



- ■ ■ Internationale
- ■ ■ Bodensee
- ■ ■ Hochschule
- Labs



Data4KMU

Data Science für KMU leicht gemacht

Aktuelle Erkenntnisse und Lösungen

Inhaltsübersicht

Kapitel und Arbeitspakete (AP)

- **Editorial**
Seite 4 - 5
- **Projektumfeld - Die Internationale Bodenseehochschule (IBH)**
Seite 6 - 7
- **Das IBH-Lab KMUdigital**
Seite 8
- **Data Science für KMU (Data4KMU) - Projektaufbau und Methode**
Seite 9 - 11
- **AP1 – Daten und Data Science in KMU und Grossunternehmen: Wo stehen wir?**
Seite 14 - 33
- **AP2 – Data Science, Strategie und Wettbewerb**
Seite 35 - 57
- **AP3 – Data Science und Geschäftsmodelle**
Seite 59 - 67
- **AP4 – Data Science und Services**
Seite 69 - 79
- **AP5 – Data Science und Prozesse**
Seite 81 - 91
- **AP6 – Datenkompetenz in Organisationen**
Seite 93 - 109
- **AP7 – Data Science braucht Organisationskultur und Ganzheitlichkeit**
Seite 111 - 129
- **AP8 – Data Science veranschaulichen: Demonstrator**
Seite 131 - 141
- **Literaturverzeichnis**
Seite 143 - 150

Editorial

Daten verändern die Welt

Daten werden heute oft auch als das «neue Gold» bezeichnet. Denn die letzten Jahre haben gezeigt, dass Daten die Grundlage erstaunlicher unternehmerischer Erfolgsgeschichten sein können. Dabei ist die Arbeit mit Daten nicht grundlegend neu. Vielmehr geht es heute im Vergleich zu früher um nahezu unendlich grossen Mengen an Daten, die im Rahmen nahezu aller denkbaren Prozesse oder Schnittstellen gesammelt, gespeichert und ausgewertet werden können. Unter anderem beinhaltet dies Maschinendaten, unternehmensinterne Prozesse oder Daten über Kunden und den Markt, welche die Grundlage für lernende Systeme (Künstliche Intelligenz) bilden. Wir können heute davon ausgehen, dass künftig nicht mehr die technische Machbarkeit, sondern die menschliche Vorstellungskraft die Grenzen des Möglichen definiert.

Bekannt sind vor allem etliche Erfolgsgeschichten von Grossunternehmen, die ihr Geschäft auf Daten aufbauen. Etablierte KMU sind hingegen noch zögerlicher, mit Daten zu arbeiten und diese wertschöpfend einzusetzen. Diese Broschüre geht auf die besondere Situation von KMU im Umgang mit Daten und Data Science ein. Denn auch für KMU kann es lohnend oder sogar zwingend notwendig sein, sich mit dem Thema «Data Science» zu beschäftigen. Daten und Data Science bieten große

Chancen, sie können aber auch zu einer Bedrohung im Wettbewerb werden. Und, zu lange warten sollten KMU nicht, die Zeit drängt. Denn Geschwindigkeit ist einer der zentralen Wettbewerbsfaktoren im digitalen Zeitalter. Das IBH-Lab KMUdigital unterstützt KMU dabei, den herausfordernden Weg in eine digitale Zukunft schneller und einfacher zu gehen.

Diese Broschüre geht daher insbesondere auf die Rolle von Daten und Data Science für KMU in der Bodenseeregion ein. Sie stellt eine Zusammenfassung ausgewählter Erkenntnisse und Handlungsempfehlungen dar, die wir in einem zweijährigen Forschungsprojekt gemeinsam mit 16 Unternehmen aus der Bodenseeregion gewinnen konnten. Die Erkenntnisse sollen KMU bei der Nutzung von Daten anhand von Data Science unterstützen. Dabei ist es kein Ziel, dass KMU zu einem «kleinen Google» werden. Vielmehr braucht es KMU-spezifische Lösungen und Überlegungen, wie mit Daten sinnvoll, zielorientiert und ressourcenschonend umgegangen werden kann. Wie kann das aussehen? Welche Chancen, Herausforderungen und Lösungen bieten sich KMU vor dem Hintergrund ihrer besonderen Situation? Was muss dazu im Unternehmen verändert werden? Welche Unterschiede bestehen im Vergleich zu Grossunternehmen auf diesem Weg?

Diese und weitere Fragen stehen im Mittelpunkt des vorliegenden Projektberichts zum Einzelprojekt «Data Science für KMU leicht gemacht» oder kurz «Data Science 4 KMU» bzw. «Data4KMU», welches unter dem Dach des IBH-Labs KMUdigital in den Jahren 2018 bis 2019 durchgeführt wurde. Dazu werden Daten und Data Science aus mehreren Perspektiven betrachtet, die nicht unabhängig voneinander sind: Strategie und Geschäftsmodell, Services und Prozesse, Leadership, HRM und Organisation, Organisationskultur und Ganzheit-

lichkeit, sowie Technologie. Diese Perspektiven greifen wir in den nachfolgenden Kapiteln auf.

Die vorliegende Broschüre wäre ohne die wertvolle Unterstützung der Praxispartner des Projektes, des Managements des IBH-Labs KMUdigital sowie ohne die finanzielle Projektförderung durch die Internationale Bodenseehochschule (IBH) und Interreg nicht möglich gewesen. Ihnen allen gilt unser ganz besonderer Dank!



**Prof. Dr.
Petra Kugler,**
Fachhochschule
St.Gallen



**Dr.
Jürg Meierhofer,**
ZHAW School
of Engineering



Projektumfeld

Die Internationale Bodensee-Hochschule

30 Hochschulen – 4 Länder – 1 Verbund

Die Internationale Bodensee Hochschule (IBH) ist der grösste hochschulartenübergreifende Verbund Europas. Sie ermöglicht die Zusammenarbeit von 30 Hochschulen aus Deutschland, dem Fürstentum Liechtenstein, Österreich und der Schweiz in Forschung, Lehre und Transfer.

Die IBH unterstützt grenzüberschreitende Forschungsprojekte zu gegenwärtigen und zukünftigen Herausforderungen für den Bodenseeraum. Sie koordiniert den Dialog zwischen Wissenschaft und Praxis, fördert den wissenschaftlichen Nachwuchs, ermöglicht Innovationen in der Lehre und unterstützt gemeinsame Angebote der Hochschulservices.

Mit ihren Projekten leisten die IBH und ihre Mitgliedshochschulen einen international sichtbaren Beitrag für das regionale Innovationssystem Bodensee.

Weitere Informationen zur Arbeit der IBH finden Sie unter:

www.bodenseehochschule.org

Die IBH-Labs

Auf Initiative der IBH und der Internationalen Bodensee Konferenz (IBK) wurden 2017 drei IBH-Labs ins Leben gerufen.

Hierbei handelt es sich um Forschungs- und Innovationsnetzwerke von Hochschulen und Praxispartnern aus Wirtschaft und Gesellschaft aller Anrainerländer des Bodensees (A, CH, D, FL). Die IBH-Labs leisten einen nachhaltigen Beitrag zur Förderung des Wissens-, Innovations- und Technologietransfers und damit zur Standortattraktivität der Bodenseeregion.

Die Förderung der IBH-Labs erfolgt aus Mitteln des Interreg V-Programms «Alpenrhein-Bodensee-Hochrhein». Für die IBH bilden die Labs einen strategischen Schwerpunkt. Die thematische Ausrichtung der IBH-Labs orientiert sich an regional relevanten Themen und den Entwicklungspotenzialen der Bodenseeregion.

Die IBH-Mitgliedshochschulen starteten 2017 gemeinsam mit Praxispartnern folgende IBH-Labs:

- IBH Living Lab Active & Assisted Living
- IBH-Lab KMUdigital
- IBH-Lab Seamless Learning

Das IBH-Lab KMUdigital

Kompetenznetzwerk für Digitalisierung in KMU

Die Bodenseeregion als einer der wettbewerbsfähigsten und dynamischsten Wirtschaftsstandorte Europas zeichnet sich durch innovative Weltmarktführer, mittelständische Unternehmen und insbesondere kleine und mittlere Unternehmen (KMU) aus.



Das IBH-Lab KMUdigital bündelt die vorhandene Expertise rund um den See, um die Chancen und Auswirkungen für die KMU der Region ganzheitlich zu untersuchen. Dies betrifft den digitalisierten Produktionsvorgang an sich (Shopfloor), den Einfluss auf Geschäftsprozesse, den Wandel vom Produkt- hin zum Dienstleistungsanbieter; die Aus- und Weiterbildung sowie die Betrachtung der Rahmenbedingungen.

Sieben Konsortialpartner und drei Projektpartner aus drei Ländern erarbeiten dafür in sechs themenbezogenen Einzelprojekten anwendungsorientierte Antworten auf die Fragen:

- Wieviel Digitalisierung muss in die KMU?
- Wieviel Digitalisierung passt zu den KMU?

Durch den digitalen Wandel wachsen die Anforderungen an die Unternehmen, aus denen sich insbesondere für KMU Problemstellungen ergeben:

- Wie sehen adäquate Digitalisierungsstrategien für KMU aus?
- Wie können die Anforderungen an eine zukünftige Produktion erfüllt werden?
- In wieweit sind Organisationsstrukturen und Führungsmodelle anzupassen?
- Welche neuen Erwerbsquellen ergeben sich?
- Wie können KMU Innovationen vorantreiben?
- Welche politischen, rechtlichen und personalpolitischen Rahmenbedingungen müssen angepasst werden?

In sechs Einzelprojekten erarbeiten die Partner des IBH-Labs KMUdigital anwendungsorientierte Lösungen für und mit KMU:

- Digitale Agenda Bodensee (DAB)
- Nutzenbasierter Digitalisierungsnavigator (DigiNav)
- Internationale Musterfabrik Industrie 4.0 (i4Production)
- [Data Science \(Data4KMU\)](#)
- Digital Transformation Guide (DigiTraG)
- Digitale Landwirtschaft (DigiLand)

www.kmu-digital.eu

Data Science für KMU (Data4KMU)

Projektaufbau und Methode

Das Einzelprojekt «Data Science für KMU» wurde zwischen 01.2018 und 12.2019 unter dem Dach des IBH-Labs KMUdigital durchgeführt. Beteiligt waren die Zürcher Hochschule für Angewandte Wissenschaften (ZHAW), die FHS St.Gallen, Hochschule für Angewandte Wissenschaften (FHSG), die Fachhochschule Vorarlberg (FHV), die Hochschule Konstanz für Technik, Wirtschaft und Gestaltung (HTWG), sowie 16 KMU aus den Branchen Maschinenbau, Dienstleistung und IT-Beratung, die ihren Firmensitz in der Bodenseeregion haben (AT, CH, D).

Wir betrachten Daten und Data Science in KMU interdisziplinär und aus verschiedenen Perspektiven, die nicht unabhängig voneinander sind:

- Strategie und Geschäftsmodell
- Services und Prozesse
- Leadership, HRM und Organisation
- Organisationskultur und Ganzheitlichkeit
- sowie Technologie.

Das Projekt umfasste mehrere Arbeitsschritte, die aufeinander aufbauten: (1) Analyse der Literatur, (2) qualitative Datenerhebung bei den Praxispartnern, (3) quantitative Datenerhebung, (4) Datenanalyse und Erarbeitung von Lösungskonzepten.

Für Schritt 1, die Analyse der Literatur wurden insgesamt etwa 150 Studien sowie wissenschaftliche und praxisorientierte Artikel zu den Themen

Daten, Data Science, Big Data und verwandten Begriffen in Verbindung mit den oben aufgeführten Perspektiven ausgewertet. Auf der Grundlage der so erarbeiteten Ergebnisse konnten Forschungslücken, erste Vermutungen zu Zusammenhängen, sowie ein Fragenkatalog erarbeitet werden. Ein Interviewleitfaden konsolidierte alle Erkenntnisse. Für Schritt 2, die qualitative Datenerhebung, wurden im Frühjahr und Sommer 2018 Interviews mit 21 Personen aus 16 KMU (Praxispartner des Projektes) der Branchen Maschinenbau, Dienstleistung und IT-Beratung geführt. Alle Unternehmen haben ihren Firmensitz im Bodenseeraum und in mindestens einem der Länder Deutschland, Österreich, Schweiz. Die Interviews wurden anhand einer Inhaltsanalyse (z.B. Mayring, 1996, 2000) ausgewertet. Wichtige Erkenntnisse wurden in einem Katalog von Arbeitshypothesen zu den oben genannten Perspektiven zusammengefasst und verdichtet. Anhand von Schritt 3 konnten ausgewählte Hypothesen anhand eines Online-Fragebogens zwischen Oktober 2018 und Januar 2019 quantitativ überprüft werden. Knapp 300 Personen aus KMU und aus Grossunternehmen in Deutschland, Österreich und der Schweiz füllten den Fragebogen aus. Es wurden jedoch nicht immer alle Fragen vollständig beantwortet. Die Ergebnisse dieses Berichts bauen auf 111 vollständig ausgefüllten Fragebögen auf. Mehr als 70% der Antworten können KMU mit bis zu 250 Mitarbeitenden zugeordnet werden. Die Ergebnisse aller Analysen wurden im Anschluss daran in Schritt 4 zu möglichen Lösungskonzepten für KMU zusammengefasst.

Das vorliegende Dokument stellt ausgewählte Ergebnisse der gesamten Studie dar und zeigt auf, wo KMU in der Bodenseeregion aktuell im Hinblick auf Daten und Data Science stehen, mit welchen Chancen und Herausforderungen sie konfrontiert sind und wie Konzepte zum Umgang damit aussehen können. Die besondere Situation von KMU steht dabei stets im Mittelpunkt.

Ein spezieller Fokus ist dem Demonstrator (AP8) gewidmet. Mit Hilfe eines Demonstrators für je einen Cloud- und Edge-basierten Service wird aufgezeigt, dass schon mit einfachen Mitteln ein Nutzen für Anwendende erzeugt werden kann. Ein solcher Demonstrator kann in einem frühen Schritt helfen, vorhandene Unsicherheiten in einer Organisation zu überwinden.

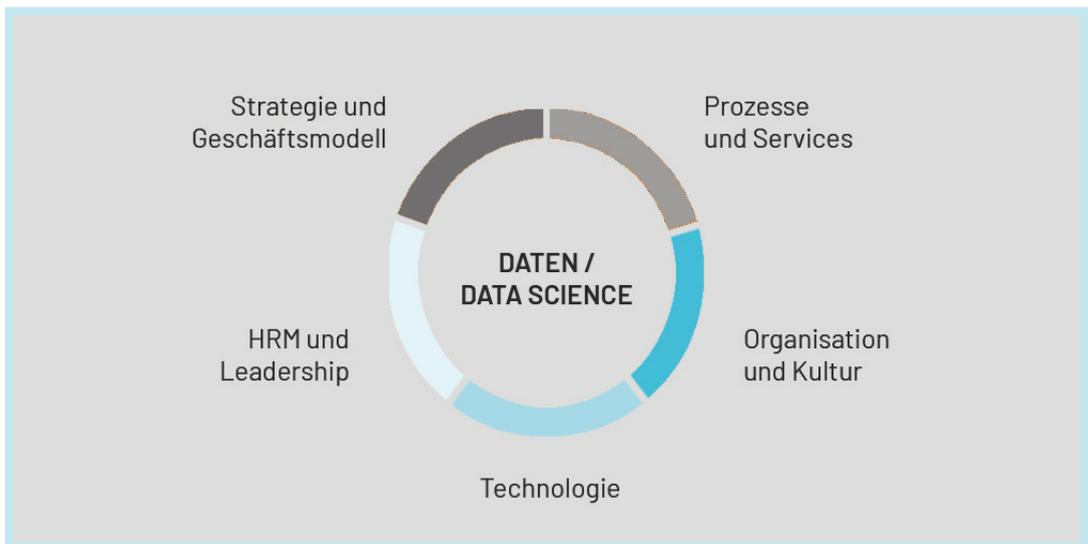


Abbildung 1: Fünf Perspektiven auf Daten und Data Science in KMU. Eigene Darstellung

Projektpartner

Am Teilprojekt Data4KMU waren vier Hochschulen aus der Schweiz, Österreich und Deutschland beteiligt:

ZHAW Zürcher Hochschule für Angewandte Wissenschaften, School of Engineering
(Dr. Jürg Meierhofer, Roman Etschmann)



FHS St. Gallen Hochschule für Angewandte Wissenschaften*
(Prof. Dr. Petra Kugler, Prof. Dr. Sibylle Olbert-Bock, Abdullah Redzepi, Prof. Dr. Christian Thiel, Prof. Dr. Rigo Tietz)



* Ab 09.2020 neue Bezeichnung: OST - Ostschweizer Fachhochschule

Fachhochschule Vorarlberg
(Martin Dobler, Prof. Dr.-Ing. Jens Schumacher)



Hochschule Konstanz Technik, Wirtschaft und Gestaltung (HTWG)
(Prof. Dr. Rainer Mueller)



Platz für Ihre Notizen:

Daten und Data Science in KMU und Grossunternehmen: Wo stehen wir?

Kapitelinhalt Arbeitspaket 1 (AP1)

- Data Science – Worum geht es eigentlich?
Seite 14 – 16
- Anwendungsbereiche von Daten und Data Science
Seite 17 – 18
- Potenzial und Bedeutung von Data Science
in KMU und Grossunternehmen
Seite 19 – 20
- Wie KMU und Grossunternehmen Data Science nutzen
Seite 21
- Daten sind «Softies»: Hürden im Umgang mit Data Science
Seite 22 – 23
- Zu klein, hohe Kosten und mangelnde Dringlichkeit in KMU
Seite 24 – 25
- Was KMU und Grossunternehmen über Daten nicht wissen
Seite 26 – 28
- Datensicherheit, Sicherheitsbedenken und rechtliche Situation
Seite 29 – 30
- Schrittweise Lernen und einen klaren Nutzen kommunizieren
Seite 31
- Was KMU tun können
Seite 32
- Die wichtigsten Erkenntnisse
Seite 33

Autoren:

Prof. Dr. Petra Kugler (FHS St. Gallen Hochschule für Angewandte Wissenschaften),
Dr. Jürg Meierhofer, Roman Etschmann (ZHAW School of Engineering)

Data Science – Worum geht es eigentlich?

Der unternehmerische Wert von Daten ist heute unbestritten. Die grossen amerikanischen Technologiekonzerne, die sogenannten «GAFA»-Unternehmen (Google, Amazon, Facebook, Apple) demonstrieren eindrucksvoll, wie Daten dazu beitragen können, Unternehmenswerte zu steigern. Diesen Unternehmen ist gemeinsam, dass sie Daten gezielt sammeln, speichern, auswerten und nutzen. Google kann so etwa neue Trends anhand der Ergebnisse ihrer Suchmaschine frühzeitig ausmachen und in innovative Geschäftsideen oder Technologien transformieren (siehe hierzu auch das Beispiel Amazon in Abbildung 2).

«Data Science» umschreibt diesen Kontext und bezieht sich allgemein auf grosse bis sehr umfangreiche Datensätze, welche anhand von tiefen Analysen zu neuen Erkenntnissen und Ideen oder zu einem effizienteren Management führen können (Gupta und George, 2016; siehe auch Côte-Real et al., 2017; Günther et al., 2017). Als Synonyme zu «Data Science» werden auch alternative Begriffe wie «Big Data Science», «Data Analytics», oder «Business Intelligence» benutzt. Weniger bekannt ist hingegen, wo KMU im Hinblick auf die Nutzung von Daten und Data Science aktuell stehen und wohin die Reise geht. Denn KMU haben eine eigene Logik, die sich nicht immer mit der Situation von Grossunternehmen vergleichen lässt. Dies gilt in besonderem Masse für die bereits skizzierte Situation der grossen amerikanischen Technologiekonzerne. Dieses Kapitel zeigt auf, welches Verständnis zu Daten und Data Science aktuell in

Unternehmen vorherrscht und wie diese genutzt werden. Es wird ein Fokus auf die Situation von KMU gelegt, die aber immer wieder mit derjenigen von Grossunternehmen verglichen wird.

