

Voraussetzungen, Herausforderungen und das richtige Projektvorgehen für den Maschinen- & Anlagenbau sowie die Fertigungsindustrie

# Datengetriebene Services erfolgreich entwickeln



Die Digitalisierung industrieller Produktionssysteme gewinnt immer mehr an Bedeutung. Data Analytics bietet vor allem Unternehmen aus dem stark vernetzten Maschinen- und Anlagenbau Chancen, innovative datenbasierte Dienstleistungen zu entwickeln und zu vermarkten. Aber wie sieht eine praxiserprobte Vorgehensweise aus, welche zentralen Herausforderungen gilt es zu meistern?

Um erfolgreiche Digitalisierungsideen zu entwickeln und umzusetzen, bedarf es in Unternehmen neuer Strukturen der Zusammenarbeit und des Denkens. Denn die Generierung neuer digitaler Produkte und Geschäftsideen kann nicht aufgezwungen werden, sie entsteht durch die Arbeit interdisziplinärer Teams (Digital Units), welche Digitalisierungsthemen unternehmensspezifisch erforschen und umsetzen. Pfiffige Ideen zur Lösung komplexer Probleme, eine gute Intuition für zukünftige Entwicklungen, eine offene, nutzenbasierte Kommunikation zur Vermarktung der Ideen im Unternehmen und beim Kunden sowie eine agile Arbeitsweise zur dynamischen Anpassung der Entwicklungen an die sich stetig verändernden Gegebenheiten spielen in diesem Schaffensprozess die zentralen Rollen.

Die zentrale Aufgabe des Managements ist es, Rahmenbedingungen zu schaffen, innerhalb derer die Zusammenarbeit der beteiligten Gruppen stattfinden kann, sowie die Interaktion zwischen Digital Units und den operativen Bereichen zu fördern. Zudem muss das Management dafür sorgen, dass geeignetes Personal rekrutiert und vorhandene Mitarbeiter weitergebildet werden.

**Komplexe Use Cases mit Hilfe von Smart Services umsetzen.** Um herauszufinden, ob datenbasierte Services in einem Unternehmen Potenzial haben, hat es sich bewährt, kleinere Pilotprojekte anhand konkreter Use Cases durchzuführen. Use Cases im Kontext

von Big Data Analytics sind Anwendungsfälle, in denen Informationen aus großen Mengen unstrukturierter Daten extrahiert und zur Generierung neuer Produkte und digitaler Geschäftsmodelle verwendet werden. Dabei sind die Formen der Produkte und Geschäftsmodelle außerordentlich vielfältig: vom automatischen Erkennen von Maschinenfehlern und dem anschließenden Anfordern des für den Fehlerfall am besten geeigneten Service-Technikers über Systeme, welche die optimale Maschinenkonfiguration zur Minimierung des Energieverbrauchs berechnen, bis hin zu KI-unterstütztem Condition Monitoring zur Überwachung der zeitlichen Entwicklung von Zuständen kritischer Maschinenkomponenten.

Die Umsetzung von Use Cases wird mit Hilfe von Smart Services realisiert. Smart Services bestehen in ihrem Kern aus Analysealgorithmen, die aus Daten nutzbringende Informationen extrahieren. Sie lassen sich je nach Aufgabengebiet in technische, wirtschaftliche und vertriebliche Smart Services kategorisieren. In der Regel verschmelzen innerhalb eines Use Case technische, wirtschaftliche und vertriebliche Smart Services, was neue kombinierte Wertangebote schafft (siehe Abbildung 1).

Zum Beispiel berechnen technische Smart Services aus Sensordaten Kenngrößen für den Qualitätszustand einzelner Maschinenkomponenten, welche anschließend durch wirtschaftliche Services aggregiert werden. In ihnen können durch Berücksichtigung weiterer Daten, beispielsweise von Maschinenparametern, neue Wertangebote geschaffen werden. Dies kann zum Beispiel die Berechnung der optimalen Maschinenkonfiguration zur Minimierung des Verschleißes sein. Je nach Funktion können Smart Services auch zeitgleich in mehreren Use Cases verwendet werden. Daher empfiehlt es sich, sie so zu gestalten, dass sie sich leicht in schon bestehende Analyse-Netzwerke integrieren lassen.

