart Data werden weniger, aber dafür aussagefähige Daten für die Entscheidungsfindung bereitgestellt. Smart Data ist deshalb besser als Entscheidungsgrundlage geeignet als Big Data.

Smart Data zur Risikoerkennung

Wer Handlungsfelder im Unternehmen frühzeitig identifizieren will, muss die Qualitätsdaten entlang des Produktlebenszyklus präventiv erfassen. Verschiedene Fachbereiche eines Unternehmens verwenden jedoch in der Regel unterschiedliche IT-Systeme (z. B. Entwicklung, Qualität, Einkauf und Logistik). Daher gibt es bisher selten fachbereichsübergreifende Datenbanken für alle unternehmensinternen und -externen Informationen und damit auch keine einheitliche Datengrundlage. Das erschwert ihre Belastbarkeit, und es stellt sich insbesondere die Frage, ob die Daten stets korrekt und aktuell sind.

Das Fehlen einer bereichsübergreifenden Datenbank führt beispielsweise dazu, dass keine Prognosen zu Schadteilausfällen realisiert werden können. Daher sind aussagekräftige, fachbereichsübergreifende Daten notwendig, die zur richtigen Zeit an der richtigen Stelle zur Verfügung ste-

hen. Aus den Unternehmensdaten muss ein ganzheitliches Wissen generiert werden. Qualitätsprobleme werden dann frühzeitig erkannt und geeignete Maßnahmen abgeleitet und umgesetzt.

Das Ziel ist ein Regelprozess im Lebenszyklus des Produkts (Product-Lifecycle-Prozess). In diesem sollen durch Wissen aus Smart Data Qualitätsprobleme abgeleitet und dann standardisiert ein Handlungsbedarf beschrieben werden (Bild 1). Erfasst werden sowohl Daten aus der Vergangenheit als auch aus der Gegenwart. Daten aus der Produktentstehung, der Serie und dem Einsatz des Produkts im Feld (interne Daten) werden zentral zusammengeführt. Auch die Hinzuziehung von Lieferantendaten (externe Daten) ist vorgesehen. Mithilfe von Mustererkennung in Datensätzen werden Prognosen erstellt und das Wissen aus den Daten und der Mitarbeiter in Form von Lessons Learned für das ganze Unternehmen zur Verfügung gestellt.

Lebenszyklus effizient absichern

Die Speicherung aller Lifecycle-Daten findet in einer ganzheitlichen Datenbank statt, die sich dadurch auszeichnet, dass die Plausibilität und Verfügbarkeit relevanter Qualitätsdaten von einem Data Checker geprüft werden. Im Zuge dieser Überprüfung werden die Daten auf formale, logische und statistische Kriterien untersucht. So werden eine Bündelung von Erfahrungen und ein bereichsübergreifender Wissenstransfer in allen Phasen des Produktlebenszyklus er-

möglicht. Die standardisierte Auswertung der Daten bietet eine Grundlage zur Problemlösung und zur transparenten Entscheidungsfindung.

Um diesen Prozess zur zentralen Erfassung und Weitergabe von Lifecycle-Daten umsetzen zu können, bedarf es verschiedener Methoden der Datenanalyse.

Datenbank

In der intelligenten und ganzheitlichen Datenbank lassen sich alle erhobenen Daten speichern, vernetzen und in Abhängigkeit zueinander setzen. Wissenselemente oder Verknüpfungen können durch die Benutzer oder von der Datenbank selbst mithilfe von künstlicher Intelligenz erstellt werden.

Data Checker

Die notwendige Voraussetzung für die Datenbank ist eine robuste Datengrundlage. Oftmals verlassen sich Unternehmen auf die Daten in ERP-Systemen, ohne deren Informationsinhalte zu hinterfragen.

Der Data Checker umfasst die Überprüfung der Datenverfügbarkeit, -plausibilität, -validität und -aussage (Bild 2, Teil A). Hierfür werden die vorhandenen Daten in ein Analysemodell importiert und durchlaufen standardisierte Auswertungsmethoden [1].