Der Umgang mit Daten ist für Unternehmen per se nicht neu. Neu ist vielmehr die unendlich grosse Menge an Daten, die heute immer und überall quasi in Echtzeit gewonnen werden. Sie sind ein Ergebnis digitaler Technologien, die ihre Speicherung und Nutzung erst ermöglichen. So ist es auch für KMU möglich, präzise Daten zum Verhalten oder zu Präfe-

renzen ihrer bestehenden und potenziellen Kunden zu gewinnen. Dazu braucht es lediglich Kontakte der Kunden mit der Unternehmenswebsite. In ähnlicher Weise können Maschinendaten aus dem Produktionsprozess beim oder für den Kunden analysiert werden. Die so entstehenden Datenmengen übersteigen in einem mittelgrossen KMU schnell die Speichermenge eines Terabytes – pro Tag.

Doch sind Daten per se nicht viel mehr als ein «Rohdiamant». Ohne den «richtigen Schliff» haben sie nur einen begrenzten Wert.

Amazon «Same -Day Delivery-Service»

Amazon nutzt unter anderem umfangreiche Datensätze, die im Rahmen des Online-Verkaufs über ihre Kunden generiert werden, um den «Amazon Same-Day Delivery-Service» zu verbessern. Amazon lernt dabei aus der Geschäftstätigkeit und aus den Bestellungen der Kunden der vergangenen Jahre. So kann abgeschätzt werden, welche Produkte von den Kunden im Rahmen des Weihnachts- oder Ostergeschäftes wo besonders häufig nachgefragt werden. Dieses Wissen ermöglicht es, Artikel aus dem Sortiment an dezentrale Verteilzentren zu versenden, bevor die Kunden sie überhaupt bestellen. So kann der gesamte Bestellprozess beschleunigt und die Produkte noch am selben Tag der Bestellung ausgeliefert werden. Geschwindigkeit ist aus Sicht von Amazon ein zentraler Faktor im digitalen Handel und kann dann zu einem Vorteil im Wettbewerb führen. Aus Sicht der Kunden ist die Geschwindigkeit ein willkommener (und von den Kunden auch verlangter) Nutzen, der jedoch seinen Preis hat: Alle gespeicherten Daten erzählen eine Geschichte über den Verursacher und sie erfordern die Bereitschaft, diese auch tatsächlich offenzulegen. Der grössere Kundennutzen wird somit durch mehr Kundentransparenz «bezahlt». Daten haben also einen Wert, auch wenn dieser oft nicht konkret bekannt oder bewusst ist.

Abbildung 2: Data Science Beispiel «Amazon Same Day Delivery». Eigene Darstellung, siehe auch Amazon (2020).

Anders ausgedrückt, die grossen Datenmengen müssen erst aufbereitet, analysiert und in Wissen oder in (neue) Erkenntnisse über wirtschaftliche Zusammenhänge transformiert werden, bevor sie konkrete Werte generieren. Wie dies genau geschehen kann, ist für zahlreiche Unternehmen noch nicht hinreichend geklärt. Dies zeigt das Verständnis von Data Science sowohl der von uns befragten KMU als auch Grossunternehmen (siehe Abbildung 3).

Mit Data Science werden häufig sehr allgemeine Begriffe verknüpft wie beispielsweise die «Analyse und Auswertung von Daten», die «Nutzung von Daten

für neue Produkte und Services», «Business Intelligence» oder das «Sammeln von Daten». Konkrete Anwendungen (z.B. «digitales Marketing», «Assistenzsysteme», «Kommunikation mit Maschinen») werden hingegen vergleichsweise selten genannt. Das Verständnis von Daten und Data Science findet in Unternehmen heute noch auf einer sehr umfassenden Ebene statt, die noch weiter konkretisiert und in Handlungen transferiert werden muss, um überhaupt greifbar zu werden. «Data Science» ist für viele KMU also eher ein abstrakter Begriff denn konkrete Handlungen und Wertschöpfungslösungen, die auf Daten fussen.

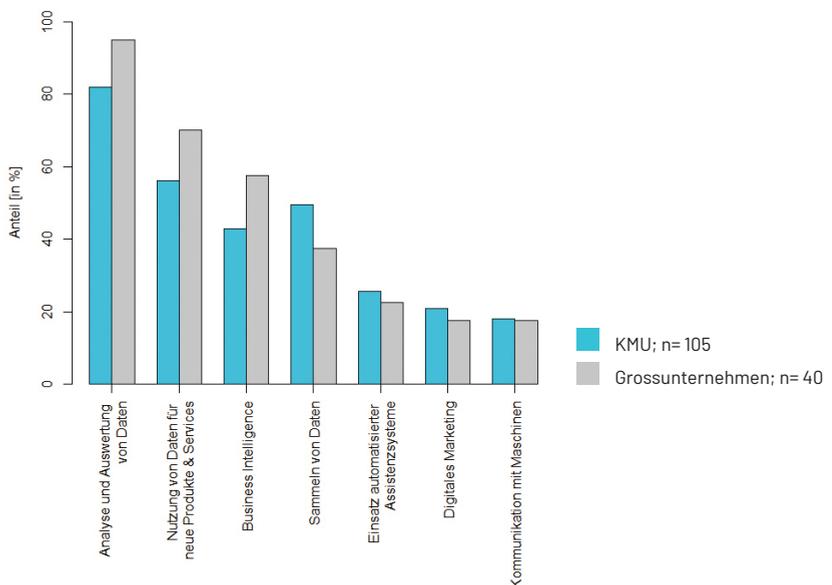


Abbildung 3: Verständnis von Data Science in KMU und in Grossunternehmen. Eigene Darstellung.

Anwendungsbereiche von Daten und Data Science

Daten können dabei helfen, die Erwartungen oder das Verhalten der eigenen und potenzieller Kunden besser zu verstehen. Anhand von Daten ist es auch möglich, den bevorstehenden Ausfall von Maschinen in der Produktion vorherzusagen und einzugreifen, bevor ein Schaden tatsächlich entsteht («Predictive Maintenance»). Unternehmen können so neue Märkte erschliessen oder Zeit und Kosten sparen. Die denkbaren Anwendungsgebiete für Daten und Data Science und die dadurch entstehenden Möglichkeiten sind nahezu unbegrenzt. Sie umfassen alles, was man in grossem Umfang zählen, messen und

zueinander (rechnerisch) in Verbindung setzen kann. Meist stellt der Schritt der Datenanalyse in Unternehmen dabei eine grössere Herausforderung als das Sammeln von Daten dar. Es wird ersichtlich, dass Data Science auch für KMU zunehmend relevant wird.

Wie genau das aussehen kann, zeigt das Beispiel der Winterhalter Gastronom GmbH aus dem baden-württembergischen Meckenbeuren (Abbildung 4). Einen Überblick über mögliche Applikationen von und mit Daten gibt Abbildung 5.

Data Science bei der Winterhalter Gastronom GmbH

Die Winterhalter Gastronom GmbH ist ein familiengeführtes Unternehmen mit Sitz im Baden-Württembergischen Meckenbeuren. Seit 70 Jahren produziert das Unternehmen Spülmaschinen und Spüllösungen für die Gastronomie. Die Digitalisierung wird im Unternehmen als eine Chance gesehen, innovative Lösungen zu erarbeiten, die den Kunden ins Zentrum stellen. Die Winterhalter GmbH nutzt Daten, um das Spülverhalten der Kunden besser zu verstehen. Daraus entstanden neue Geschäftsmodelle wie «Connected Wash» und «Pay per Wash», mit welchen unter anderem neue Kundengruppen angesprochen werden. «Pay per Wash» ermöglicht es auch kleinen Gastronomiebetrieben, eine High-End Spüllösung zu nutzen, indem kein Kaufpreis bezahlt werden muss, sondern eine nutzenabhängige Abrechnung pro Spülgang erfolgt.

Wie die Winterhalter GmbH mit Daten umgeht, zeigt auch ein kurzes Video unter: youtu.be/ixT018dnORA, Bodenseezentrum Innovation 4.0 (2019).

Funktion	Beschreibung	Gross- unternehmen	KMU
Produktion und Wertschöpfung	Simulation und Optimierung von Materialflüssen und Herstellungsprozessen, Frühzeitige Warnung vor Produktionsunterbrüchen (z.B. Predictive Maintenance, Digitaler Zwilling)	ABB General Electric	Rey Automation
Logistik und Intralogistik	Optimierung Warenlager und Warentransport	Amazon Schweizerische Post	Meteomatics
Preise	Dynamische Preise, Yield Management, Identifikation der Preise, den Profit / Ertrag maximieren	Lufthansa Marriott Hotels Booking.com	Pizol Bergbahnen
Neue und / oder verbesserte Produkte und Services	Qualitätsprobleme aufdecken, optimieren, Neue Produkte entwerfen	Heidelberger Druckmaschinen	ANTA SWISS Winterhalter Gastronom GmbH Müller Martini
Finanzen	Besseres Verständnis der finanziellen Treiber und nichtmonetärer Faktoren im Unternehmen	AXA Winterthur	Contovista
Human Resources	Auswahl, Anreize, Entlohnung von Mitarbeitenden, HR-Analytics	Xerox Call Center Gate Gourmet	Avectris AG SFC Koenig AG HR Campus AG
Genauere Kundenkenntnis, Kundenloyalität, Marketing	Definition von Kundengruppen, Aufdecken der Kundengruppen mit dem grössten Potenzial, gezielte Kundenansprache, Nutzungsverhalten	Migros	Winterhalter Gastronom GmbH Valantic Advertima
Forschung und Entwicklung	Verbesserung der Qualität, des Einsatzes und ggfs. der Sicherheit von Produkten und Services	Novartis Amazon Google	ProSim

Abbildung 5: Beispielhafte Anwendungsbereiche von Daten und Data Science in KMU und in Grossunternehmen. Eigene Darstellung in Anlehnung an Struktur nach Datenport (2006: 101).

Potenzial und Bedeutung von Data Science in KMU und Grossunternehmen

Das grosse Potenzial, das in Daten und Data Science steckt, erkennen heute schon sowohl die im Rahmen der Studie befragten KMU als auch Grossunternehmen (siehe Abbildung 6). Auffällig ist dabei, dass sich die Einschätzungen beider Unternehmenskategorien zum aktuellen Zeitpunkt kaum voneinander unterscheiden. In der Mehrheit der befragten Unternehmen ist gemäss eigenen Angaben ein Bewusstsein für den Umgang mit Daten vorhanden.

Jedoch lohnt sich ein genauerer Blick auf die

Angaben, insbesondere in Kombination mit der jeweiligen Einschätzung der Bedeutung von Daten und Data Science zum heutigen Zeitpunkt und in fünf Jahren für das eigene Unternehmen der befragten Personen (siehe hierzu Abbildung 7, nächste Seite). Zum aktuellen Zeitpunkt (linker Teil der Abbildung 7) schätzen die beiden Unternehmenskategorien die Bedeutung bereits unterschiedlich ein. Grossunternehmen tendieren dazu, Daten schon heute eine grössere Bedeutung zuzuweisen, während KMU tendenziell verhaltener sind.

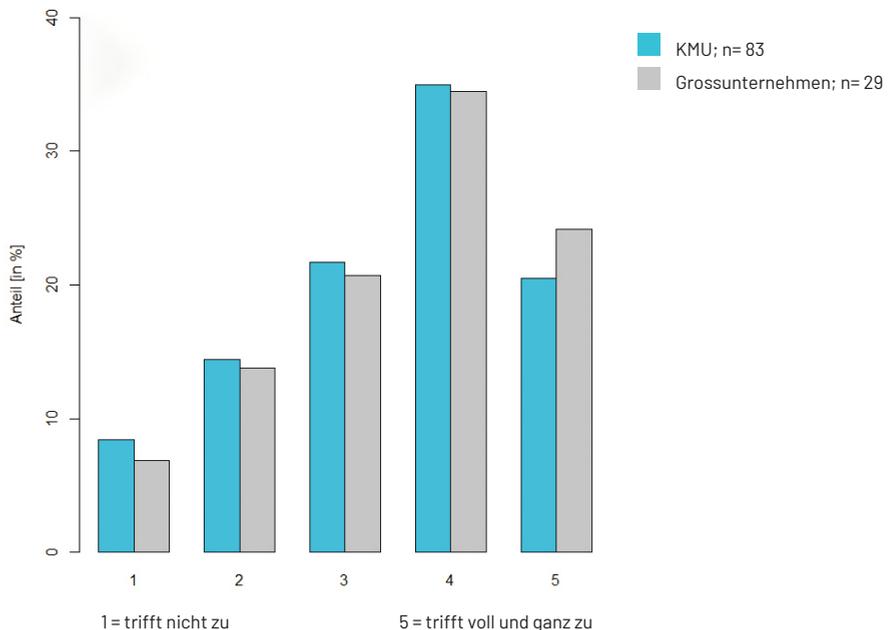


Abbildung 6: Potenzial von Daten und Data Science aus der Sicht von KMU und Grossunternehmen. Eigene Darstellung.

Für einen zukünftigen Zeitpunkt in fünf Jahren wird jedoch eine deutlich veränderte Situation vermutet. Sowohl KMU als auch Grossunternehmen gehen dann von einer erheblich grösseren Bedeutung von Data Science für ihr Geschäft aus. Auffällig ist, dass fast 70% der Grossunternehmen der Aussage voll und ganz zustimmen, dass Daten künftig eine grosse Bedeutung für ihr Unternehmen und ihr Geschäft haben. Kein Unternehmen dieser Kategorie ist der

Ansicht, dass dies nicht oder nur in geringem Masse zutrifft. Das heisst, gemäss Erwartung werden Daten einen grossen Teil ihres Geschäfts beeinflussen oder gar dessen Grundlage bilden. KMU sind erneut zurückhaltender. Sie scheinen weniger davon auszugehen, dass Daten ihr künftiges Geschäft aktiv oder passiv (z.B. durch Stakeholder wie Kunden, Lieferanten, Wettbewerber) beeinflussen, dies jedoch in grösserem Masse als heute.

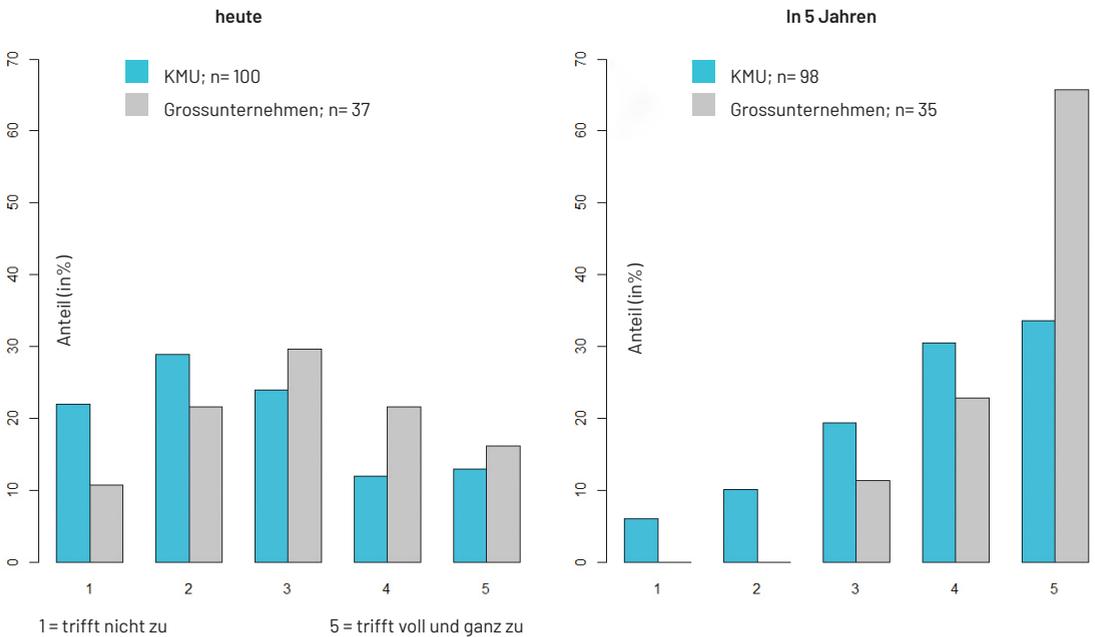


Abbildung 7: Bedeutung von Data Science in KMU und in Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

Daten sind «Softies»: Hürden im Umgang mit Data Science

Sowohl KMU als auch Grossunternehmen wurden im Rahmen der Studie nach Hürden befragt, welche sie davon abhalten, Daten und Data Science umfassend zu nutzen (siehe Abbildung 9). Die Mehrheit der Hürden wurde von beiden Unternehmenskategorien etwa im gleichen Ausmass genannt. Auffällig ist, dass «unpassende Daten» die vergleichsweise kleinste Hürde darstellen. Zudem wird diese Hürde von Grossunternehmen

deutlich häufiger wahrgenommen als von KMU. Es ist möglich, dass es vor allem in KMU an ausreichend Wissen und Kompetenzen fehlt, die Eignung der vorhandenen Daten überhaupt einzuschätzen. Oder anders gesagt, einige Unternehmen wissen möglicherweise noch nicht, was sie im Hinblick auf die Nutzung von Daten (noch) nicht wissen, nicht haben oder brauchen.

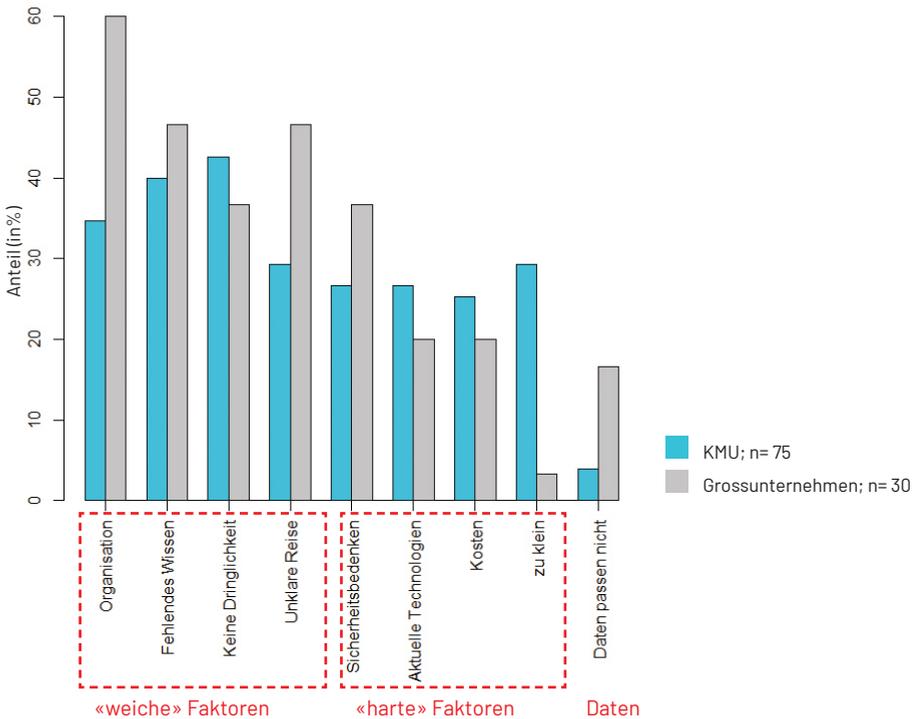


Abbildung 9: Hürden für die Nutzung von Daten und Data Science in KMU und in Grossunternehmen. Eigene Darstellung.

Eine zweite Kategorie von Hürden bilden die sogenannten «harten Faktoren», welche «Sicherheitsbedenken», «aktuelle Technologien», «Kosten» und eine zu geringe Grösse des Unternehmens («zu klein») umfassen. Die «harten Faktoren» sind mit Ausnahme der «Sicherheitsbedenken» für KMU von grösserer Bedeutung als für Grossunternehmen. Sie hängen direkt mit der begrenzteren Ressourcensituation von KMU (vgl. Kugler und Tietz, 2015) zusammen.

Den wichtigsten Block der in der Wahrnehmung der befragten Unternehmen grössten Hürden bilden sogenannten «weiche Faktoren». Damit sind «Organisation», «fehlendes Wissen», «keine Dringlichkeit» und eine «unklare Vision» im Hinblick auf die Nutzung von Daten gemeint. Erneut unterscheiden sich die jeweils grössten Hürden für KMU («fehlende Dringlichkeit») und für Grossunternehmen («Organisation»). Der Punkt «Organisation» wurde in der Umfrage nicht weiter ausdifferenziert, so dass die Antwortenden unter dieser Kategorie möglicherweise nicht nur strukturelle Aspekte der Unternehmensorganisation verstehen, sondern auch weitere Punkte, welche das Unternehmen selbst

betreffen (z.B. Kompetenzen, Führung, Kultur). Die insbesondere von KMU empfundene «fehlende Dringlichkeit» ist alarmierend, denn die Unternehmen bewegen sich dann gegebenenfalls in einer falscherweise wahrgenommenen Sicherheit und sie realisieren nicht, mit welcher Geschwindigkeit Daten zu einem Teil der Wertschöpfung werden.