**Die Konzeption von Use Cases.** Ein Erfolg versprechender Use Case muss echten Mehrwert schaffen. Zu Beginn der Konzeption erster Ideen empfiehlt es sich daher, sämtliche Randbedingungen und Bedenken zur Machbarkeit auszublenden und sich einzig allein auf die Frage zu konzentrieren,

welche datengetriebene Produkte und Geschäftsmodelle der Kunde beziehungsweise das eigene Unternehmen wirklich benötigt beziehungsweise welche Modelle in Zukunft relevant sein könnten. Die Entwicklung von Use Cases, die nur auf Daten

basieren, funktioniert im Allgemeinen nicht. Sinnvolle Use Cases entspringen der realen Arbeitswelt. Da Use Cases in der Regel aus mehreren kontextspezifischen Smart Services bestehen, ist es bei der Entwicklung von Ideen und Lösungsansätzen unerlässlich, Mitarbeiter aus verschiedenen Domänen zusammenzuführen. Das Wissen über interne Prozesse und deren Schwachstellen, Hintergrundwissen über Kunden und deren Bedürfnisse, technisches Fachwissen, strategisches Wissen sowie eine gehörige Portion Kreativität sind die Erfolgsfaktoren für die Konzeption von guten Use Cases. Im Idealfall ist das Resultat eine Auswahl von Use Cases sowie deren Ranking nach Relevanz. Unzureichende Unterstützung durch die Geschäftsführung sowie fehlendes Verständnis und mangelnde Akzeptanz von Mitarbeitern sind nennenswerte Risikofaktoren. Deshalb sollte das Ranking von allen Verantwortlichen akzeptiert und die Use Cases innerhalb des Unternehmens aktiv beworben werden.

Die beste Use-Case-Idee bringt nichts, wenn sie nicht realisierbar ist. Fallstricke in der technischen Umsetzung eines Use Cases kann es sowohl

bei der Implementierung der IT-Infrastruktur als auch in der Entwicklung geeigneter Analysesysteme geben. Aus Analysesicht ist eines der häufigsten Hindernisse ein zu geringer Informationsgehalt in den Daten. Um dies frühzeitig zu erkennen, empfiehlt es sich, dem Projekt eine Forschungsphase vorzuschalten. Ziel dieser Phase muss es sein, zu verstehen, ob in den Daten die nötigen Informationen zur Umsetzung des Use Cases enthalten sind. Da hierzu Domänen- und Data-Science-Wissen in gleichem Maße von Bedeutung ist, findet die Phase in enger Kooperation zwischen Fachexperten und Data Scientisten statt. Zeigt sich in den Untersuchungen, dass der Informationsgehalt der Daten nicht ausreicht, muss die Datenlage durch geeignete Maßnahmen verbessert werden. Je nach Use Case kann dies beispielsweise durch die Verwendung zusätzlicher Datenquellen oder durch eine verbesserte, dem Use Case angepasste Sensorik erfolgen. Auch die Entwicklung alternativer Lösungsstrategien ist ein probates Mittel. Kann keiner der Ansätze die Probleme lösen, bleibt nichts anderes übrig, als das Projekt aufzugeben und sich dem nächsten Use Case zu widmen. Dies sollte jedoch nicht zu leichtfertig geschehen, da mit abnehmendem Ranking auch der Impact der