Eine Plausibilisierung von Grunddaten prüft die logische Verknüpfung von Informationen (logischer Data Checker). Datensätze aus unterschiedlichen Systemen müssen dabei konsistent sein. Ist gewährleistet, dass die Daten aus unterschiedlichen Anwendungen sich nicht widersprechen, liegt eine gute Datenqualität vor. Ist ein Datensatz statistisch, also aufgrund von Werten aus der Vergangenheit, nicht zu erklären, kann er als auffällig gekennzeichnet werden (statistischer Data Checker). Dann wird die Ursache analytischer Extremwerte in den Kennzahlen erörtert. Eine formale Kontrolle erlaubt die Bereinigung von Inhalten, die nicht dem gewünschten Datenformat entsprechen (formaler Data Checker). Eine manuelle Dateneingabe birgt dabei das höchste Fehlerpotenzial. Ein einfaches Beispiel ist die Eingabe eines Datums in ein System. Hier sollte das Datum korrekt sein und in dem vom System vorgegebenen Format eingetragen werden. Die Aussage der Daten wird durch die Konzeptionierung des

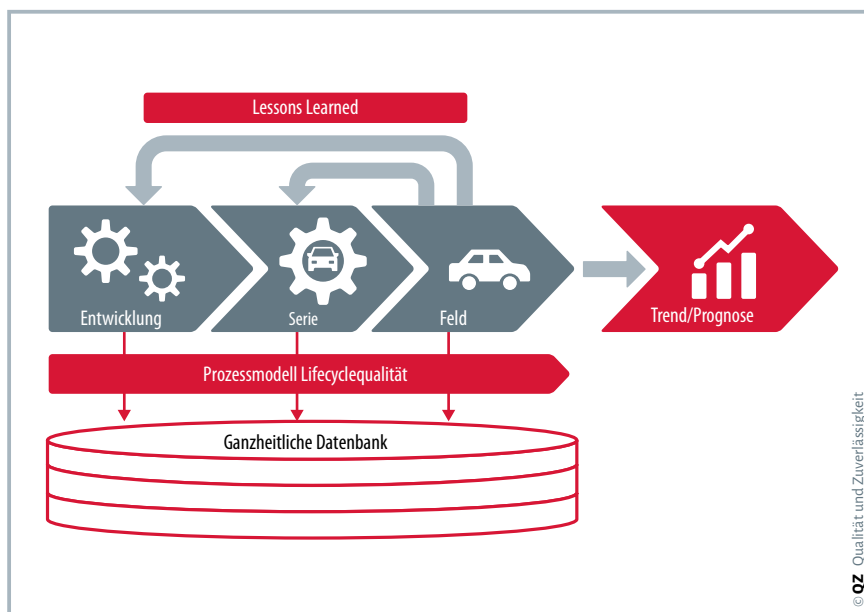


Bild 1. Prozess zur zentralen Erfassung und Weitergabe von Daten des Lebenszyklus

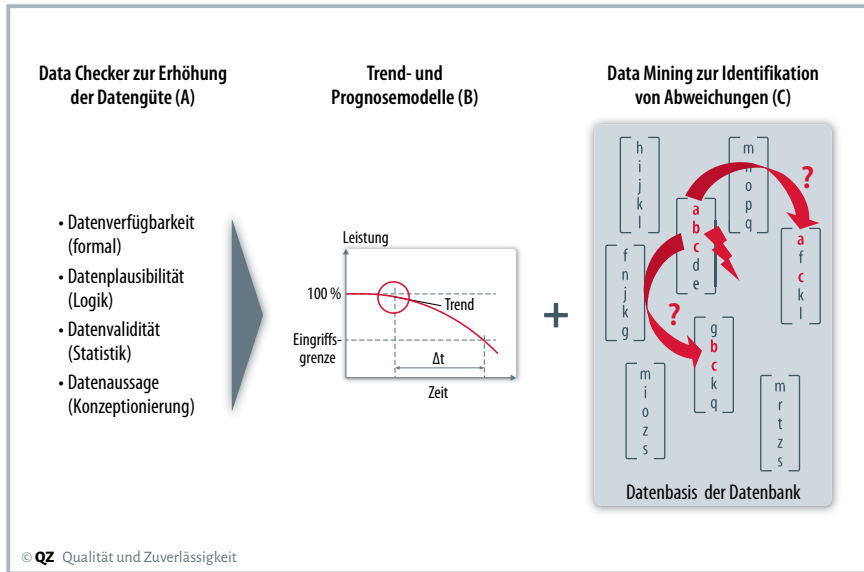


Bild 2. Konzept des Daten-Checks sowie der anschließenden Datenauswertung

Datensatzes analysiert (konzeptioneller Data Checker). Innerhalb der strategischen Vorgehensweise wird der Data Checker einmalig genutzt, beispielsweise zur Erstellung einer Kennzahl.