Ausser einer «fehlenden Dringlichkeit» werden die «weichen» Hürden von Grossunternehmen (zum Teil deutlich) stärker wahrgenommen als von KMU. Diese Antworten deuten darauf hin, dass eine konsequente Nutzung von «Data Science» im Unternehmen auch grundlegende Veränderungen mehrerer unternehmerischer Bereiche erfordert und dort tief verankert werden muss. Die Arbeit mit Data Science ist keine isolierte Aktivität. Vielmehr braucht es ein neues unternehmerisches Verständnis und veränderte Bedingungen in den Unternehmen, welche diese Arbeit überhaupt erst ermöglicht.

Die wichtigsten der hier genannten Hürden werden in diesem und in den nachfolgenden Kapiteln dieser Broschüre individuell oder im Kontext weiterer Aspekte aufgegriffen und vertieft diskutiert.

Zu klein, hohe Kosten und mangelnde Dringlichkeit in KMU

Obwohl die in der Studie befragten Unternehmen beider Unternehmenskategorien, KMU und Grossunternehmen, das Potenzial von Daten und Data Science nahezu identisch einschätzen, bereiten sie sich unterschiedlich auf die Arbeit mit Daten vor. Beide Unternehmenskategorien ergreifen Massnahmen, um erste Erfahrungen im Zusammenhang mit Data Science zu gewinnen, auf denen weitere Aktivitäten aufbauen können. Es wird ein Versuchs-und-Irrtums-Prozess angestossen, um zu lernen. Doch Grossunternehmen scheinen heute schon mehr Ressourcen für die Digitalisierung

insgesamt und insbesondere für die Nutzung von Daten zur Verfügung zu stellen. Sie investieren stärker in die Arbeit mit Daten. Eine Vielzahl unterschiedlicher Massnahmen und Tools wird dabei von Grossunternehmen ergriffen oder eingesetzt. Dazu gehören zum Beispiel Apps, soziale Medien oder CRM-Systeme, die zur Gewinnung von Daten angewendet werden, sowie Bezahlmodelle, die auf Daten aufbauen. Bei solchen Bezahlmodellen wird der Preis eines Gutes oder Services anhand der Stärke der Nutzung der Produkte durch den Kunden definiert («Pay per Use»).

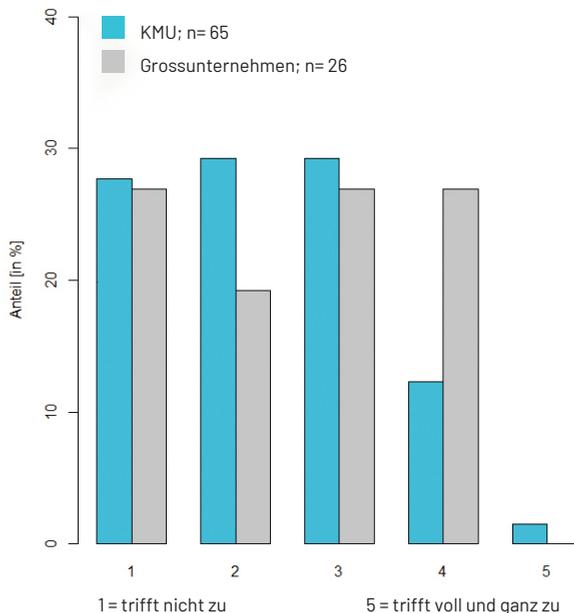


Abbildung 10: Fehlendes Wissen zur Datennutzung in KMU und in Grossunternehmen. Eigene Darstellung.

Diese Massnahmen sind häufig mit hohen (initialen) Kosten für die Unternehmen verbunden. Ein Mittel, um die Kosten tiefer zu halten, sind Pilotprojekte, die mit geringem Budget durchgeführt werden, die aber zu grossen Lerneffekten führen können. Die Unternehmen sind sich vor diesem Hintergrund bewusst, dass es vor allem darauf ankommt, zu starten und sich mit Daten beschäftigen, um einen kollektiven Lernprozess auf allen Hierarchiestufen im Unternehmen anzustossen. Pilotprojekte können im Unternehmen kommuniziert werden und ein internes Signal setzen. Erfolgreiche Pilotprojekte können zudem auch nach aussen kommuniziert werden, so dass sich das Unternehmen auf dem Markt als innovativer «Data-Player» positioniert. Dabei ist es zentral, dass die Mitarbeitenden im Unternehmen in solche Projekte eingebunden und für das neue Thema sensibilisiert werden. Für KMU ist ein solcher Prozess meist schwieriger, da weniger Ressourcen vorhanden sind, um die entstehenden Kosten zu tragen, und oft sind KMU zu klein, um Spezialisten zu beschäftigen (z.B. Kugler und Tietz, 2015).

Gerade in KMU sind die hohen initialen Kosten und das oft ungewisse Ergebnis von Data Science-Projekten herausfordernd. Sie «stören» das ohnehin schon fordernde Alltagsgeschäft und werden nicht selten auf einen unbestimmten Zeitpunkt in der Zukunft verschoben. Notwendige Veränderungen werden dann als «nicht dringlich» eingestuft. Dieser

Punkt wurde von den durch die Studie befragten KMU als grösste Hürde eingeschätzt (siehe Abbildung 9), was generell als alarmierend gelten kann. Denn KMU laufen Gefahr, das Zeitfenster des Handelns zu verpassen, während aktuelle oder potenzielle Wettbewerber Kompetenzen im Umgang mit Daten aufbauen und verbessern, um einen Vorteil im Wettbewerb zu erzielen.

Häufig wird dann die Geschwindigkeit, mit der sich neue Technologien wie Data Science etablieren, unterschätzt. Paradoxerweise sind es oft gerade erfolgreiche Unternehmen, welche den Anschluss verpassen können. Der heutige Erfolg kann zu einer vermeintlichen Sicherheit führen, vor deren Hintergrund neue Technologien und disruptiven Prozessen nicht erkannt werden. Zu grosser heutiger Erfolg kann Unternehmen dann daran hindern, Neues anzupacken, um ihre Zukunft zu sichern. Solche Unternehmen wägen sich in einer falschen Sicherheit, die dazu führt, dass keine Dringlichkeit zum Handeln empfunden wird (siehe zu Disruptionen allgemein Christensen, 1997; Christensen et al., 2016; zu Disruptionen im digitalen Kontext Kugler und Tietz, 2019; Kugler, 2019a+b). Doch eine Situation des heutigen (finanziellen) Erfolgs bietet auch Freiräume, um Neues wie Data Science, auszutesten, ohne einem unmittelbaren Erfolgsdruck ausgesetzt zu sein. Dies sind meist gute Voraussetzungen, um zu neuen Lösungen zu kommen.

Was KMU und Grossunternehmen über Daten nicht wissen

Zum aktuellen Zeitpunkt stellt der gezielte Umgang mit Daten für viele Unternehmen noch eine Herausforderung dar. Häufig sind grundlegende Fragen zu Daten und Data Science erst im Ansatz (wenn überhaupt) klar formuliert oder beantwortet, und es lassen sich auch grosse Unterschiede im Wissensstand von Unternehmen feststellen. Aufgrund des hohen Neuigkeitsgehaltes des Themas muss vielfach erst noch ein Verständnis darüber entwickelt werden, was überhaupt Data Science ist, was es im jeweiligen Unternehmen zu leisten vermag und vor allem, welcher Nutzen für die Unternehmen selbst und für deren Kunden oder andere Stakeholder aus Daten generiert werden kann. Dies belegen Zitate aus den geführten Interviews:

«Ich versuche vorerst mal, die Begriffe [Data und Analytics] zu deuten. Data ist eigentlich nur Information und Analytics ist nach meinem Verständnis der Weg, um aus den Daten Wissen zu generieren sowie daraus Handlungsempfehlungen oder Handlungen generell ableiten zu können.»
(Unternehmen 5, Maschinenbau)

«Bei den meisten [KMU] ist noch nicht viel vorhanden, Daten können vorhanden sein, aber Analytics ist als Thema noch recht fern.»
(Unternehmen 8, IT-Consulting)

Dabei sind insbesondere viele Fragen im Zusammenhang mit den Daten selbst noch unklar. Häufig liegt zwar schon eine grosse Menge an Daten in produzierenden Unternehmen vor, und den Unternehmen gelingt es auch, diese aus den vorhandenen Maschinen herauszuholen. Es fehlt jedoch an anderen Wissensbestandteilen. Rund 80% der befragten Unternehmen gaben an, dass sie noch nicht wissen, was mit den vorhandenen Daten überhaupt gemacht werden kann. Doch auch an dieser Stelle zeigen sich Unterschiede zwischen Grossunternehmen und KMU. Von den befragten Grossunternehmen geben 30% an, dass das notwendige Wissen zur Nutzung von Daten im Unternehmen vorhanden sei. Dies ist ein deutlicher Unterschied im Vergleich zu den befragten KMU, bei welchen dieser Anteil bei etwa 15%, also der Hälfte der Grossunternehmen, liegt (siehe Abbildung 10).

Dabei werden unterschiedliche Ansätze zum Umgang mit den Daten in den Unternehmen verfolgt. Einerseits werden so viele Rohdaten wie möglich auf einer flachen Hierarchie ungefiltert gesammelt, um dann nach sinnvollen Mustern und Zusammenhängen in den Datensätzen zu suchen. Eine solche Vorgehensweise ermöglicht einen freien, ungefilterten oder «induktiven» Zugang zu den Daten und Erkenntnissen aus ihnen. Diese Vorgehensweise

ermöglicht es, die Daten auch zu einem späteren Zeitpunkt auf mögliche Muster zu untersuchen, an die zu einem früheren Zeitpunkt noch niemand als relevant eingestuft hat. Dieser Ansatz ist jedoch mit hohen Kosten verbunden, da eine grosse Menge an Daten gespeichert und analysiert werden muss. Für den Alltag vieler KMU ist diese Vorgehensweise daher nur bedingt geeignet (siehe Abbildung 11).

Andererseits besteht ein zweiter Ansatz darin, zunächst Hypothesen zu formulieren und mit

diesen zu filtern und vorzudefinieren, welche Daten überhaupt gesammelt, gespeichert und ausgewertet werden sollen («deduktiver Zugang»). Die zu speichernde Datenmenge wird so reduziert, aber dieses Vorgehen funktioniert nur, wenn dem Unternehmen bereits grundlegende Kenntnisse zum untersuchten Sachverhalt vorliegen. Es besteht aber auch die Gefahr, dass die Problemdefinition zu eng oder fehlerhaft ist, so dass wichtige Daten nicht erfasst werden. Entscheidende Zusammenhänge werden dann möglicherweise nicht erkannt

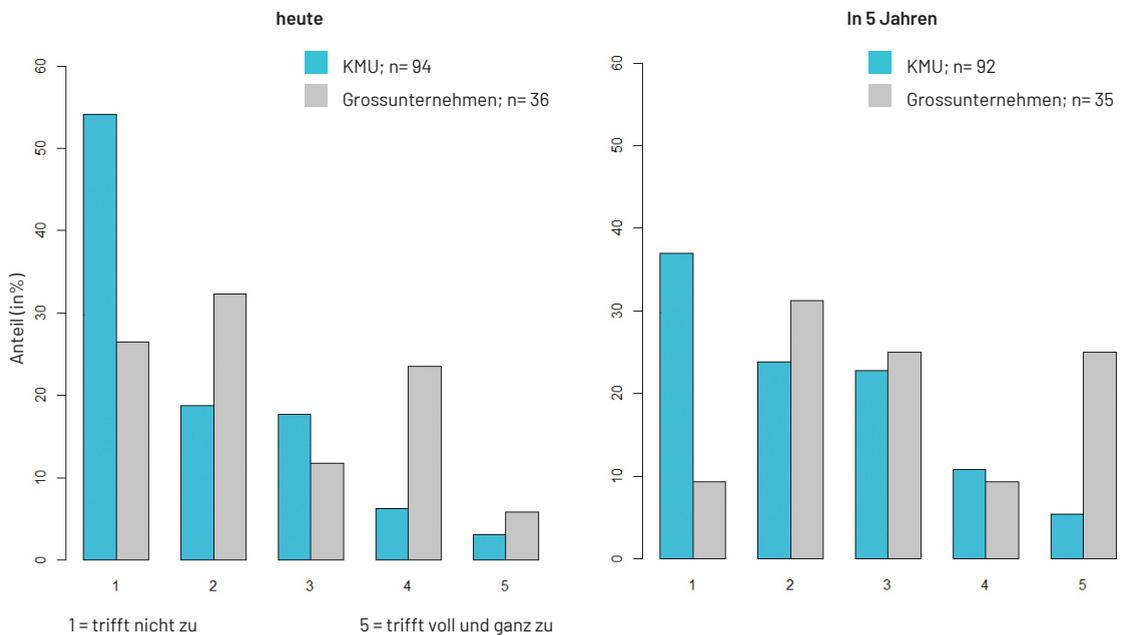


Abbildung 11: Daten auf Vorrat sammeln in KMU und in Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

oder sie werden nicht als bedeutsam eingestuft. Für den Alltag vieler KMU ist dieser Ansatz vor dem Hintergrund knapper Ressourcen insgesamt realistischer und pragmatischer:

«Für uns ist es wichtig zu verstehen, welche Daten wir brauchen, damit ein Modell funktioniert. Wenn wir nicht wissen, welche Daten wir sammeln sollen, dann macht das keinen Sinn. [...] Wenn man ein Modell entwickelt und weiss, welche Daten man braucht, dann kann man diese sammeln.»
(Unternehmen 4, Dienstleistung)

Zum aktuellen Zeitpunkt scheint jedoch in vielen Unternehmen beider Kategorien (KMU und Grossunternehmen) das notwendige Wissen noch zu fehlen, welche Daten es überhaupt für welchen Zweck braucht. Beide Unternehmenskategorien gehen davon aus, dass sich die Situation (und ihr Wissen) in fünf Jahren deutlich verbessert hat und dann Daten gezielt nach Bedarf gesammelt werden. Diese Vermutung ist in Grossunternehmen stärker als in KMU (siehe Abbildung 12).

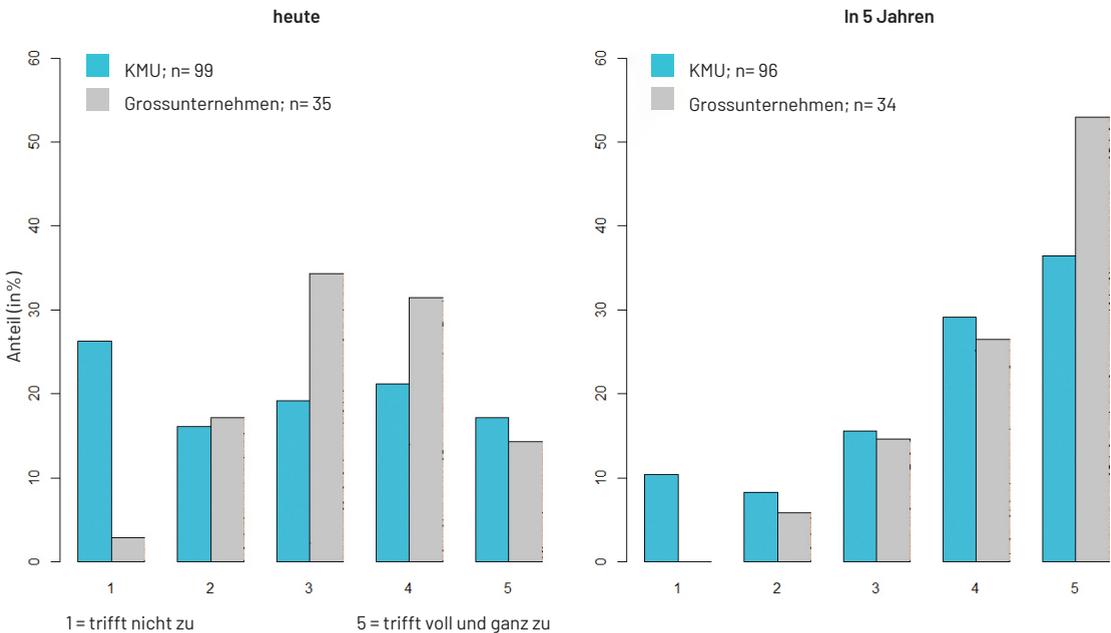


Abbildung 12: Daten gezielt sammeln in KMU und in Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

Datensicherheit, Sicherheitsbedenken und rechtliche Situation

Datensicherheit und die vielfach noch diffuse rechtliche Situation zur Erhebung und Nutzung von Daten stellen eine weitere Hürde für die Unternehmen dar, die von etwa 30% der befragten Unternehmen genannt wurde. Dabei lassen sich nationale Unterschiede feststellen und Deutschland wird im Vergleich zur Schweiz oder zu Österreich als restriktiver wahrgenommen:

«Das Hauptthema in Deutschland ist immer Datensicherheit, Datenhoheit, Datenschutz. In Deutschland ist das ein Problem. Da haben Sie es, wenn Sie hier über die Grenze gehen, in der Schweiz, viel einfacher. Das gilt auch für Holland und Belgien, dort ist es auch viel einfacher. (Unternehmen 2, IT-Beratung)

Der **Ort der Datenspeicherung** spielt in diesem Zusammenhang eine wichtige Rolle. Zahlreiche Unternehmen oder auch einzelne Hierarchiestufen in den Unternehmen haben vor allem Bedenken, Daten in der Cloud zu speichern. Auch Kunden fragen zunehmend nach dem Speicherort ihrer Daten. Dabei ist es nicht immer vollständig transparent, in welchem Land die Daten tatsächlich liegen oder wer der Host der Daten ist. Mehrstufige oder indirekte Beziehungen zwischen Unternehmen verschleiern häufig, wo genau die Daten liegen. Nicht immer können die so entstehenden Fragen unmittelbar

beantwortet oder Herausforderungen bewältigt werden. Andererseits wird die Cloud von einigen Unternehmen aber auch als unbedingt notwendig für die Speicherung von Daten erachtet. Chancen und Risiken müssen dann gegeneinander abgewogen werden.

Generell stellt sich für viele Unternehmen die Frage, ob Daten intern oder extern gehostet werden sollen. Für eine interne Lösung spricht eine grössere Flexibilität und Kontrolle über die Daten. Dagegen sprechen hingegen die hohen Kosten, welche durch den grossen Speicherbedarf entstehen und der Bedarf an ausreichend Wissen im Umgang mit den Daten. Auch an diesem Punkt zeigt sich häufig, dass es den Unternehmen an einem ausreichenden Mass an Wissen im Kontext von Daten und Data Science fehlt. Ein IT-Berater verweist in Rahmen eines der geführten Interviews darauf, dass Datensicherheit zwar als Hindernis genannt wird. Tatsächlich verfügen Unternehmen aber oft nicht über ausreichend Wissen, um die Situation überhaupt beurteilen zu können, z.B. für welche Daten es welche Art von Sicherheit braucht.

Auch stellt die DSGVO, die seit 2018 rechtlich bindend ist, eine Hürde für die umfassende Gewinnung und Nutzung von Daten dar. Die rechtliche Situation ist zum aktuellen Zeitpunkt noch nicht überall

hinreichend geklärt, so dass etliche Unternehmen nicht wissen, welche Handlungen überhaupt rechtens sind und welche nicht. Aus Angst, gegen geltendes Gesetz zu verstossen, warten etliche Unternehmen noch ab oder sie nehmen nur ausgewählte Handlungen im Zusammenhang mit Daten vor. Abwarten kann dann einen Zeitverlust bedeuten. Zu beachten ist in diesem Zusammenhang auch, dass der Unterschied zwischen Personen- und Objekt- bzw. Maschinendaten oft nicht hinreichend geklärt ist.

«Die Unsicherheit ist schon gross, vor allem, was darf man überhaupt.»