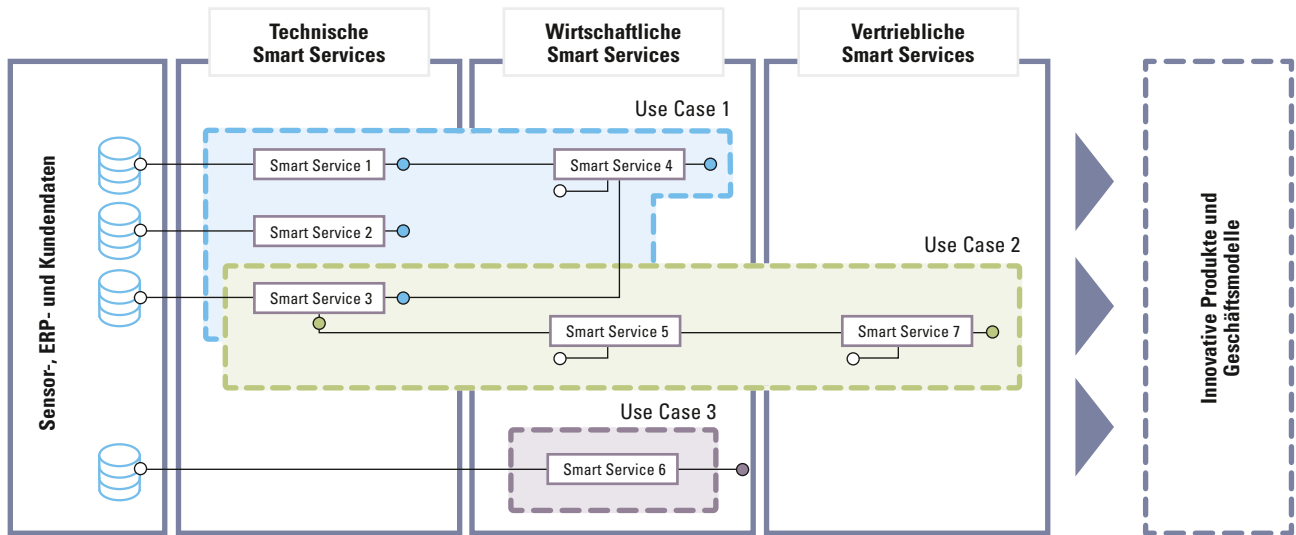
Use Cases und somit deren Relevanz für die Kunden abnimmt. Gerade aus strategischer Sicht wird damit eine erfolgreiche Umsetzung weniger wahrscheinlich.

Use Cases müssen sich unmittelbar an den Gegebenheiten und Anforderungen des Kunden ausrichten. Dies gilt sowohl für den direkten Mehrwert, welcher durch den Use Case generiert wird, wie auch für die Integrierbarkeit in die schon bestehenden Arbeitsabläufe. Wenn eine datengetriebene Lösung nicht praktikabel in den Arbeitsalltag integriert werden kann, kann ihr Mehrwert nicht realisiert werden. Spielen Kundendaten für die Entwicklung und Nutzung der Use Cases eine Rolle, ist



## Netzwerk von Smart Services

Quelle: USU



**Abbildung 1:** Schematische Darstellung eines Netzwerks von Smart Services. Smart Services extrahieren aus Sensor-, ERP- und Kundendaten (grau) hochverdichtete kontextbezogene Informationen (grün), welche die Basis für intelligente Produkte und Geschäftsmodelle sind.

es wichtig zu prüfen, ob eine genügend große Anzahl von Kunden dazu bereit ist, die notwendigen Daten zur Verfügung zu stellen. Erfahrungsgemäß zeigt sich jedoch, dass Kunden, die die Mehrwerte datengetriebener Ansätze verstehen und für sich erkennen, auch dazu bereit sind, sich neuen Produkten und Geschäftsmodellen zu öffnen.

Um Use Cases im Zuge der Unternehmensdigitalisierung immer effizienter entwickeln zu können, sollten die dem Use Case zu Grunde liegenden Smart Services intelligent modularisiert werden. Sollen beispielsweise in einem Anwendungsfall Maschinendaten mit dem Ziel analysiert werden, Kunden Empfehlungen für eine verbesserte Maschinenutzung zu geben, sollte man sich die Frage stellen, ob sich Zwischenergebnisse in einen Mehrwert für die eigene Produktion übersetzen lassen. Ist dies der Fall, ist es ratsam, die Berechnung der Zwischenergebnisse in eigene Services zu verpacken. Eine starke Modularität hat zusätzlich den positiven Ne-



benefekt, dass sich Fehler leichter identifizieren lassen. Außerdem lässt sich künstliche Intelligenz in Form von trainierten Modellen maschineller Lernverfahren einfacher anpassen und warten.