Trend und Prognose

Bisher generieren Unternehmen nur wenig Wissen aus ihren Daten. Außerdem betrachten sie fast ausschließlich Daten aus der vergangenen oder aktuellen Zeitperiode. Es ist jedoch möglich, mithilfe von Trendanalysen und Prognosen präventiv Wissen aus Smart Data abzuleiten [2]. Dabei ist u. a. eine regelmäßige Bewertung der Lifecycle-Qualität erforderlich. Trend- und Prognosemodelle bieten dabei eine Entscheidungsgrundlage für den präventiven Einsatz geeigneter Eskalationen, da die Informationen bei einer Verschlechterung der Performance frühzeitig generiert werden können (Bild 2, Teil B). Die Fachbereiche warten somit nicht mehr, bis eine Eingriffsgrenze erreicht ist, um die notwendigen Maßnahmen einzuleiten.

Data Mining

Data Mining ermöglicht es, Wissen über die Lifecycle-Qualität durch Korrelationen von Daten in einem Risikomuster zu generieren. Sind alle unternehmensrelevanten Daten zusammengetragen, werden Muster in der Datenbasis zur präventiven Risikoabschätzung mithilfe von mathematischen Algorithmen gesucht. Ist ein Muster auffällig, können frühzeitig Rückschlüsse auf mögliche Risiken innerhalb des Lifecycles

gezogen werden. Dabei werden Muster in der Datenbasis zur präventiven Risikoabschätzung verglichen. Ist ein Muster aufgefallen, können frühzeitig Rückschlüsse auf mögliche Risiken bei anderen Produkten mit einem gleichen oder ähnlichen Musteranteil gezogen werden, die noch nicht negativ in Erscheinung getreten sind (Bild 2, Teil C). Mit diesem Wissen wird ein Mehrwert durch frühzeitige Handlungsfähigkeit für alle Fachbereiche generiert. Herkömmliche dezentrale Methoden decken diese Risikoprävention nicht ab.

Langfristig wettbewerbsfähig

Eine ganzheitliche Lebenszyklus-Datenbank als Schlüsselement des unternehmensinternen Informationsaustauschs erleichtert die Risikoabschätzungen für Prozesse, Projekte und Produkte durch das Verknüpfen von Wissen.

Gleichzeitig führt die Vernetzung aller zur Verfügung stehenden Daten und Informationen zu einem bereichsübergreifenden Wissen und ermöglicht die Transparenz von internen und externen Vorgängen. Das generierte Wissen eignet sich als Entscheidungsgrundlage zur effizienten Steuerung des gesamten Unternehmens und trägt zum Unternehmenserfolg bei. Mit dieser belastbaren Entscheidungsgrundlage können präventiv Maßnahmen zur Absicherung der Produkte und Prozesse eingeleitet werden. Die Datenbank und die dahinterliegenden Prozesse werden aktuell als Pilotprojekt mit Industriepartnern aus verschiedenen Branchen erarbeitet. ■

INFORMATION & SERVICE

LITERATUR

- 1 Dust, R.; Wilde, A.: Datenqualität im Lieferanten-Risikomanagement. ERP Management 3/2015, S. 35-37
- 2 Dust, R.; Gleinser, M.; Gürtler, B.: Total Supplier Risk Monitoring – Lieferfähigkeit präventiv absichern. Management und Qualität 1-2/2010, S. 27-29

AUTOREN

Prof. Dr.-Ing. Robert Dust, Professor für Qualitätsstrategie und Qualitätskompetenz an der TU Berlin. Zuvor war er in leitender Position im Entwicklungs- und Einkaufsbereich von BMW, Rolls-Royce, Porsche und Mercedes-Benz tätig.

Marietta Balschun M. Sc., und **Dipl.-Ing. Anja Wilde** sind wissenschaftliche Mitarbeiterinnen am Fachgebiet Qualitätsstrategie und Qualitätskompetenz der TU Berlin.

KONTAKT

Marietta Balschun
T 030 314-24453
marietta.balschun@tu-berlin.de

QZ-ARCHIV

Diesen Beitrag finden Sie online:
www.qz-online.de/1410911