(Unternehmen 4, Dienstleistung)

«Man muss vor allem die neue DSGVO beachten. Wenn man Daten sammelt, dann müssen Kunden unterschreiben, dass die Daten genutzt werden können. So können wir keine grossen Datenmengen sammeln, um statistische Untersuchungen durchzuführen.»

(Unternehmen 4, Dienstleistung)



Schrittweise Lernen und einen klaren Nutzen kommunizieren

Sowohl unternehmensintern als auch extern gegenüber dem Kunden, zeigt sich bereits heute schon, dass der Mehrwert, der durch die Gewinnung und Nutzung von Daten entsteht, klar kommuniziert werden muss. Unternehmensintern geht es vor allem darum, neue Chancen, Möglichkeiten und den entstehenden Mehrwert klar zu vermitteln, die für das Unternehmen durch die Gewinnung und Nutzung von Daten entstehen können. Auch ist es denkbar, dass Daten und Data Science dabei helfen können, bestehende Probleme besser zu bewältigen, die bisher nicht lösbar waren. Schwieriger ist es hingegen, auf Herausforderungen zu verweisen, die entweder durch die Nutzung der Daten für das Unternehmen entstehen können oder mit denen ein Unternehmen ggfs. konfrontiert wird, wenn es (vorerst) auf deren Nutzung verzichtet:

«Auch hier nicht mit der Angst-Keule zu wedeln: Wenn du das jetzt nicht machst, dann bist du morgen tot, sondern die neuen Möglichkeiten dementsprechend auch anzusprechen. Was sind denn neue Möglichkeiten, neue Geschäftsmodelle, was kann ich denn aus Daten machen.»

(Unternehmen 2, IT-Consulting)

Auf der unternehmensexternen Seite des Kunden zeigt sich unter anderem heute schon, dass die Bereitschaft der Kunden sinkt, Daten ohne Gegenleistung zur Verfügung zu stellen. Kunden sind sich zunehmend darüber bewusst, dass Daten einen Wert haben und ihre Bereitstellung einem «Geschäft» mit wechselseitigem Austausch einer Leistung gleicht. Sowohl im eigenen Unternehmen, als auch auf der Seite der Kunden ist eine Sensibilisierung für die Nutzung von Daten von großer Bedeutung, wenn diese bereits von der Nutzung von Daten «betroffen» sind, zum Beispiel da Wettbewerber dies schon tun. KMU fehlt es dabei jedoch häufig an Vorbildern oder «Use Cases» anderer mittelständischer Unternehmen, die bereits erfolgreich mit Daten arbeiten. Die häufig als Beispiele genannten GAFA-Unternehmen (Google, Apple, Facebook, Amazon) sind zu gross und sie funktionieren zu anders, um tatsächlich als Vorbild für ein typisches KMU zu gelten:

«Das werden wir auch immer gefragt: Wer hat denn da schon was gemacht? Wer hat sich schon digitalisiert? Welche Probleme gibt es denn da? Und dann immer nur mit Google oder Apple zu kommen, das bringt dem Mittelstand gar nichts.»

(Unternehmen 2, IT-Consulting)

Was KMU tun können

Zum aktuellen Zeitpunkt stehen sowohl zahlreiche KMU als auch Grossunternehmen erst noch am Anfang der Arbeit mit Daten und Data Science. Es lassen sich keine signifikanten Unterschiede zwischen den beiden Unternehmenskategorien ausmachen. Das wirtschaftliche Potenzial von Daten und Data Science wird daher heute jeweils noch nicht voll ausgeschöpft. Das ist eine gute Nachricht, denn in dieser paritätischen Situation liegen für alle Unternehmen heute noch zahlreiche Chancen. Die Nutzung von Daten kann in absehbarer Zeit tatsächlich zu einem Unterschied, oder besser, zu Vorteilen im Wettbewerb, führen. Denn die Situation ändert sich rasch.

Und das ist zugleich auch die schwierige Seite der Nachricht. Denn Unternehmen müssen sich möglicherweise in absehbarer Zeit fragen, ob sie es sich noch erlauben können, Daten in ihrem Wertschöpfungsprozess nicht zu nutzen. Es kann entscheidend sein, das geeignete Zeitfenster zum Handeln nicht zu verpassen. Dies gilt vor allem für KMU. Denn die Ergebnisse der Befragung lassen vermuten, dass sich die aktuell noch paritätische Situation schon in wenigen Jahren zugunsten der Grossunternehmen verändern wird und diese Daten und Data Science schneller in Ihren Arbeitsalltag und in ihre Wertschöpfung integrieren als KMU.

Es besteht daher die Gefahr, dass KMU schon in wenigen Jahren im Vergleich zu den Grossunternehmen einen Nachteil im Wettbewerb haben werden, sofern sie Daten nicht systematisch nutzen.

KMU sollten vor diesem Hintergrund rasch erste Massnahmen ergreifen, um mit Data Science vertraut zu werden. Sie laufen sonst Gefahr, den «Zug zu verpassen», da Wissen und Kompetenzen im Umgang mit Daten erst aufgebaut werden müssen, bevor diese wertschöpfend eingesetzt werden können. Die Ergebnisse dieser Studie legen nahe, dass es notwendig ist, das Unternehmen selbst auf die Arbeit mit Daten auszurichten (siehe «weiche Faktoren», oben). Dies braucht vor allen Dingen Zeit. Unternehmen sollten also interne Lernprozesse anstossen, um schrittweise mit der Arbeit mit Daten und Data Science vertraut zu werden. Pilotprojekte oder einzelne Massnahmen zu Austesten der Wirkung und der Notwendigkeiten für den Einsatz von Daten und Data Science können dabei helfen, die damit verbundenen Kosten und Risiken überschaubar zu halten.

Die nachfolgenden Kapitel gehen auf dieses Ergebnis und wie Unternehmen damit umgehen können, genauer ein. Dazu werden mehrere unternehmerische Perspektiven eingenommen.

Die wichtigsten Erkenntnisse

- Data Science bezeichnet die Analyse und Nutzung von Daten, welche anhand von tiefen Analysen zu neuen Erkenntnissen, Innovationen oder zu mehr Effizienz führen können.
- Das Verständnis von Daten und Data Science findet aktuell in KMU und in Grossunternehmen eher auf einer allgemeinen Ebene statt, die noch weiter konkretisiert werden muss.
- Das mit Daten und Data Science verbundene Potenzial wird von KMU und Grossunternehmen gleichermaßen erkannt.
- In den meisten Unternehmen beider Kategorien (KMU, Grossunternehmen) haben Daten und Data Science heute noch keine grosse Bedeutung und die Unternehmen beginnen erst, Daten zu nutzen. In 5 Jahren wird eine deutlich gesteigerte Bedeutung und Nutzung von Daten vermutet. Beides trifft für Grossunternehmens stärker zu als für KMU.
- Die grössten Hürden für die Anwendung von Daten und Data Science im Unternehmen liegen in den sogenannten «weichen Faktoren» begründet, gefolgt von den «harten Faktoren» und einer mangelnden Datenqualität.
- Es fehlt in KMU stärker als in Grossunternehmen an allgemeinem Wissen dazu, was mit Daten und Data Science überhaupt gemacht werden kann.
- Zwei mögliche Ansätze zum Umgang mit Daten liegen darin, alle Daten zu sammeln und dann nach Mustern zu suchen (induktives Vorgehen), oder Hypothesen zu entwickeln und dann gezielt Daten dazu zu sammeln und auszuwerten (deduktives Vorgehen).
- Datensicherheit und die noch unklare rechtliche Situation stellen Hürden zum Umgang mit Daten in Unternehmen dar.
- Pilotprojekte und erste Massnahmen können Unternehmen dabei helfen, den Umgang mit Daten und Data Science zu lernen, aber die Kosten und Risiken überschaubar zu halten.

Platz für Ihre Notizen:

Data Science, Strategie und Wettbewerb

Kapitelinhalt Arbeitspaket 2 (AP2)

- Strategische Relevanz von Daten
Seite 36 - 37
- Erhoffter Nutzen aus Daten und Data Science
Seite 38 - 40
- Daten verändern den Wettbewerb
Seite 41 - 43
- Wettbewerbsrelevante Charakteristika von Daten und Data Science
Seite 44 - 45
- Wettbewerbsvorteile für Daten-Nutzer im Vergleich zu Nicht-Nutzern: Die fünf «V's»
Seite 46 - 47
- Wettbewerbsvorteile aus Daten und Data Science: Wofür und wie?
Seite 48 - 50
- Heutiger Erfolg verhindert Data Science-Strategie
Seite 51 - 52
- Wo Data Science stattfindet: In-House, Outsourcing und neue Kooperationsmodelle
Seite 53 - 55
- Was KMU tun können
Seite 56
- Die wichtigsten Erkenntnisse
Seite 57

Autoren:

Prof. Dr. Petra Kugler (FHS St. Gallen Hochschule für Angewandte Wissenschaften)

Strategische Relevanz von Daten

Im August 2018 ist Apple gelungen, was zuvor noch kein anderes Unternehmen geschafft hat. Der Wert des Unternehmens durchbrach erstmals die «magische Grenze» von einer Billion USD. Auch andere Technologiekonzerne erreichen heute Werte, die noch vor wenigen Jahren als «utopisch» galten. Dies gilt insbesondere für die sogenannten «GAFA»-Unternehmen, zu denen ausser Apple auch Google, Amazon und Facebook zählen. Diesen Beispielen ist gemeinsam, dass Daten und Erkenntnisse, die aus den Daten gewonnen werden, Vieles auf den Kopf stellen, welches unser Bild des Wirtschaftens und der Wertschöpfung in der Vergangenheit geprägt hat. Data Science verändert die Spielregeln des Wettbewerbs. Daten sind dabei ein zentrales, wenn nicht sogar das wichtigste, Element der digitalen Transformation und für viele Unternehmen von unbedingter strategischer Relevanz. Doch die amerikanischen Technologie-Giganten oder «Superunternehmen» sind nur bedingt ein Vorbild für ein «typisches» KMU. Sie sind zu gross, zu anders und zu weit vom Alltag eines KMU entfernt. Trotzdem lohnt es sich auch für KMU, sich mit dem Thema «Data Science» zu beschäftigen. Daten und Data Science bieten ihnen grosse Chancen, sie können aber auch zu einer Bedrohung werden, falls nicht oder zu spät gehandelt wird. Die Zeit drängt, denn Geschwindigkeit ist ein zentraler Wettbewerbsfaktor im digitalen Zeitalter.

Vieles in oder zwischen Unternehmen kann durch digitale Technologien und durch die Analyse von Daten schneller, **effizienter** und einfacher erledigt werden. Aber auch **Innovationen**, wie zum Beispiel neue Produkte, Geschäftsmodelle oder Services werden so ermöglicht. Daten oder die Ergebnisse aus der Datenanalyse können zudem **verkauft** werden. In diesen Möglichkeiten liegt eine grosse **Chance** für Unternehmen. Data Science birgt dann das Potenzial, die Performance von Unternehmen zu verbessern (Fosso Wamba et al., 2017; Henke et al., 2016). Meist geht dies jedoch nicht, ohne die Wertschöpfung des Unternehmens neu zu ordnen.

Die digitale Transformation allgemein und die Nutzung von Daten birgt damit gleichzeitig auch **Risiken**. Denn der Umgang mit Daten muss erst ausgetestet und erprobt werden, für viele Unternehmen ist Data Science ein unbekanntes Terrain. Was bei Google, Apple oder jungen Start-ups so einfach zu gelingen scheint, gleicht für KMU dann oft dem Betreten einer «neuen Welt». Denn gerade die Chancen einer neu geordneten Wertschöpfung bedeuten auch, dass etablierte Denk-, Arbeits- und Handlungsweisen an ihre Grenzen stossen und neu austariert oder sogar ersetzt werden müssen. Neue Wege brauchen auch neue Methoden und Unternehmen, die mit Daten arbeiten möchten, müssen anders funktionieren als Unternehmen,

welche dies nicht tun. Für viele etablierte KMU stellt dies zunächst eine grosse Hürde dar. Denn nahezu alle Ressourcen sind in einem KMU begrenzt, ein aufwändiger Versuchs- und Irrtumsprozess («trial and error») ist im gedrängten Alltag häufig kaum möglich. Hinzu kommt, dass (junge) Technologieunternehmen oft schon einen Schritt weiter sind: sie definieren die neuen Regeln, welche etablierte Unternehmen erst kennenlernen und verstehen müssen. Insbesondere für Praktiker bleibt in diesem Zusammenhang oft unklar, was genau die Unterschiede zwischen «Digitalisierung» allgemein und konkret «Data Science» sind. Die genannten Aspekte werden auch der Digitalisierung allgemein zugesprochen.

Insgesamt stehen daher vor allem für etablierte Unternehmen aus strategischer Sicht zwei Fragenkomplexe im Mittelpunkt der Diskussion um Daten und Data Science:

- (1) Wie können die **Chancen** von Daten und Data Science für das eigene Unternehmen genutzt werden?
- (2) Welche **Herausforderungen** entstehen für das eigene Geschäft durch andere Unternehmen, die Daten und Data Science nutzen und wie kann jeweils damit umgegangen werden?

Erhoffter Nutzen aus Daten und Data Science

Welchen Nutzen erhoffen sich Unternehmen aus der Arbeit mit Daten und Data Science? Im Rahmen der Studie wurden in den Interviews unter anderem die nachfolgenden Ziele im Zusammenhang mit einem Engagement im Bereich der Daten und Data Science von den KMU genannt. Dabei lassen sich sowohl direkte als auch indirekte Effekte feststellen:

- Marktanteil gewinnen
- Geschäft ausdehnen, wachsen
- Mehrwert für die Kunden generieren
- Investition in die eigene Marke und das Image als innovatives Unternehmen
- Mehr Informationen über Kunden gewinnen
- Zukunftssicherung
- Den Veränderungen auf dem Markt proaktiv begegnen
- Effizienter werden, Kosten sparen, etc.

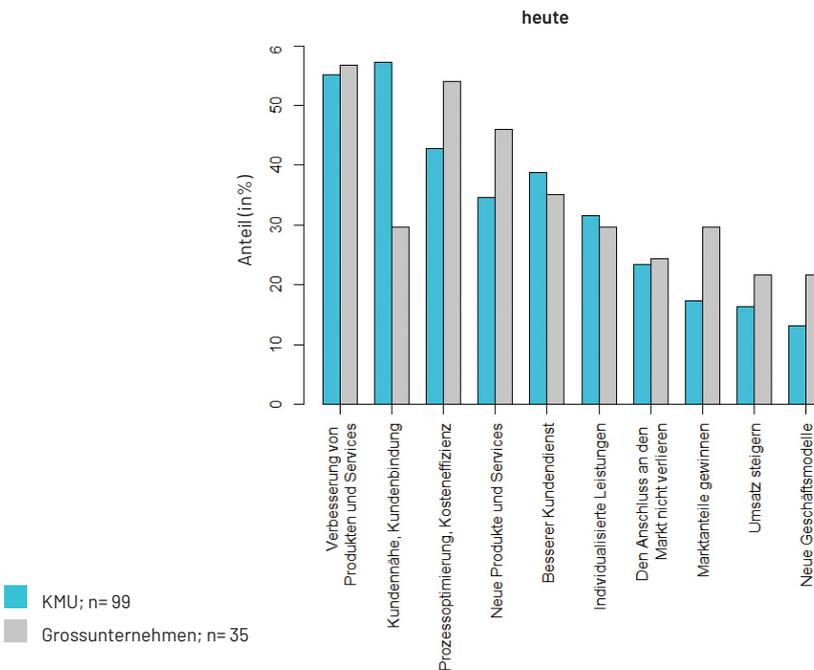


Abbildung 13 a): Von KMU und Grossunternehmen wahrgenommener Nutzen von Data Science (heute). Eigene Darstellung.

Im Rahmen der quantitativen Erhebung zeigte sich, dass es einen Unterschied zwischen dem heutigen und dem zukünftig vermuteten Nutzen aus Daten gibt. Die befragten Unternehmen sehen zum **aktuellen Zeitpunkt** vor allem eine «Verbesserung von Produkten und Services», «Kundennähe und Kundenbindung», sowie «Prozessoptimierung und Kosteneffizienz» als zentrale Möglichkeiten, um aus Daten Nutzen zu generieren. Heute schon

stehen sowohl **operative Ziele** als auch strategische Ziele im Mittelpunkt der Nutzung von Daten. Dabei geht es vielfach um unmittelbare Effekte, die an das aktuelle Kerngeschäft direkt anknüpfen, sowie um eine Steigerung der Effizienz, siehe hierzu die Abbildung 13 a) und 13 b). Tatsächlich scheint es insofern heute noch vor allem um operative Ziele zu gehen.

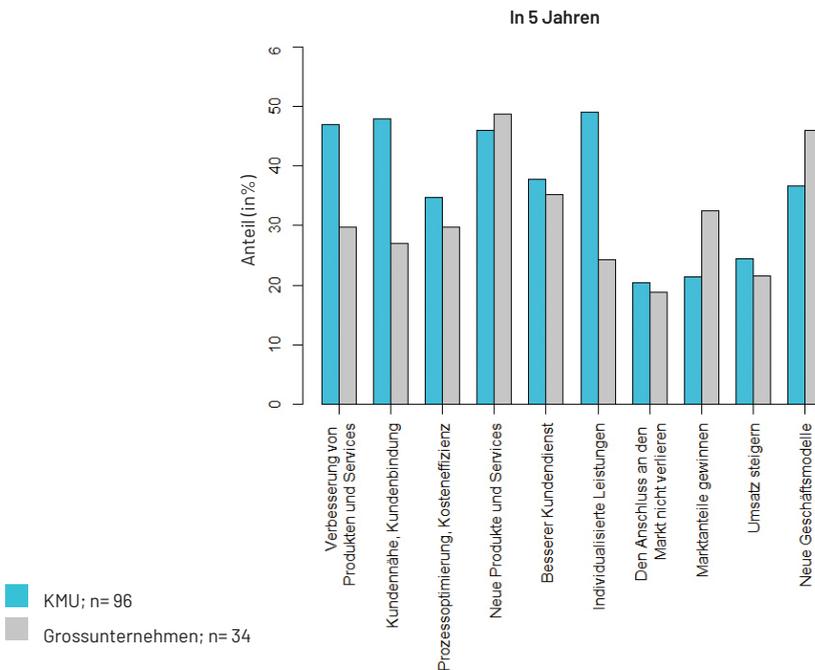


Abbildung 13 b): Von KMU und Grossunternehmen wahrgenommener Nutzen von Data Science (in fünf Jahren). Eigene Darstellung.

In **fünf Jahren** vermuten sowohl KMU als auch Grossunternehmung tendenziell eine Verschiebung von den operativen hin zu stärker **strategischen Zielen** wie «Marktanteile gewinnen», «individualisierte Leistungen» oder «neue Geschäftsmodelle». Die Aussagen sind bei Grossunternehmen deutlicher ausgeprägt als bei KMU. Diese Ergebnisse deuten darauf hin, dass die Bedeutung von Daten und Data Science für ihr Geschäft künftig steigen wird, siehe hierzu auch Kapitel 1. Unklar ist dabei, ob sich die befragten Unternehmen auf den möglichen (erreichbaren) Nutzen oder auf erhoffte Ziele beziehen. Die Ergebnisse zeigen aber auch, dass das längerfristige Potenzial, das mit Daten verbunden wird,

vermehrt im Bereich von **Innovationen** liegt. Interessanterweise darf die **Effizienz** nicht darunter leiden. In Zukunft müssen Unternehmen beides leisten: sowohl effizientes als auch innovatives Arbeiten, und Daten sollen sie auf diesem Weg unterstützen. Indem Neues erobert werden kann, müssen möglicherweise auch das bisherige Geschäft, die Organisation und das Geschäftsmodell verändert werden. Dies ist per se mit mehr Unsicherheit verbunden und es benötigt auch mehr und andere Ressourcen als die bisherigen. Die befragten Unternehmen widmen ihre Aufmerksamkeit also zunächst den «low hanging fruits» (operative Ziele, Effizienz) bevor neue Bäume gepflanzt werden (strategische Ziele, Innovation).