**Die Qualität der Daten.** Der zentrale Bestandteil eines jeden Big-Data-Analytics-Projekts sind Daten. Die reine Menge der Daten spielt für den Erfolg eines Projekts jedoch nur eine untergeordnete Rolle. Vielmehr ist die Qualität der Daten erfolgskritisch. Aber was bedeutet Qualität in Bezug auf Daten? Der Qualitätsbegriff macht erst in Kombination mit dem konkreten Anwendungsfall Sinn und beschreibt, ob genügend Informationen in Form von Trends, Mustern und Zusammenhängen in den Daten enthalten sind, um die Umsetzung des Use Cases zu gewährleisten. Dabei wird die Menge an Informationen einerseits durch die Wahl der Datensätze beziehungsweise Messgrößen bestimmt, andererseits durch den

Messprozess selbst. Will man beispielsweise den Verschleißzustand eines Lagers durch Vibrationsmessungen bestimmen und positioniert den Sensor zu weit entfernt vom Lager, ist die Gefahr groß, dass der eigentliche Verschleißprozess nur schwach erfasst wird und sich bei der Messung zusätzlich störende Vibrationen überlagern. Selbst wenn sich Teile des Rauschens nachträglich aus dem Signal filtern lassen, führen sie im Allgemeinen zu Fehlern in den Ergebnissen. Gerade in komplexen Analysenetzen können sich diese in anderen Analyseschritten fortsetzen und potenzieren, was Ergebnisse verfälscht und die Robustheit des gesamten Analysesystems reduziert. Daher ist es wichtig, dass das Finden einer optimalen Messkonfigu-

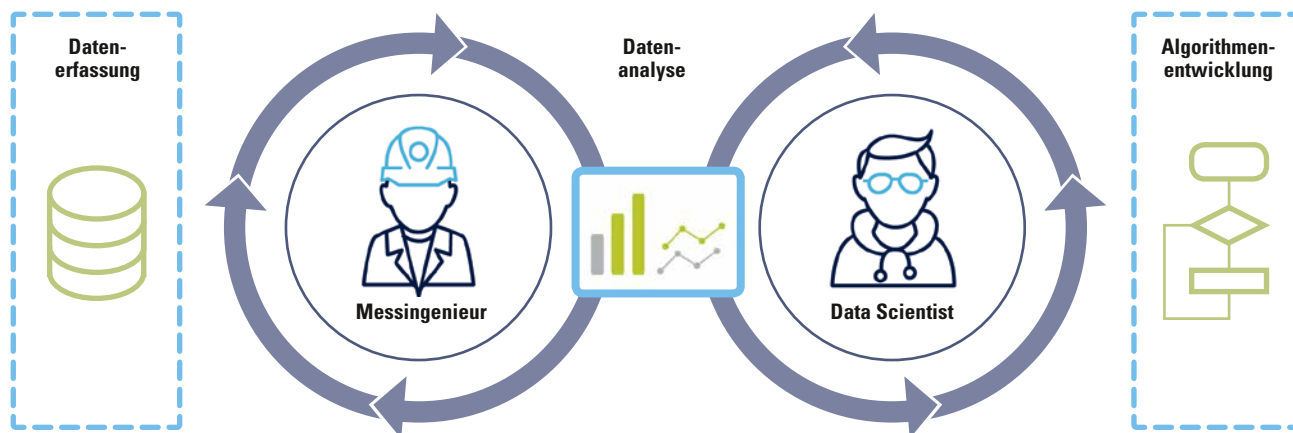
### Whitepaper Download

Dieser Artikel ist ein Auszug aus einem umfangreichen Whitepaper, das hier heruntergeladen werden kann:

<http://bit.ly/2Js2vJO>

## Identifikation von Use-Case-relevanten Daten

Quelle: USU



**Abbildung 2:** Prozess zur Identifikation von Use-Case-relevanten Daten. Nach der Datenerfassung wird mit Hilfe explorativer Ansätze und erster Prototypen untersucht, ob die Daten zur Umsetzung des Use Cases geeignet sind. Ist dies der Fall, erfolgt die Entwicklung des KI-basierten Analysealgorithmus. Eignen sich die Daten nicht, müssen neue Daten erfasst und analysiert werden. Dieser Prozess erfolgt so lange, bis die erforderlichen Messgrößen und Datensätze zur Realisierung des Use Case identifiziert wurden.

ration als ein aktiver wissenschaftlicher Prozess verstanden wird, in dem Messingenieure und Domänenexperten durch Data-Science-Know-how unterstützt werden. Zur Identifikation der richtigen Daten sollten daher Messtechnik und Data Science Hand in Hand gehen. Gleichzeitig sollte die IT-Infrastruktur so aufgebaut sein, dass der Datenaustausch zwischen verschiedenen Unternehmensbereichen möglich ist, so dass Data Scientists und Domänenexperten ein möglichst allgemeines Bild über die zur Verfügung stehenden Daten erhalten.

Konnten die für die Realisierung des Use Case relevanten Datensätze und Messgrößen identifiziert werden, erfolgt im nächsten Schritt die algorithmische Umsetzung der in der Analysephase entwickelten Lösungsstrategie. Wichtig anzumerken ist, dass es keine universellen Lösungsformeln und Algorithmen gibt, um einen Use Case umzusetzen. Es ist vielmehr das Zusammenspiel von mathematischem Methodenwissen, Domänenwissen und Kreativität, die über den Erfolg der Umsetzung entscheidet. Wird eine Maschine oder Anlage modifiziert,

kann dies Auswirkungen auf die Eigenschaften der Messdaten haben. Dies hat im Allgemeinen zur Folge, dass trainierte Modelle ihre Gültigkeit verlieren oder der gesamte Analysealgorithmus nicht mehr anwendbar ist. Darum ist es bereits während der Entwicklung der Algorithmen notwendig, geeignete Sicherheitsmechanismen zu integrieren, welche Veränderungen in den Datenmerkmalen erkennen und Anwender warnen beziehungsweise neue Lernphasen automatisiert einleiten. Gleichsam sollte die Herkunft der Daten genau erfasst und Änderungen, beispielsweise hervorgerufen durch neue Maschinenkomponenten oder Datenmanipulationen, dokumentiert werden. Damit sind sie rückverfolgbar und können im Analyseprozess berücksichtigt werden.

**Fazit.** Big-Data-Analytics-Projekte erfordern aufgrund ihrer hohen Komplexität und Vielschichtigkeit eine neue Form der Zusammenarbeit. Dabei sind Kreativität sowie kooperatives, inter-

disziplinäres und agiles Arbeiten von zentraler Bedeutung. Damit Projekte erfolgreich umgesetzt werden können, müssen einerseits sinnhafte Use Cases zu Grunde liegen, andererseits die richtigen Daten und Analysealgorithmen sowie eine IT-Infrastruktur zur Verfügung stehen, die sowohl die Verarbeitung der Daten als auch die Bereitstellung der Ergebnisse passgenau ermöglichen. Des Weiteren hat es sich bewährt, Ressourcen für den Betrieb eigener Data-Analytics-Systeme bereitzustellen, damit die verwendete Hardware gewartet und Software stets auf dem neusten Stand gehalten werden kann.

Erfolgskritisch ist es ferner, sowohl Kunden als auch Mitarbeiter früh in die Entwicklung der Produkte und Dienstleistungen einzubeziehen. Denn schlussendlich entscheiden sie über den Erfolg oder Misserfolg der Lösung.

*Mike Bonny, Hanna Sotnikova,  
Saban Güzel, Sebastian Klapp*

USU Software AG