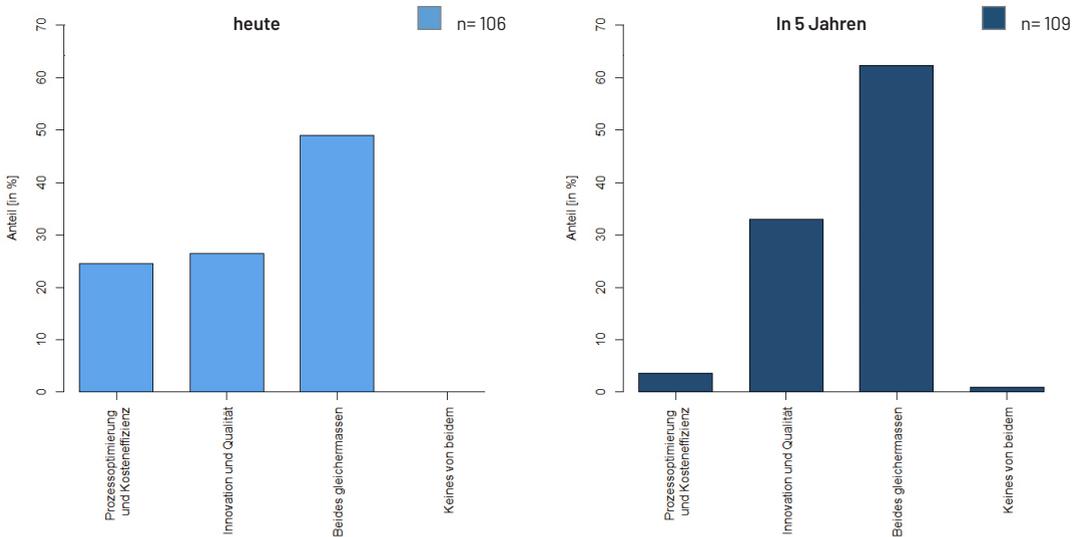


Abbildung 14: Innovation vs. Effizienz als strategische Ziele für KMU und Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

Daten verändern den Wettbewerb

Daten und Data Science als strategische Option zu betrachten, macht durchaus Sinn. Denn bereits zum aktuellen Zeitpunkt berichten Unternehmen von grundlegenden Veränderungen auf dem Markt und im Wettbewerb, die der Nutzung von Daten zugeschrieben werden (siehe Abbildung 15). Diese werden heute von Grossunternehmen bereits stärker wahrgenommen als von KMU. Auch wenn diese Veränderungen die Unternehmen zum Teil noch nicht direkt betreffen, so sind sie doch schon in ihrem Umfeld zu spüren. Die befragten Unternehmen berichteten in den Interviews aber davon, dass sich etliche Unternehmen von den Veränderungen und den möglichen Konsequenzen distanzieren:

sie scheinen «gefühl» noch weit weg zu sein, sie betreffen «die anderen», aber noch nicht das eigene Unternehmen:

«Sie [die Unternehmen] sehen es, kennen die Beispiele von CD, Fotokamera, Video etc., aber beziehen das [Veränderungen im Wettbewerb] nicht auf sich.» (Unternehmen 8, IT-Beratung)

Für die Zukunft wird von einer weiteren Verschärfung der Situation ausgegangen. Sowohl Grossunternehmen als auch KMU gehen davon aus, dass Daten den Wettbewerb bis in fünf Jahren deutlich verändern.

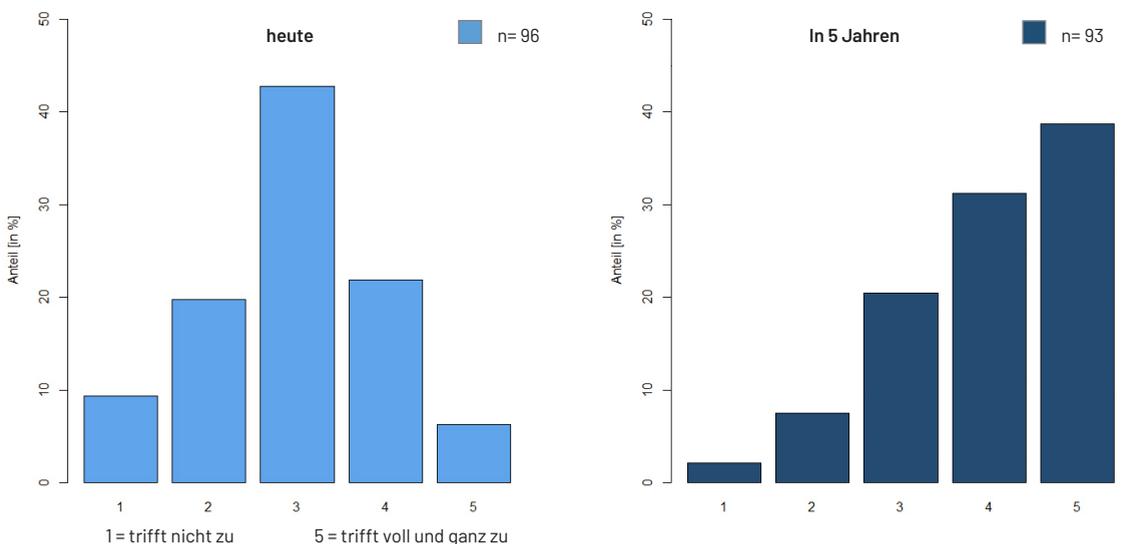


Abbildung 15: Die Nutzung von Daten verändert den Wettbewerb: KMU und Grossunternehmen gemeinsam (heute und in 5 Jahren). Eigene Darstellung.

So rechnen beide Unternehmenskategorien etwa damit, dass neue Wettbewerber aus anderen Branchen auftauchen, welche ihr Geschäft auf Daten aufbauen. Solche Konkurrenten sind oft besonders gefährlich, da sie anders als das Bekannte funktionieren und von den Etablierten nicht immer wahrgenommen werden. In manchen Fällen geht es um Disruptionen, welche die etablierten Unternehmen mit einfachen Produkten und Services angreifen oder einen ganz neuen Markt begründen. Sie sind interessant, da sie durch die Auswertung von Daten einen neuen Nutzen anbieten, den es bislang nicht gab (siehe zu Disruptionen allgemein Christensen, 1997; Christensen et al., 2016; zu Disruptionen im digitalen Kontext Kugler und Tietz, 2019; Kugler, 2019a+b). Erneut fällt das Urteil der Grossunternehmen stärker aus als das der befragten KMU.

Die Veränderung des Wettbewerbs wird unter anderem daran deutlich, dass Daten heute schon die Funktionsweise und den Aufbau der Wertschöpfung neu strukturieren. So wird zum Beispiel von Veränderungen in der Wertschöpfungskette berichtet, indem sich die Rollen der Spieler verändern und einzelne Spieler bzw. ganze Stufen der Wertschöpfungskette obsolet werden oder die Wertschöpfung wird neu strukturiert. Auch werden Märkte heterogener und Branchengrenzen verschwimmen zunehmend. Zum Teil formieren sich stattdessen neue Strukturen,

etwa durch Ökosysteme (oder: «Ecosystems») mit neuen unternehmerischen Partnerschaften, welche nicht mehr den etablierten Kategorien, wie etwa Branchen, genügen. Solche neuen Strukturen verwirren, denn sie passen nicht in unsere etablierten Denkschemata und Begrifflichkeiten, mit welchen Unternehmen die Situation analysieren und beschreiben. Daher geht von ihnen eine grosse Gefahr aus, sie werden oft nicht erkannt.

Interessanterweise sind es dabei zum aktuellen Zeitpunkt vor allem KMU, welche die Veränderungen in der Wertkette tendenziell stärker wahrnehmen als die befragten Grossunternehmen, wobei die Antworten auch polarisierend ausfallen. Dies könnte daran liegen, dass KMU oft heute schon stärker in Wertschöpfungsnetze eingebettet sind als Grossunternehmen. Dabei kommt es zu zahlreichen wechselseitigen Abhängigkeiten. Sobald ein Spieler beginnt, mit Daten zu arbeiten, hat dies massive Auswirkungen auf die anderen Beteiligten im Netzwerk. Das gesamte System, die gesamte Wertschöpfung muss dann auf Daten ausgerichtet werden, um das mögliche Potenzial zu nutzen. Für die Zukunft in 5 Jahren gehen beide Unternehmenskategorien von einer deutlichen Verstärkung des beschriebenen Effektes aus (siehe Abbildung 16 und Abbildung 17).

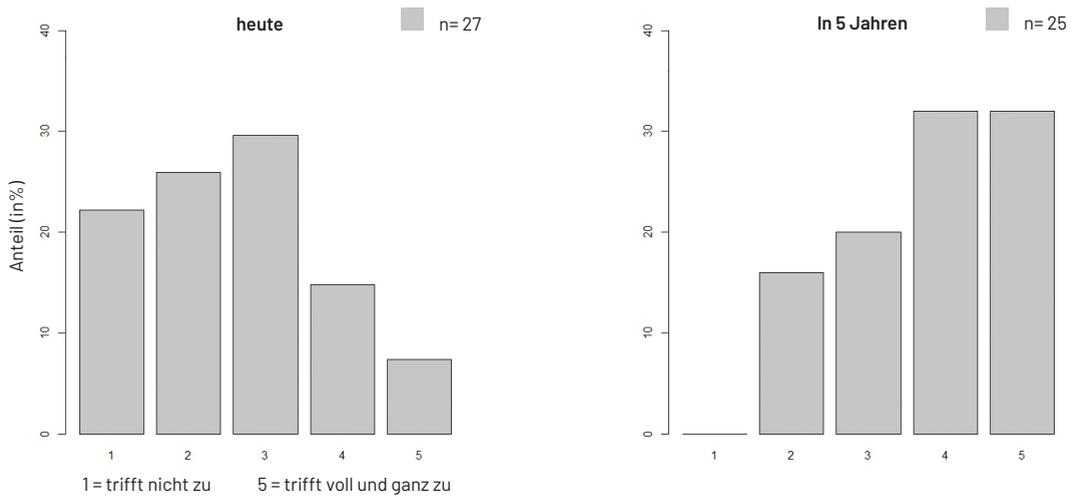


Abbildung 16: Die Nutzung von Daten führt zu einer Neustrukturierung der Wertkette: Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

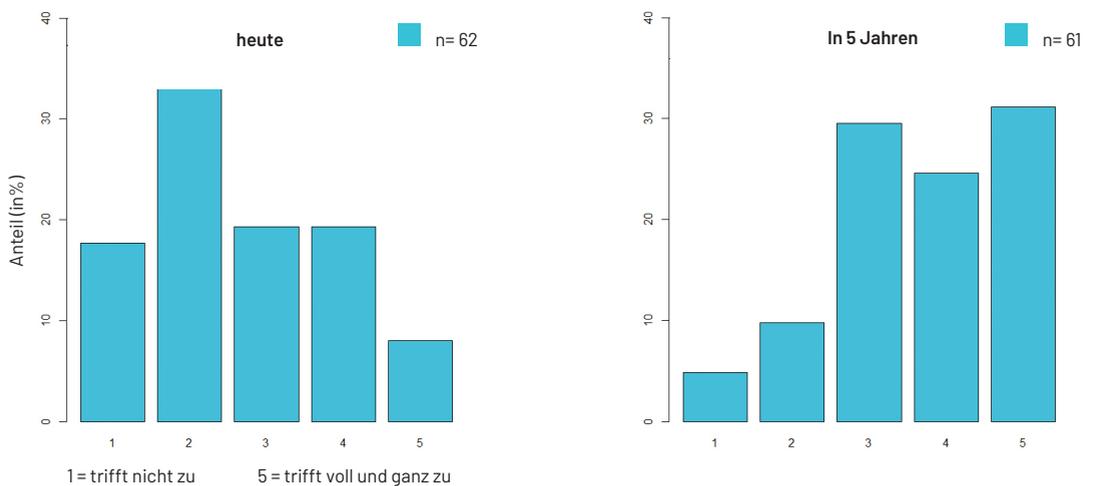


Abbildung 17: Die Nutzung von Daten führt zu einer Neustrukturierung der Wertkette: KMU (heute und in 5 Jahren). Eigene Darstellung.

Wettbewerbsrelevante Charakteristika von Daten und Data Science

Immer wieder spielen bei den skizzierten Veränderungen des Wettbewerbs auch weitere digitale Technologien (z.B. IoT, Internet of Things) eine Rolle. Vor allem die grossen amerikanischen Technologiekonzerne, aber zunehmend auch kleine Startups, sind bereits dabei, den Charakter des bisherigen Wettbewerbs, oder die «Spielregeln des Wettbewerbs» grundlegend zu verändern. Denn die Nutzung von digitalen Daten für das eigene Business bietet im Vergleich zu physischen Produkten einige Charakteristika, die für Unternehmen vorteilhaft sind. Dazu gehört die Möglichkeit, grosse Mengen an Nutzern, Kunden, Daten, Interaktionen etc. zu analysieren, ebenso wie von Netzwerkeffekten, Skaleneffekten, exponentiellen Wachstumsraten, so gut wie keine Transaktionskosten und von der damit verbundenen grossen Komplexität zu profitieren (Chui und Manyika, 2015; Henke et al., 2016; Remane et al., 2017). Diese Eigenschaften können einen nachhaltigen Wettbewerbsvorteil für die betroffenen Unternehmen begründen, sie sind von anderen Unternehmen nur schwer zu imitieren. Verschiedene Aktivitäten, die mit Daten verknüpft sind, bieten die Möglichkeit unterschiedliche starke Wettbewerbsvorteile aufzubauen. Für eine ausführliche Darstellung der veränderten «Spielregeln im Wettbewerb» siehe Kugler und Tietz, 2019, sowie Kugler, 2019a-f.

Zugleich verlieren traditionelle Werte (z.B. Maschinen oder andere physische Produkte) in einem durch Daten veränderten Wettbewerb an Wert und an Bedeutung. Daten haben aber nie einen Selbstzweck, sie sollten stets im Hinblick auf einen bestimmten Nutzen (z.B. Effizienz oder Innovation, Kundenkenntnis, etc.) oder eine bestimmte Zielsetzung betrachtet werden.

Daten können produzierenden Unternehmen auch dabei helfen, den Schritt hin zum Lösungs- oder Serviceanbieter zu gehen. Dies zum Beispiel, indem Gebühren für Ergebnisse aus der Datenanalyse von bisherigen oder neuen Kundengruppen verlangt werden. Häufig verschiebt sich dann das Tätigkeitsfeld von Unternehmen von der Produktion hin zum Management der entstehenden Netzwerke und Ecosystems (Chui und Manyika, 2015). Denn Nutzer, Geräte und Organisationen müssen neu verknüpft und koordiniert werden. Daten bieten also die Möglichkeit, den Prozess der Wertschöpfung neu zu ordnen und neue Geschäftsmodelle zu etablieren.

In den Interviews wurde im Zusammenhang eines veränderten Wettbewerbs der Begriff «Paradigmenwechsel» benutzt, der darauf hindeutet, dass Daten und Data Science vor diesem Hintergrund zu einer völlig veränderten Wettbewerbssituation führen können. Daten wird dann das Potenzial zugesprochen, das Bisherige und Abschätzbare, grundlegend zu verändern:

*«Aber man merkt schon, wie sich die Märkte zu wandeln beginnen, vor allem im globalen Wettbewerb. [...] Man merkt, dass von der Industrie ein Wandel ausgeht. Die Bemühungen, Händlernetze aufzubauen und zu unterhalten, halten sich immer mehr in Grenzen. Man versucht seitens der Industrie, Daten von den Endkunden zu bekommen, um direkt vertreiben zu können. Da spielt das Internet, die Digitalisierung schon eine sehr grosse Rolle. [...]. Aber der mittelbare Effekt, dass der Hersteller seinen Händler loswerden und direkt an den Kunden ran will, der ändert auch unser Geschäft»
(Unternehmen 4, Dienstleistung)*

Die Folgen für das eigene Unternehmen sind dann nicht immer klar ersichtlich. Diese strukturellen Veränderungen spiegeln das veränderte Verhalten vieler Verbraucher, angestossen durch neue technische (digitale) Möglichkeiten. Es gilt dann zu reflektieren, wie sich solche grundlegenden Veränderungen auf das eigene Geschäft auswirken können. Zentral ist es, dass Unternehmen die Veränderungen frühzeitig wahrnehmen, diese analysieren und sich mit den möglichen Konsequenzen ehrlich und ohne diese zu verharmlosen auseinandersetzen.

Daten können vor diesem Hintergrund zu Vorteilen im **Wettbewerb auf zwei Ebenen** führen: (1) Wettbewerbsvorteile für die **Nutzer** von Daten im Vergleich zu **Nichtnutzern**; sowie (2) Wettbewerbsvorteile für Unternehmen, welche Daten auf eine **andere Art und Weise** nutzen als dies vergleichbare Unternehmen tun.

Wettbewerbsvorteile für Daten-Nutzer im Vergleich zu Nicht-Nutzern: Die fünf «V's»

Die wettbewerbsverändernden Charakteristika von Daten und Data Science werden häufig anhand von bis zu fünf zentralen Eigenschaften, die sogenannten fünf «V's» beschrieben, wobei die «V's» für die englischsprachigen Originalbegriffe stehen (z.B. Fosso Wamba et al., 2015, 2017; Remane et al., 2017), siehe Abbildung 18. Was verbirgt sich dahinter?

Aufgrund der grossen Datenmengen, die durch digitale Technologien zur Verfügung stehen, können durch Data Science sehr aussagekräftige Muster in den Daten gefunden werden («**Volume**»). Die Daten können aus zahlreichen verschiedenen Kontexten stammen, die neu kombiniert zu bisher unerkannten Einsichten, z.B. zum Kundenverhalten, führen («**Variety**»). Dazu kommt, dass Daten aus Maschinen in der Produktion oder aus dem Nutzungsverhalten des Internets quasi in Echtzeit zur Verfügung stehen. Sie werden immer und überall erhoben und es entsteht keine zeitliche Verzögerung zwischen Datenerhebung und Datenauswertung («**Velocity**»).

Daten können damit zur Beschreibung von Sachverhalten genutzt werden, über die bisher keine oder keine verlässlichen Aussagen getroffen

werden konnten (z.B. Aussagen von Kunden über ihr Verhalten müssen nicht das tatsächliche Verhalten spiegeln, sondern können sich auch auf ein sozial erwünschtes Verhalten beziehen). Datenbasierte Entscheide ersetzen somit intuitive Entscheide, die auf vagen Daten oder auf einem «Bauchgefühl» basieren. Daten können schliesslich dabei helfen, Werte für Unternehmen zu generieren, dies über neue Produkte, Services oder Geschäftsmodelle («**Value**»). Gerade die Analyse der durch die schnelle Veränderung und die grosse verfügbare Menge grundlegend schwer verständlichen Daten («**Veracity**») kann dabei zu neuen Erkenntnissen und zu neuen Werten führen.

In den fünf «V's» liegen damit auch Quellen für Wettbewerbsvorteile, die über Daten und Data Science generiert werden können oder auch müssen. Unternehmen, die mit Daten arbeiten, können also potenziell schnellere, bessere, differenziertere und zuverlässigere Entscheidungen zu allen erdenklichen Sachverhalten treffen als Unternehmen, die dies nicht tun. Jedes der genannten «V's» kann einen Vorteil im Wettbewerb darstellen. Wenn es gelingt, alle genannten Vorteile zu realisieren, dann ist die Wirkung umso stärker.

Englischer Originalbegriff	Deutsche Übersetzung	Bedeutung
volume	Menge	«Volume» bezeichnet die unendlich grossen Datenmengen, die verfügbar sind und die gesammelt, gespeichert, analysiert und in neue Werte transferiert werden können.
variety	Unterschiedlichkeit	«Variety» bezieht sich auf zahlreiche unterschiedliche Quellen der Datengenerierung sowie viele verschiedene Datenformate, die verfügbar sind.
velocity	Geschwindigkeit	«Velocity» bezieht sich darauf, dass Daten heute kontinuierlich generiert und in Echtzeit ausgewertet werden können. Sie stehen sofort zur Verfügung.
veracity	Aussagekraft	«Veracity» bezieht sich darauf, dass Daten per se noch kein Wissen sind. Sie müssen erst analysiert und interpretiert werden, um auch tatsächlich Aussagen über Zusammenhänge zu ermöglichen.
value	Wert	«Value», also Werte, können Daten erst dann generieren, wenn sie zu wertvollen Erkenntnissen oder zu einem anderen Nutzen führen. Dies ist der Fall, wenn Unternehmen direkt oder indirekt Gewinne aus Daten schöpfen, z.B. durch Vorteile im Wettbewerb oder durch den Verkauf von Daten oder Erkenntnissen.

Abbildung 18: Data Science – Die fünf «Vs». Eigene Darstellung.

Wettbewerbsvorteile aus Daten und Data Science: Wofür und wie?

Sobald mehrere Wettbewerber Daten für ihre Wertschöpfung nutzen, ist sowohl die Art und Weise, **wofür** Daten eingesetzt werden (Effizienz, Innovation, Verkauf), als auch die Art **wie** sie genutzt werden (sammeln, aggregieren, Analytics), entscheidend. Denn unterschiedliche Aktivitäten im Umgang mit Daten eignen sich mehr oder weniger gut als Grundlage für nachhaltige Wettbewerbsvorteile, die über einen längeren Zeitraum Geltung besitzen. Nachhaltige Vorteile im Wettbewerb entstehen dann, wenn es einem Unternehmen gelingt, einzigartige Ressourcen zu nutzen oder Werte herzustellen, die von (potenziellen) Wettbewerbern nicht oder zumindest nur erschwert imitiert werden können (z.B. Barney, 1991).

Werden Daten im Rahmen des «**wofür**» primär zur **Effizienzsteigerung** eingesetzt, so können Kostenvorteile im Wettbewerb erzielt werden. Konkurrenten, welche nicht mit Daten und Data Science arbeiten, haben dann das Nachsehen. Häufig sind diese Vorteile aber nicht nachhaltig, sie erodieren mit der Zeit, da sie prinzipiell allen Unternehmen offenstehen. Denn je mehr Unternehmen Daten und Data Science für ihre unternehmerischen Aktivitäten nutzen, umso eher werden diese «normal». Sie bilden dann einen neuen Standard im Wettbewerb, der von allen Marktteilnehmern als selbstverständlich erwartet wird. Zum aktuellen Zeitpunkt ist die Integration von Daten und Data Science in das eigene Wertschöpfungsmodell noch eine Option, aber noch kein «Muss», um Effizienzvorteile zu erzielen. Dies kann sich jedoch schnell ändern.

Sofern Daten genutzt werden, um zu **innovativen Lösungen** wie Produkte, Prozesse, Geschäftsmodelle, Services, etc.) zu kommen, können tendenziell nachhaltigere Vorteile im Wettbewerb angestossen werden. Neue Produkte, Services und Prozesse, die auf Daten aufbauen, sind einfacher zu imitieren als Geschäftsmodelle, die ein Zusammenspiel zahlreicher Faktoren auf dem Markt und im Unternehmen erfordern (siehe auch Kugler und Tietz, 2015, 2019; Kugler, 2019c). Solche Lösungen sind meist erheblich komplexer und daher schwieriger zu imitieren.

Sofern ein **Verkauf** von Daten als Service in Erwägung gezogen wird, so hängen die erzielbaren Wettbewerbsvorteile in noch stärkerem Masse (als Effizienz, Innovation) davon ab, wie die Daten bearbeitet wurden. Mehrere Stufen können im Hinblick auf Daten und Data Science unterschieden werden (Henke et al., 2016). Weitgehend unbearbeitete Rohdaten sind besonders wertvoll, solange kein anderes Unternehmen über vergleichbare Daten verfügt. Die Erhebung solcher Daten ist aber generell für Unternehmen möglich, also imitierbar. Jeder weitere Schritt der Bearbeitung wie Aggregieren von Daten aus verschiedenen Quellen sowie die Analyse und Interpretation der Daten macht es schwieriger, die entstehenden Werte zu imitieren. Denn jeder Schritt setzt hinreichende Kompetenzen des Unternehmens voraus, um die Daten in Wissen über komplexe, unbekannte oder unvermutete Zusammenhänge zu transferieren, die einen Wert für potenzielle Kunden besitzen (siehe Abbildung 19).

Wofür werden Daten eingesetzt?	Ermöglichen Wettbewerbsvorteile, sie sind ...		Nachhaltige Wettbewerbsvorteile möglich
	einzigartig	imitierbar	
Effizienzsteigerung	ja	ja	nein
Innovation			
Produktinnovation	ja	ja	nein
Prozessinnovation	ja	meist	nein
Geschäftsmodell-Innovation	ja	teilweise	ja
Organisationale / Management-Innovation	ja	teilweise	ja
Verkauf von ...			
Rohdaten	ja	ja	nein
Aggregierten Daten	nein	teilweise	meist nicht
Analyseergebnisse / Interpretationen	ja	teilweise	ja

Abbildung 19: Wettbewerbsvorteile – Wofür werden Daten eingesetzt? Eigene Darstellung.

Hinreichend Kompetenzen zum Umgang mit Daten, insbesondere zum Aggregieren, Auswerten und Interpretieren der Daten, können Unternehmen daher nachhaltige, über einen längeren Zeitraum gültige, Wettbewerbsvorteile ermöglichen.

Auch für KMU stellt sich damit die (strategische) Frage, ob solche Kompetenzen selbst entwickelt oder «eingekauft» (bzw. rekrutiert) werden oder ob sie von Externen bezogen werden.

Wie werden Daten eingesetzt?	Wirkung	Ermöglichen Wettbewerbsvorteile, sie sind ...	
		einzigartig	nicht imitierbar
Sammeln von Rohdaten	<ul style="list-style-type: none"> • Das Sammeln von Daten wird einfacher, Kosten für die Datenspeicherung sinken • Ehemals knappe Daten werden breiter verfügbar und ggfs. zum Massengut • Herausbildung eines neuen Standards ist möglich («Muss» für Unternehmen) 	nein	nein
Aggregieren von Daten aus unterschiedlichen Quellen	<ul style="list-style-type: none"> • Die Kombination, Verarbeitung, Aggregation von Daten ist technisch anspruchsvoll oder organisatorisch schwierig • Nicht alle Unternehmen können diese Aktivitäten vornehmen 	ja/nein	ja/nein
Analytics, Datenauswertung und -interpretation	<ul style="list-style-type: none"> • Daten sind noch keine Erkenntnis, erst deren sinnvolle Interpretation liefert wertvolle Informationen • Hier könnte das grösste Potenzial zur Generierung von Wettbewerbsvorteilen liegen 	ja	ja

Abbildung 20: Wettbewerbsvorteile – Wie werden Daten eingesetzt? Eigene Darstellung.

Heutiger Erfolg verhindert Data Science-Strategie

Häufig bleiben die beschriebenen Aktivitäten bei den im Rahmen der Studie untersuchten und befragten Unternehmen zum aktuellen Zeitpunkt noch punktuell. Sie werden jedoch nicht flächendeckend eingesetzt. Es kann dann (noch) nicht von einer «Digitalisierungs-Strategie» oder von einer «Daten-Strategie» gesprochen werden. Dabei scheinen real wahrnehmbare, aber auch diffuse Befürchtungen und Ängste eine zentrale Rolle als Hürde für ein Engagement auf dem Gebiet der Daten und Data Sciences zu spielen. Da ein solches Engagement für viele KMU schnell mit hohen initialen Kosten («Sunk Costs») verbunden ist, warten viele Unternehmen noch ab, insbesondere, wenn das Outcome des Engagements nicht klar greifbar ist. Wahrnehmbar ist dann ein grosser

Respekt davor, falsche Handlungen zu ergreifen. Auch werden der aktuelle oder bisherige Erfolg vieler Unternehmen, ebenso wie das grosse Engagement in operativen, dringlichen Themen, als mögliche Hürden für ein rasches Engagement auf dem Gebiet der Daten und Data Sciences gesehen. Dies spiegelt sich auch in den Antworten der im Rahmen der Studie befragten KMU und Grossunternehmen wider (siehe Abbildung 21).

Häufig wird dann die Geschwindigkeit, mit der sich neue Technologien und Tools (wie Data Science) etablieren, unterschätzt. Paradoxerweise sind es oft die erfolgreichen Unternehmen, welche den Anschluss verpassen können. Der heutige Erfolg kann zu einer vermeintlichen Sicherheit führen, die

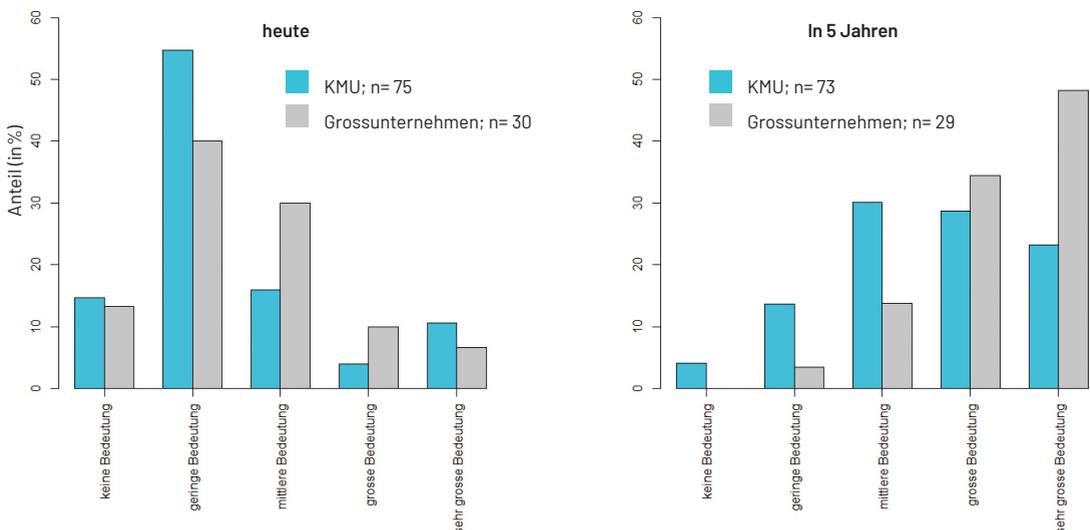


Abbildung 21: Strategische Bedeutung von Data Science in KMU und in Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

durch neue Technologien in disruptiven Prozessen unterwandert wird. Zu grosser heutiger Erfolg kann Unternehmen dann daran hindern, Neues anzupacken, welches ihre Zukunft sichert, da keine Dringlichkeit zum Handeln empfunden wird (siehe zu Disruptionen allgemein Christensen, 1997; Christensen et al., 2016). Es fehlt dann generell an einer wahrgenommenen Dringlichkeit zum Wandel (siehe Abbildung 9 in Kapitel 1). Vielen KMU scheint dabei bewusst zu sein, dass eine stärkere Nutzung von Daten möglicherweise dazu führt, dass das bisherige Geschäftsmodell und die bisherige Funktionsweise des Unternehmens in Frage gestellt werden. Viele unternehmerische Parameter müssen dann grundlegend verändert werden, um die Wertschöpfung auf Daten auszurichten. Grosse Veränderungsprojekte beinhalten aber stets die Gefahr des Scheiterns oder sie führen zu tiefgreifenden Verschiebungen für Führungskräfte (z.B. Machtbereich, Hierarchie), Mitarbeitende (Zuständigkeiten) oder andere Stakeholder (Kunden, Lieferanten). Unternehmen scheinen also zu ahnen, dass möglicherweise ein Teil des Bisherigen aufgegeben werden muss, um neue Ufer zu erreichen. Das Ergebnis bleibt indes unklar, die ergriffenen Handlungen können den KMU dann möglicherweise eher schaden als die aktuelle Situation tatsächlich zu verbessern.

«Und dann sagen Leute oft «never change a running System», also warum etwas anders machen, auch wir.» (Unternehmen 1, IT-Beratung)

«Aber denen [KMU] geht es oft auch einfach zu gut momentan. Die Auftragsbücher sind voll, usw. [Die Unternehmen fragen sich dann] Was soll ich mich jetzt damit beschäftigen, ich habe so viele andere Themen.» (Unternehmen 2, IT-Beratung)

Für andere Unternehmen ist der aktuelle Erfolg eine gute Voraussetzung für ein Engagement auf dem neuen Gebiet, da so ein finanzieller Spielraum zum «Ausprobieren» entsteht. Entscheidend scheint also ein weiterer Faktor zu sein, der mit der vorherrschenden Kultur, dem Mindset oder auch mit dem Engagement von Einzelpersonen im Unternehmen zu tun hat. Auch wird darauf verwiesen, dass externe Berater eine hilfreiche, da neutrale Expertenrolle einnehmen können.

«Wir haben einfach gesagt, wir wissen, das ist die Zukunft, das sind die Themen, die gehen wir an und wir wussten von vornerein das ist ein grosser Feldtest und das wird uns jetzt erstmal ein paar Jahre Geld kosten und zwar richtig Geld. Solange unser eigentliches Geschäft gut läuft und die entsprechenden Erträge abwirft, machen wir das so, weil das unsere Zukunftssicherung ist.» (Unternehmen 3, Maschinenbau)

Es sind unterschiedliche Handlungen der KMU wahrnehmbar, wie mit den aufgezeigten Veränderungen auf dem Markt, im Wettbewerb und mit den neuen technischen Möglichkeiten umgegangen wird. Dazu gehören einerseits **neue Kooperationsmodelle** und andererseits **neue Geschäftsmodelle**.

Wo Data Science stattfindet: In-House, Outsourcing und neue Kooperationsmodelle

Um Daten und Data Science aktiv zu nutzen, braucht es für KMU bestimmte Voraussetzungen. So werden unter anderem eine **Mindestgrösse** und die Bereitschaft (bzw. finanzielle Möglichkeit) zu Investitionen angeführt. Ein Engagement auf dem Gebiet von Daten und Data Science ist schon zu einem frühen Zeitpunkt mit hohen, oft auch unsicheren **Investitionen** verbunden, die nicht für alle KMU ohne weiteres zu stemmen sind. Denkbar ist dann das **Outsourcing des Datengeschäfts** an einen Datendienstleister.

Damit besteht jedoch auch die Gefahr des Verlustes der Kontrolle über einen möglicherweise strategischen und sensitiven Bereich (heute oder künftig). Den Unternehmen gelingt es dann nur begrenzt, eigene Erfahrungen zu sammeln und Wissen selbst

aufzubauen, eine Abhängigkeit von Externen kann entstehen. Insofern verwundert es nicht, dass der Outsourcing-Entscheid von der wahrgenommenen strategischen Bedeutung der Daten abhängt. Das Ziel ist es dann, strategisch relevante Datengeschäfte, im Haus zu behalten, während weniger kritische Bereiche ausgelagert werden (können). Die Auslagerung des Bereichs an einen externen Datendienstleister setzt zudem voraus, dass die Unternehmen bereits Klarheit über ein mögliches datengetriebenes Geschäftsmodell bzw. über die erforderlichen Prozesse verfügen. Für viele Unternehmen ist dies heute noch nicht der Fall, das Thema «Data Science» ist noch zu neu. So verwundert es nicht, dass KMU externen Beratern kritisch gegenüberstehen, während diese Option für Grossunternehmen eher in Frage kommt (Abb. 22).

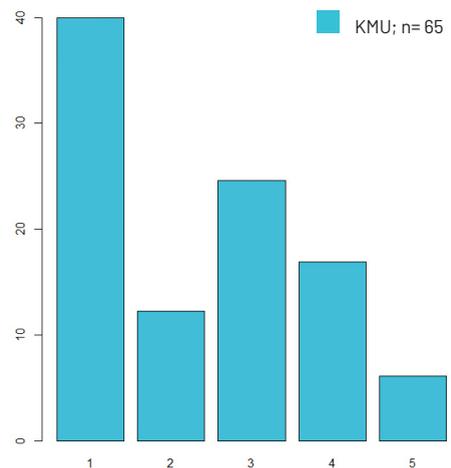
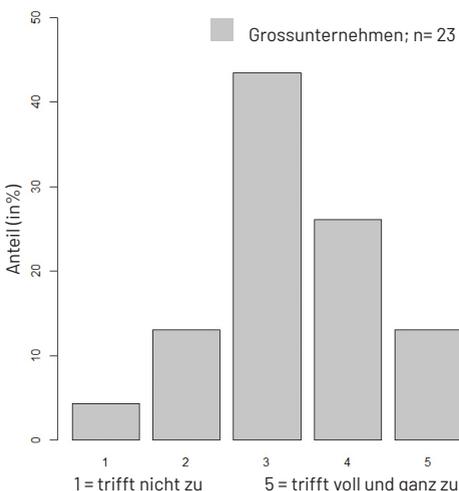


Abbildung 22: Data Science Know-How von externen Spezialisten in Grossunternehmen und in KMU. Eigene Darstellung.

«Wir müssen alles, was für uns unternehmenskritisch ist, im Haus haben.» (Unternehmen 3, Maschinenbau)

Sofern externe Berater in Anspruch genommen werden, wählen KMU kleine, lokale Anbieter, zum Teil in Kombination mit grösseren Unternehmen. Grossunternehmen sind hingegen weniger auf eine bestimmte Unternehmenskategorie fixiert (siehe Abbildung 23).

Häufig ist die **Inhouse-Variante** zum aktuellen Zeitpunkt (noch) keine Option, da das notwendige Wissen und die Kompetenzen im Unternehmen nicht vorhanden sind. Dies betrifft die Datenanalyse

ebenso wie die Vielfalt möglicher Technologien, die kontinuierlich wächst. Hinzu kommt, dass bereits heute ein akuter Mangel an technischen Mitarbeitenden, insbesondere auf den Gebieten der Datenanalyse, IT und Software, besteht. Vor allem in ländlichen Gegenden ist es schwierig, qualifiziertes Personal zu rekrutieren. Gerade kleinere Unternehmen haben nicht die erforderliche Mindestgrösse, um eine oder mehrere Personen in diesem Bereich in Vollzeit zu beschäftigen. In allen Fällen braucht es jedoch grundlegende Software-Kenntnisse im Unternehmen, entweder um eigene Lösungen zu entwickeln, oder um externe Lösungen überhaupt beurteilen zu können.

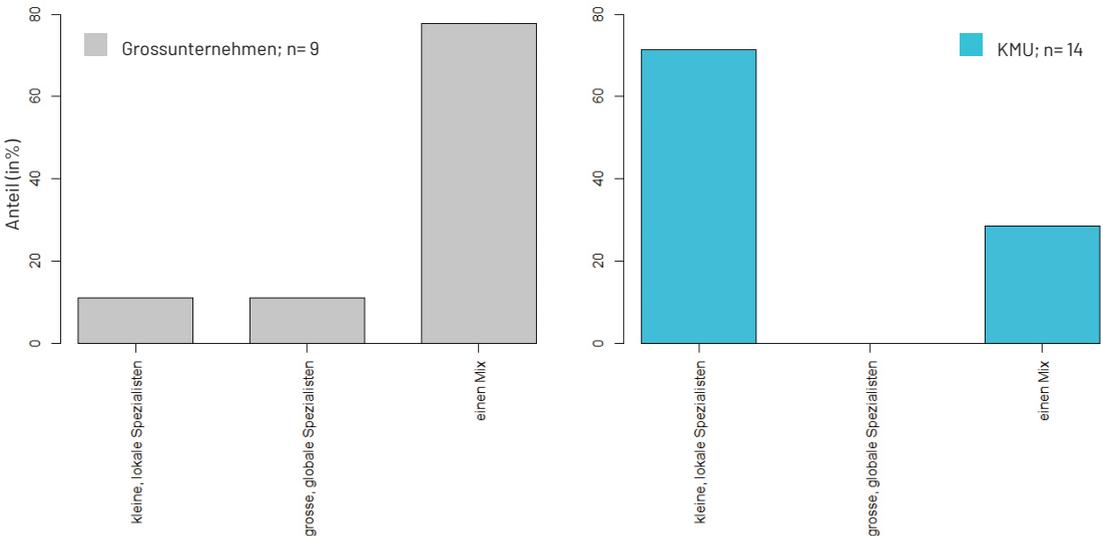


Abbildung 23: Das Unternehmen setzt auf diese Spezialisten: Grossunternehmen und KMU. Eigene Darstellung.

«Wir wissen ja noch gar nicht ob wir die Leute kriegen. Wir werden für beide Wegen die Augen offen halten: kaufen wir uns extern Know-How ein oder intern? Langfristig ist uns «intern» natürlich lieber, aber ich brauche auch nie alles intern. Aber momentan kann es sein, dass falls wir eine Stelle auf absehbarer Zeit nicht besetzen können, dann müssen wir extern zukaufen.» (Unternehmen 3, Maschinenbau)

Ein alternativer Weg liegt darin, **gezielt Partnerschaften** mit anderen Unternehmen einzugehen, und gemeinsam Kompetenzen auf dem Gebiet der Daten und Data Science aufzubauen. Eine Option kann dann darin bestehen, gemeinsam mit einem

anderen Unternehmen eine Lösung zu entwickeln, die durch alle Beteiligten genutzt werden kann, zum Beispiel, indem ein gemeinsames Start-up / Kompetenzzentrum gegründet wird. Eine Voraussetzung für eine derartige Lösung ist es, dass die beteiligten Unternehmen keine Wettbewerber sind, auch ist ein gemeinsames Auftreten der Partner auf dem Markt nicht erforderlich. Diese Lösung bietet den Vorteil, dass eine individuelle Lösung erarbeitet werden kann, die ggfs. nicht auf dem Markt erhältlich ist. Sowohl die Mehrheit der KMU als auch der Grossunternehmen können sich eine solche Lösung prinzipiell vorstellen, die KMU aber leicht ausgeprägter (siehe Abbildung 24).

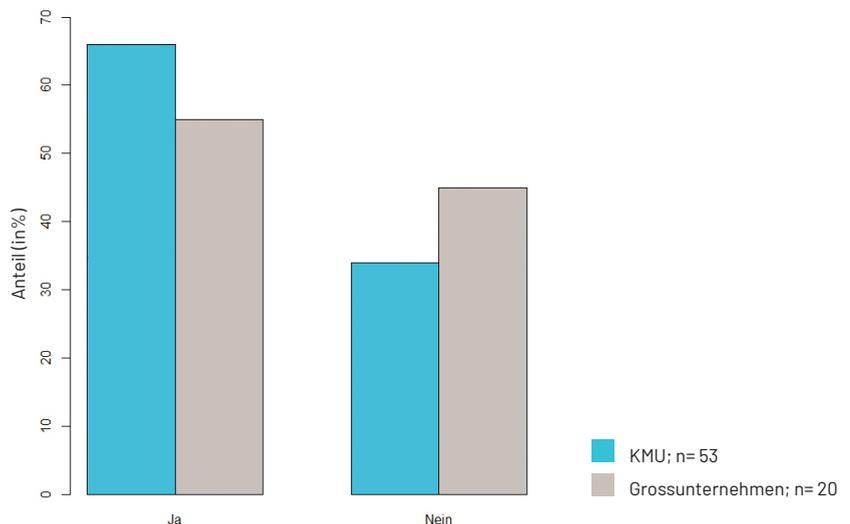


Abbildung 24: Gemeinsames Kompetenzzentrum: KMU und Grossunternehmen. Eigene Darstellung

Was KMU tun können

KMU sollten sich an den beiden identifizierten strategischen Fragenkomplexen (Chancen und Herausforderungen), die mit Data Science verbunden sind, orientieren. Das heißt, es gilt, die **Chancen**, die sich dem eigenen Unternehmen bieten, genau auszuloten und anhand erster Pilotprojekte zu lernen (siehe hierzu auch Kapitel 1). Wofür können in diesem Zusammenhang Daten und Data Science eingesetzt werden (Effizienz, Innovation, Verkauf)? Welche Voraussetzungen müssen dazu erfüllt sein? Wie können Daten genau bearbeitet werden (unbearbeitete Rohdaten, Aggregieren, Analyse und Interpretation)? Welche Kompetenzen sind dazu notwendig, und möchte das Unternehmen diese selbst aufbauen oder von Externen beziehen?

Ebenso zentral ist es, **Veränderungen** im Wettbewerb, die aufgrund von Data Science entstehen, wahrzunehmen. Welche Konsequenzen haben diese Bewegungen für das eigene Unternehmen? Wird es das eigene Geschäft künftig noch in dieser Form brauchen, welche Rolle könnten Daten bei einer Neupositionierung spielen? Auf keine dieser Fragen gibt es eine einzig richtige Lösung. Vielmehr muss jedes Unternehmen ausloten, welche Risiken es zu tragen bereit ist, oder auch nicht. Die Integration von Daten in ein bestehendes oder in ein neues Geschäftsmodell kann dabei ein zentraler Schritt sein. Auf Daten, Data Science und Geschäftsmodelle wird im nächsten Kapitel eingegangen.

Die wichtigsten Erkenntnisse

- Zwei Fragenkomplexe stehen im Mittelpunkt der strategischen Diskussion um Data Science, (1) Wie können die Chancen von Daten und Data Science für das eigene Unternehmen genutzt werden? (2) Welche Herausforderungen entstehen durch andere Unternehmen, welche Daten und Data Science nutzen und wie kann damit umgegangen werden?
- Heute werden mit Data Science in Unternehmen vor allem operative Ziele zur Effizienzsteigerung verfolgt. Künftig kommen auch strategische Ziele und Innovationsstreben hinzu.
- Daten haben das Potenzial, den Wettbewerb zu verändern. Möglich ist ein Paradigmenwechsel mit neuen Spielregeln im Wettbewerb. Dazu gehören unter anderem neue Wettbewerber, die Daten nutzen und eine Veränderung der Wertschöpfungskette.
- Anhand von Daten und Data Science können Vorteile im Wettbewerb generiert werden. Dies einerseits im Vergleich zu Nicht-Nutzern von Daten, aber auch im Vergleich zu anderen Unternehmen, die Daten bereits nutzen.
- Daten lassen sich anhand von 5 wettbewerbsrelevanten Charakteristika beschreiben: volume, variety, velocity, veracity, value.
- Wie nachhaltig Wettbewerbsvorteile sind, die durch Data Science erzielt werden können, hängt davon ab, wofür Daten eingesetzt werden (Effizienz, Innovation, Verkauf), und wie die Daten bearbeitet werden (unbearbeitete Rohdaten, Aggregieren, Analyse und Interpretation).
- Heutiger Erfolg von Unternehmen kann eine Data Science Strategie verhindern, bietet aber auch gute Voraussetzungen, eine solche zu erarbeiten.
- Das Sammeln und Aufbereiten von Daten kann In-House, durch Outsourcing oder durch Kooperationsmodelle erfolgen.

Platz für Ihre Notizen:

Data Science und Geschäftsmodelle

Kapitelinhalt Arbeitspaket 3 (AP3)

- **Datengetriebene und datenbasierte Geschäftsmodelle**
Seite 60 - 61
- **Daten und Informationen über Endkunden**
Seite 62 -63
- **Neue Erlösmodelle und Pricingstrategien**
Seite 63 - 64
- **Muster datengetriebener und datenzentrierter Geschäftsmodelle**
Seite 65
- **Was KMU tun können**
Seite 66
- **Die wichtigsten Erkenntnisse**
Seite 67

Autoren:

Prof. Dr. Rigo Tietz (FHS St. Gallen Hochschule für Angewandte Wissenschaften)

Data Science und Geschäftsmodelle

Daten sind sehr vielfältig und können sich einerseits auf Kunden, Lieferanten oder Produkte, andererseits auch auf die Leistungserstellung, die Vermarktung und die mit den Produkten verbundenen Dienstleistungen beziehen. Sie stellen als Quelle von Informationen und Wissen eine wichtige unternehmerische Ressource dar. Den Wert dieser Daten zu erschliessen, wird in Zukunft der zentrale Hebel für den Aufbau von Wettbewerbsvorteilen sein (Opresnik und Taisch, 2015). Dies gilt insbesondere für Unternehmen mit digitalen Geschäftsmodellen, bei denen die Nutzung von Daten im Zentrum steht. In diesem Zusammenhang gibt es für Unternehmen verschiedene Ansatzpunkte. Sie können bestehende Produkte und Leistungen verbessern oder auf Grundlage der Erkenntnisse aus der Datenauswertung ganz neue Produkte entwickeln. Bei der Leistungserstellung kann die Nutzung von Daten dazu beitragen, die Effizienz zu erhöhen, beispielsweise bei der Planung und Produktion (Porter und Heppelmann, 2015). Eine weitere Option besteht darin, das bestehende Geschäftskonzept zu verändern oder ganz neue, datenbasierte Geschäftsmodelle zu entwickeln und umzusetzen (Kollmann, 2016). Während viele grosse Unternehmen wie Google, Amazon & Co. mittlerweile bekannt sind für ihre datenbasierten Geschäftsmodelle, setzen auch mehr und mehr kleine und mittlere Unternehmen auf Daten als wichtigen Teil ihres Geschäftsmodells.

Datengetriebene und datenbasierte Geschäftsmodelle

Der Wettbewerb dreht sich heutzutage nicht mehr ausschliesslich um Produkte oder Dienstleistungen, sondern immer mehr um die Frage nach dem richtigen Geschäftsmodell. Ein innovatives Geschäftsmodell kann den Unterschied ausmachen und somit sowohl Alleinstellungsmerkmal als auch Wettbewerbsvorteil sein. Ein Geschäftsmodell beschreibt das Grundprinzip, wie ein Unternehmen oder Geschäftsbereich funktioniert sowie wie und welcher Nutzen für den Kunden gestiftet wird. Neue digitale Technologien eröffnen Unternehmen viele neue Möglichkeiten für die Entwicklung und Umsetzung neuer Geschäftsmodelle. Im Bereich Data Science beschäftigen sich einige Autoren mit dem Zusammenhang zwischen Daten und dem Geschäftsmodell von Unternehmen. Hartmann et al. (2014) definieren ein datenbasiertes Geschäftsmodell als «a business model that relies on data as a key resource» (S. 6) und stellen somit Daten als den zentralen Teil des Wertschöpfungsprozesses dar. Im Unterschied dazu versteht Morabito (2015) unter datenbasierten Geschäftsmodellen Unternehmen oder Geschäftsbereiche, deren Leistungsversprechen massgeblich auf Daten basiert, und rückt somit die Produkte und Dienstleistungen stärker in den Mittelpunkt.

Für die im Rahmen der Studie befragten Unternehmen geht es bei der Nutzung von Daten zumeist darum, das bestehende Geschäftsmodell zu ergänzen und abzusichern, nicht unbedingt komplett zu verändern. In diesem Kontext spricht man von einem datengetriebenen Geschäftsmodell, bei dem die Nutzung von Daten zwar einen wichtigen Treiber für Veränderungen darstellt, das bestehende Geschäftsmodell aber nicht grundsätzlich in Frage gestellt wird.

*«Das Geschäftsmodell [...] läuft ja noch zu 98% weiter, das neue kommt ja obendrauf.»
(Unternehmen 2, Maschinenbau)*

*«...unser Geschäft durch digitale Geschäftsstrategien abzusichern und vielleicht Geschäftsmodelle zu entwickeln, die wir oben draufsetzen, quasi als zusätzliche Geldquelle. Das andere, was uns auszeichnet, hat sich nicht verändert.»
(Unternehmen 4, Dienstleistung)*

Daten und Informationen über Endkunden

Viele Unternehmen vertreiben ihre Leistungen über Zwischenhändler oder Distributoren, die als Intermediäre fungieren und die direkte Beziehungen zum Endkunden haben. Digitale Vertriebskanäle, wie beispielsweise der eigene Online-Shop, ermöglichen es immer mehr Herstellern und Anbietern, die direkte Schnittstelle zum Kunden zu besetzen und ihre Leistungen selbst zu vermarkten. Der direkte Kontakt zum Endkunden nimmt für Hersteller an Bedeutung zu, während sich die Rolle und Bedeutung von Intermediären verändern werden. Eine zentrale Herausforderung für Unternehmen besteht dann darin, Daten ihrer Endkunden zu erhalten sowie Informationen zu sammeln und auszuwerten.

«... man merkt schon, [...] dass von der Industrie ein Wandel ausgeht. Die Bemühungen, Händlernetze aufzubauen und zu unterhalten, halten sich immer mehr in Grenzen. Man versucht seitens der Industrie, Daten von den Endkunden zu bekommen, um direkt vertreiben zu können.»
(Unternehmen 4, Dienstleistung)

Die Vermutung ist, dass für Hersteller Daten über Endverbraucher zunehmend an Bedeutung gewinnen werden. Die Studienergebnisse zeigen, dass für die befragten Unternehmen Daten der Endverbraucher heute eine unterschiedliche Rolle spielen. Bei einigen Unternehmen ist die Wichtigkeit

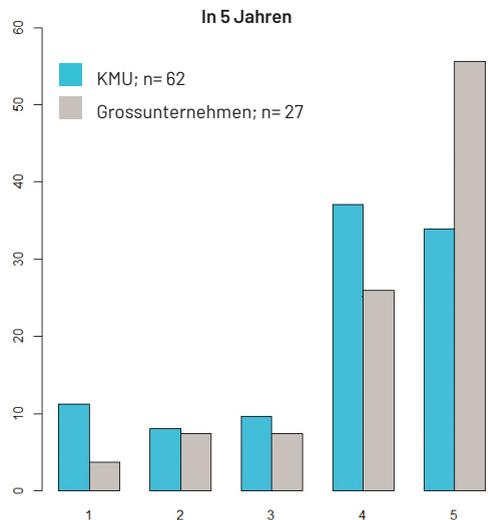
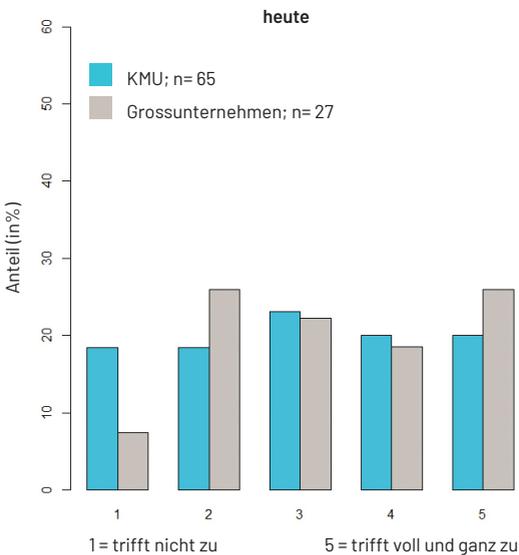


Abbildung 25: Bedeutung von Daten der Endverbraucher für KMU und für Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

dieser Daten bereits sehr gross, während andere Unternehmen hier aktuell keine hohe Relevanz wahrnehmen. Einen Unterschied zwischen KMU und Grossunternehmen ist dabei nicht auszumachen (vgl. Abbildung 25, links). In 5 Jahren schätzen die Unternehmen die Wichtigkeit der Daten, die von den Endverbrauchern stammen, deutlich höher ein (vgl. Abbildung 25, rechts). Sowohl KMU als auch Grossunternehmen gehen davon aus, dass die Daten der Endverbraucher zunehmend wichtiger werden und eine bedeutsame Rolle einnehmen werden. Unternehmen gehen folglich davon aus, dass künftig genauere Daten vom und über den Endverbraucher vorliegen, die beispielsweise dabei helfen, stärker individualisierte Produkte herzustellen.

Neue Erlösmodelle und Pricingstrategien

Wenn es für Unternehmen durch die Analyse und Auswertung von Daten möglich wird, die Leistung und den Effekt ihrer Produkte und Dienstleistungen beim Kunden zu messen, dann kann auf dieser Grundlage auch das Erlösmodell verändert werden. Erfolgsabhängige Vergütungsmodelle und nutzenbasierte Pricingstrategien eröffnen neue Möglichkeiten, um zusätzliche Einnahmequellen zu generieren oder die Wertabschöpfung in Form einer höheren Marge zu verbessern. Eine entsprechende Datengrundlage stellt die Voraussetzung hierfür dar. Beim so genannten «Pay-per-use» Modell bezahlt der Kunde nur dann, wenn er ein Produkt oder eine Dienstleistung auch tatsächlich nutzt. Beim «Performance-based» Modell geht es noch einen Schritt weiter. Der Kunde zahlt nicht für die Nutzung, sondern für das Ergebnis bzw. für den Output. Die Verantwortung des Anbieters gegenüber seinen Kunden nimmt somit deutlich zu und kann nur auf Grundlage einer sauberen Datenbasis getragen werden. Das kann so weit gehen, dass der Hersteller eine Verfügbarkeitsgarantie für die eigenen Leistungen übernimmt, die den Kunden gegenüber einem etwaigen Ausfall absichern soll. Aus den Interviews ergaben sich erste Ansätze, die in diese Richtung zeigen.

«Es gibt mehrere Gründe, warum die Kunden [...] zu uns kommen. Einer ist der Vertriebskanal, d.h. sie wollen Kontakte knüpfen und neue Leads generieren, mit denen sie später auch Umsätze machen. Wenn wir das unterstützen können, wenn wir zum Beispiel einem Kunden [...] garantieren können, dass er 500 Leads bekommt, dann wäre das eine Möglichkeit.» (Unternehmen 4, Dienstleistung)

«Unser Job ist, dass die [...] Maschine immer läuft. [...] Irgendwann kann es gut sein, dass der Kunde nicht nur das Ergebnis kauft, sondern [...] ein Ergebnis mit einer zugesagten Betriebssicherheit.» (Unternehmen 2, Maschinenbau)

Die Umfrageergebnisse machen deutlich, dass die Nutzung von Daten heute noch keine wesentlichen Veränderungen beim Erlösmodell nach sich ziehen. Darin sind sich die KMU und die Grossunternehmen einig (vgl. Abbildung 26, links). Beim Blick in die Zukunft herrscht zwischen den befragten Unternehmen ziemliche Uneinigkeit. Einige Unternehmen, vor allem Grossunternehmen, schätzen die Situation so ein, dass Daten durchaus das Potenzial haben, das klassische Erlösmodell zu verändern. Für andere Unternehmen, insbesondere KMU, scheint dies auch in Zukunft eher kein Thema zu sein.

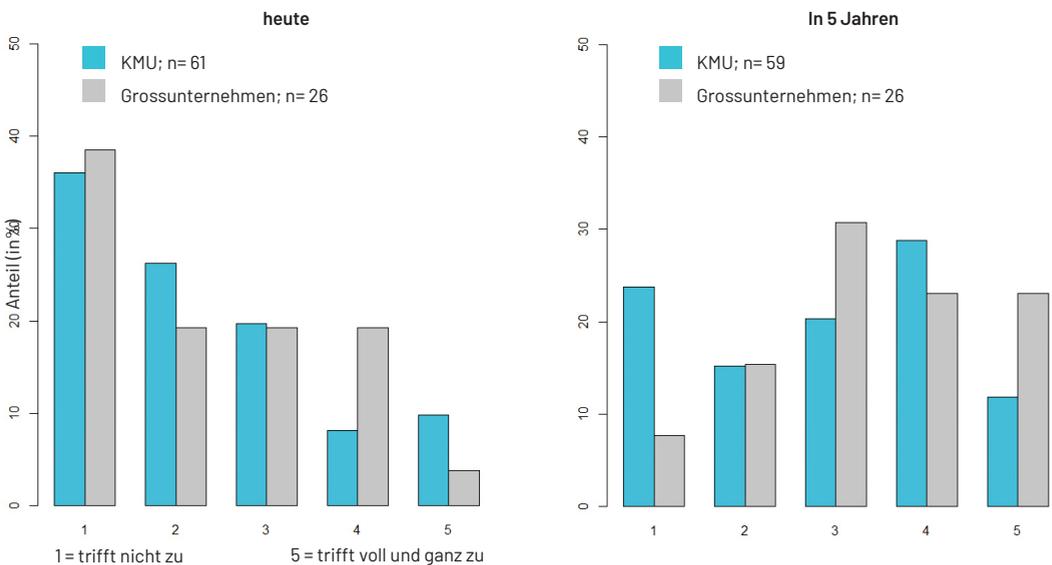


Abbildung 26: Daten verändern das Erlösmodell von KMU und von Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

Muster datengetriebener und datenzentrierter Geschäftsmodelle

Die Nutzung von Daten wird in Zukunft für fast alle Unternehmen zu Veränderungen des Geschäftsmodells führen. Das Ausmass und die Geschwindigkeit der Veränderungen können sich jedoch von Branche zu Branche und zwischen einzelnen Unternehmen sehr stark unterscheiden. Im ersten Schritt geht es daher darum, die grundsätzliche Bedeutung von Daten für das eigene Geschäftsmodell zu klären und alle Aktivitäten darauf abzustimmen. Zwischen datengetriebenen und datenbasierten Geschäftsmodellen gibt es eine grosse Spannweite. Abbildung 27 zeigt drei typische Muster auf.

Beim ersten Muster «Daten als Tool» geht es um die Unterstützung der Aktivitäten im bestehenden Geschäftsmodell bzw. der Tätigkeiten in der Wertekette, wie beispielsweise Einkauf, Forschung und Entwicklung, Produktion oder Marketing und Vertrieb. Zumeist gibt es hierbei keine substantielle Veränderung des bestehenden Geschäftsmodells. Daten verbessern betriebliche Abläufe und unterstützen bei unternehmerischen Entscheidungen.

Das zweite Muster «Daten als Strategie» beschreibt Geschäftsmodelle, bei denen Daten einen strategischen Vorteil und ein Alleinstellungsmerkmal darstellen. In der Regel gibt es hierbei substantielle Veränderungen des Leistungsangebotes oder der Leistungserstellung. Dies bedeutet auch, dass Unternehmen über das erforderliche Know-how verfügen müssen, um datenbasierte Aktivitäten, wie die Gewinnung oder die Analyse von Daten, steuern oder selbst ausführen zu können. Das dritte Muster «Daten als Geschäftsmodell» rückt die Gewinnung, Verarbeitung und Analyse von Daten in den Mittelpunkt der Betrachtung. Das Geschäftsmodell basiert auf Daten, so dass zumeist sowohl die Leistungserstellung, als auch das Leistungsangebot betroffen sind. Oftmals handelt es sich um neue, innovative Geschäftskonzepte, bei denen eine klare Zuordnung zu den klassischen Branchen schwerfällt oder gar nicht möglich ist. Daher gelingt etablierten Unternehmen die Entwicklung und Umsetzung eines datenbasierten Geschäftsmodells in der Regel weniger leicht als jungen Start-ups.



Abbildung 27: Typische Muster datengetriebener / datenzentrierter Geschäftsmodelle. Eigene Darstellung.

Was KMU tun können

Die Nutzung von Daten wird in Zukunft grundsätzlich für alle Unternehmen immer wichtiger werden. Dies bedeutet zwangsläufig, dass sich Unternehmen neu ausrichten und ihr bestehendes Geschäftsmodell verändern müssen. Das Ausmass und die Geschwindigkeit der Veränderungen können sich allerdings von Unternehmen zu Unternehmen massgeblich unterscheiden. Es können drei typische Muster datengetriebener

Geschäftsmodelle abgegrenzt werden, die sich bezüglich der Rolle und Bedeutung von Daten unterscheiden (vgl. Abbildung 27). Unternehmen sollten zunächst ihre strategische Ausrichtung klären und daraus die Ziele ableiten, die sie mit der Nutzung von Daten verknüpfen. Hierbei müssen die etwaigen Implikationen auf unterschiedlichen Ebenen berücksichtigt werden (vgl. Abbildung 28).

Auswirkungen datengetriebener Geschäftsmodelle			
Geschäftsmodell-Muster	«Daten als Tool»	«Daten als Strategie»	«Daten als Geschäftsmodell»
Ziele der Nutzung von Daten	Daten zur Erhöhung von Effizienz und Wirksamkeit	Daten als Alleinstellungsmerkmal und strategischer Vorteil	Daten als zentraler Bestandteil des Geschäftskonzeptes
Typische Unternehmen	Oftmals etablierte Unternehmen	Ausgründung oder neuer Geschäftsbereich etablierter Unternehmen	Oftmals innovative Startups
Erforderliche Fähigkeiten	Einschlägiges Anwenderwissen	Know-how über Daten-Wertschöpfungsprozess	Data Science Expertenwissen
Veränderung des Geschäftsmodells	Kleinere Veränderungen am bestehenden Geschäftsmodell	Substanzielle Veränderungen bei Leistungsangebot und/oder Leistungserstellung	Oftmals neues (innovatives) Geschäftsmodell

Abbildung 28: Typische Eigenschaften datengetriebener Geschäftsmodell-Muster. Eigene Darstellung.

Die wichtigsten Erkenntnisse

- Daten stellen als Quelle von Informationen und Wissen eine wichtige unternehmerische Ressource dar. Den Wert dieser Daten zu erschliessen, wird in Zukunft der zentrale Hebel für den Aufbau von Wettbewerbsvorteilen sein und gilt insbesondere für Unternehmen mit digitalen Geschäftsmodellen.
- Die Nutzung von Daten hat einen Einfluss auf das Geschäftsmodell von Unternehmen und stellt einen zentralen Treiber für Veränderungen dar. Man spricht dann von einem datengetriebenen Geschäftsmodell. Bei einem datenbasierten Geschäftsmodell baut das Leistungsangebot oder die Leistungserstellung sogar massgeblich auf Daten auf.
- Viele Unternehmen vertreiben ihre Leistungen über Zwischenhändler. Digitale Vertriebskanäle ermöglichen es immer mehr Herstellern, die Schnittstelle zum Kunden selbst zu besetzen. Der direkte Kontakt zum Endkunden nimmt für Hersteller an Bedeutung zu. Eine Herausforderung für Unternehmen besteht dann darin, Daten ihrer Endkunden zu erhalten sowie Informationen zu sammeln und auszuwerten.
- Aus der Auswertung von Kunden- und Nutzungsdaten können neue Erkenntnisse über Kundenpräferenzen und Zahlungsbereitschaften gewonnen werden. Dies ermöglicht erfolgsabhängige Vergütungsmodelle und nutzenbasierte Pricingstrategien, um zusätzliche Einnahmequellen zu generieren oder die Wertabschöpfung in Form einer höheren Marge zu verbessern.
- Die Nutzung von Daten wird in Zukunft grundsätzlich für alle Unternehmen immer wichtiger werden. Das Ausmass und die Geschwindigkeit der notwendigen Veränderungen können sich allerdings von Unternehmen zu Unternehmen massgeblich unterscheiden. Unternehmen sollten zunächst ihre strategische Ausrichtung klären und daraus die Ziele ableiten, die sie mit der Nutzung von Daten verknüpfen.

Platz für Ihre Notizen:

Data Science und Services

Kapitelinhalt Arbeitspaket 4 (AP4)

- **Dienstleistungs-Ökonomie und Smart Service-Modelle**
Seite 70 - 71
- **Die Bedeutung von Data Science für Smart Service Modelle**
Seite 72 - 73
- **Anwendungsfälle von Smart Services in der KMU Praxis**
Seite 73 - 77
- **Was KMU tun können**
Seite 78
- **Die wichtigsten Erkenntnisse**
Seite 79

Autoren:

Dr. Jürg Meierhofer (ZHAW School of Engineering)

Dienstleistungs-Ökonomie und Smart Service Modelle

Der Dienstleistungssektor wächst kontinuierlich und macht einen wesentlichen Teil der Beschäftigung und des Bruttoinlandsprodukts aus (Kindström und Kowalkowski, 2014). Beim Übergang von Produkten zu Dienstleistungen beginnen Unternehmen, sich vom Konzept der «Goods-Dominant Logic» (GDL) zur «Service-Dominant Logic» (SDL) zu bewegen, die eine schrittweise Änderung ihrer Denkweise, ihres Wissens und ihrer jeweiligen Kompetenzen erfordert. In SDL gilt der Service als der grundlegende Zweck des wirtschaftlichen Austauschs (Lusch und Vargo, 2014). Das Konzept der Industrieunternehmen als Dienstleister ist entstanden (Lay, 2014). Der Fokus der Wertschöpfung von Unternehmen verlagert sich damit vom Hersteller zur Mitgestaltung in der Firmen-Kunden-Interaktion (Vargo und Lusch 2008). Dies bedeutet, dass es für die Hersteller längerfristig schwieriger wird, auf der Basis reiner Engineering-Ansätze am Markt erfolgreich zu sein, wenn sie nicht in kundenorientierte Konzepte eingebettet sind. Bis heute haben jedoch noch viele Unternehmen Schwierigkeiten, sich der SDL anzunähern.

Die Verlagerung zu Dienstleistungen wird durch gesättigte Märkte und hohe Wettbewerbsintensität (Gebauer et al., 2012) sowie durch die Nachfrage der Kunden nach den Werten und Vorteilen der Dienstleistungen (Kowalkowski und Ulaga, 2017) getrieben. Insbesondere gibt es eine Entwicklung bei den Kunden, anstelle des Ressourceneinsatzes

des Anbieters einen vereinbarten Leistungsoutput zu fordern und zu bezahlen. Daher wird der Übergang von Produkten zu Dienstleistungen und die Integration von Dienstleistungen in Produkte als wesentlich für produzierende Unternehmen angesehen (Baines und Lightfoot, 2013). Laut Fang, Palmatier und Steenkamp (2008) werden die Auswirkungen des Servicegeschäfts auf den Wert eines Unternehmens erst relevant, wenn der Anteil der Serviceverkäufe eine kritische Masse erreicht, die mehr als etwa 20 bis 30% des gesamten Firmenumsatzes ausmacht. Dabei ist für die Entwicklung der Dienstleistungswirtschaft die breite Verfügbarkeit der Informations- und Kommunikationstechnologie eine wichtige Antriebskraft (Chen et al., 2010).

Die Literatur bietet eine Klassifizierung von Industriedienstleistungen auf der Grundlage des Wertes, der dem Kunden zur Verfügung gestellt wird, wobei entweder eine Input- oder eine Outputleistung garantiert wird (Ulaga und Reinartz, 2011; Kowalkowski und Ulaga, 2017). Darüber hinaus wird zwischen Dienstleistungen unterschieden, die sich an den Produkten der Anbieter oder an den Prozessen des Kunden orientieren (Abbildung 29). Gemäss der Abbildung sind traditionelle Servicemodelle im PLS-Quadranten (Product Lifecycle Services) angesiedelt. Beispiele sind die Installation von Neugeräten, Wartung, Reparatur oder Ersatzteillieferung. Wenn der Anbieter zu neuen

Service-Modellen rund um seine Produkte wechselt, werden die PLS-Dienste durch Output-orientierte Asset Efficiency Services (AES) ergänzt oder ersetzt, wie z.B. Individualisierung, Zustandsüberwachung (Condition Monitoring), vorausschauende Wartung (Predictive Maintenance), Leistungsoptimierung

oder Beratung des Kunden auf dem Weg entlang der Customer Journey oder des Produkt-Lebenszyklus'. Neue Service-Modelle, die auf die Output-Leistung fokussieren, werden auch als «Advanced Services» bezeichnet (Baines und Lightfoot, 2013) bzw. als «Smart Services» (Stich et. al. 2019).



Abbildung 29: Input- vs. Output orientierte Services, angepasst von Kowalkoswki und Ulaga 2017.

Die Bedeutung von Data Science für Smart Service Modelle

Bei Advanced Services garantiert der Anbieter dem Kunden eine vereinbarte Leistung zu einem vereinbarten Preismodell. Wird diese Leistung nicht erreicht, muss der Anbieter Korrekturmaßnahmen ergreifen oder eine Gebühr zahlen, wie z.B. einen geringeren Anteil am Umsatz. So verlagert sich bei Advanced Services das Angebot von der kostenbasierten zur wertorientierten Preisgestaltung, was dem Anbieter die Möglichkeit gibt, höhere Margen zu erzielen, wenn er die Produktionskosten durch Effizienzsteigerungen bei gleichbleibender versprochener Qualität der Ergebnisse senken kann.

Andererseits führt dieser Ansatz bei Problemen mit der vereinbarten Leistung zu finanziellen Risiken für den Anbieter. Die Bewertung und Quantifizierung der Schwankungen und Risiken, die mit der erbrachten Leistung verbunden sind, sowie der Produktionskosten, um das versprochene Niveau der Ausgangsqualität zu erreichen, wird daher für einen Anbieter zu einer Schlüsselfähigkeit beim Übergang zu Outputbasierten erweiterten Diensten.

Der Anbieter muss daher die Risiken verstehen und managen, die mit der Garantie von Leistungen einhergehen. Es wird deutlich, dass die Fähigkeit, Daten der installierten Basis zu verwalten, zu verarbeiten und zu analysieren, dafür unerlässlich ist. Daher wird mit zunehmendem Grad der Servitization der Produktion und am Übergang zu Advanced

Services die Nutzung von Daten für die Entwicklung und Erbringung von Diensten zu einer zentralen Voraussetzung und gleichzeitig zu einer zentralen Herausforderung für die Anbieter.

Laut Tao et al. (2018) bieten Daten im Kontext von datengesteuertem Smart Manufacturing Vorteile bei der Individualisierung, Selbstorganisation, automatischer Ausführung («Self-Execution»), oder automatisiertem Lernen. Dies ermöglicht datengesteuerte Smart Services wie Instandhaltung, Qualitätskontrolle, Prozessüberwachung, Materialwirtschaft, Planung oder Smart Design. Smart Service Design übersetzt Kundenstimmen in Produkteigenschaften und Qualitätsanforderungen und beschleunigt so Innovationen und senkt Kosten. Porter und Heppelmann (2014) führen eine Hierarchie der Wertschöpfung mit Smart Services ein, die hilft, die Wertschöpfung in Bezug auf die SDL zu diskutieren.

Durch die Umsetzung dieser Schritte wird eine Wertsteigerung mit intelligenten Dienstleistungen und Produkten erreicht:

- 1) Überwachung
- 2) Steuerung
- 3) Optimierung und
- 4) Autonomie.

Anwendungsfälle von Smart Services in der KMU Praxis

Ein Beispiel für 1) ist die **Zustandsüberwachung** von Maschinen. Der Dienstleister kann den Zustand der beim Kunden laufenden Maschine aus der Ferne beobachten («Remote Monitoring»). Auf der Ebene 2) **Steuerung** wird eine Rückkopplung eingerichtet, um die Maschine basierend auf den Ergebnissen der Überwachung zu steuern. Dies kann z.B. dazu führen, dass Betriebsparameter angepasst werden, um den Zustand der Maschine zu verbessern. Die auf Stufe 3) eingesetzte **Optimierung** verfolgt ein Ziel wie z.B. Energieverbrauch oder Anzahl der pro Zeit produzierten Einheiten. **Autonome Systeme** auf Ebene 4) wären vollständig selbstorganisierte Werkstätten, was heute noch sehr isoliert geschieht.

Im Austausch mit den KMU wurden im Rahmen des Forschungsprojektes jeweils die Möglichkeiten erörtert, konkrete Fallstudien für Lösungsansätze zu erarbeiten. Dabei wurden mit den KMU User Jobs, Pains und Gains sowie Customer Journeys analysiert und mögliche Service-Konzepte entwickelt, die in einzelnen Fällen bis zur Entwicklung kleiner Konzept-Prototypen mit echten oder synthetischen Daten gingen (Letzteres kam vereinzelt zum Einsatz, wenn die verfügbaren echten Daten von der Qualität oder Quantität für eine prototypische Modellerstellung nicht genügten). Daraus haben sich die in der Folge beschriebenen vier Typen von Service-Konzepten ergeben.

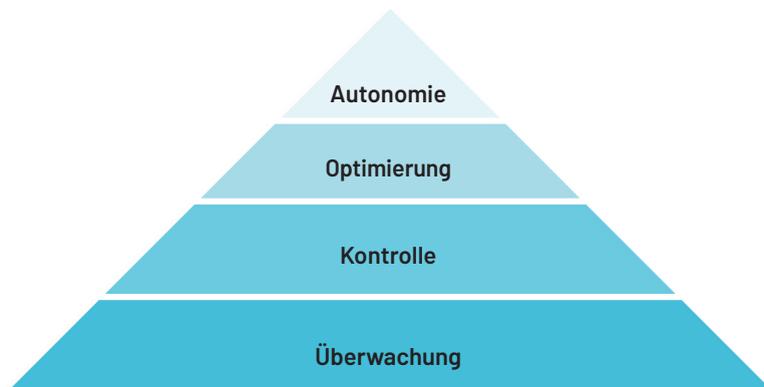


Abbildung 30: Wertehierarchie von Smart Services (angepasst von Porter und Heppelmann, 2014).

Service-Konzept Typ 1:

Rückblickende Visualisierung und Überwachung des Betriebszustandes

Das Ziel bei diesem Service-Typ besteht darin, die Leistung und den Zustand verschiedener Maschinen in der Produktion des Betreibers transparent darzustellen und damit Verständnis für das Personal zu schaffen.

In der Hierarchie gemäss Abbildung 30 befindet sich dieser Service auf der Stufe «Überwachung».

Typische Bedürfnisse von Produktionsleitenden wie «Eine Übersicht erhalten über wichtige Maschinenmetriken ohne grossen Aufwand» oder «Mit einfachen Mitteln wissen, was mit den Maschinen gerade läuft» können damit abgedeckt werden.

Die Praxis-Erhebung hat ergeben, dass sich dabei möglichst einfache Dashboards bewähren, bei denen die Anwender sofort den Zustand der verschiedenen Maschinen auf einen Blick sehen.



Abbildung 31: Beispiel Dashboard für Service-Konzept Typ 1. Eigene Darstellung.

Service-Konzept Typ 2:

Verbesserung der Produktionsleistung durch Einsicht in die Abhängigkeiten

Beim Service Typ 2 geht es darum, dass ein Operateur seine Produktion besser verstehen und einstellen kann, so dass bessere Leistung erreicht wird mit der Maschine oder dem Maschinenpark in Abhängigkeit der aufgewendeten Ressourcen. Es geht primär um eine Verbesserung der Leistung durch veränderte Einstellungen an den Maschinen, was im Endausbau bis zur Optimierung führen kann.

In der Hierarchie gemäss Abbildung 30 befindet sich dieser Service auf den Stufen «Kontrolle» oder «Optimierung».

Typische Bedürfnisse von Produktionsleitenden wie «Aufwand, Zeit, Ressourcenbedarf und Leistung in der Produktion beobachten und verbessern können» oder «Bessere Planungswerte ableiten können» werden damit abgedeckt. Die Praxis-Erhebung hat ergeben, dass sich dabei möglichst einfache Dashboards bewähren, bei denen die Anwender die Leistung ihrer Maschine in Abhängigkeit der Einstellungen beobachten können. Dadurch entwickeln sie ein Verständnis der Abhängigkeit der Produktionsleistung von den Einstellungen und sie können diese mit der Zeit verbessern.

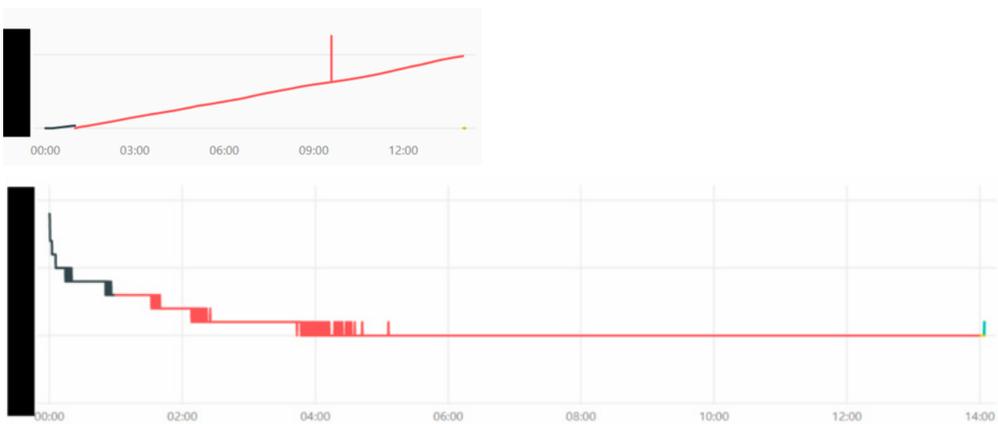


Abbildung 32: Beispiel Dashboard für Service-Konzept Typ 2. Eigene Darstellung.

Service-Konzept Typ 3:

Vorausschauende Zustandsüberwachung

Beim Service Typ 3 geht es darum, mit einer den verfügbaren Daten und der beherrschbaren Komplexität angemessenen Vorlaufzeit vorherzusagen, ob sich der Zustand einzelner Maschinen verschlechtern wird. Damit wird der Operateur in die Lage versetzt, sich auf potenzielle Ausfälle vorzubereiten. Dies geschieht durch eine vorsorgliche Bereitstellung von Ressourcen für die Wartung oder durch den Umgang mit der Störung.

In der Hierarchie gemäss Abbildung 30 befindet sich dieser Service auf den Stufen «Kontrolle» oder «Optimierung».

Typische Bedürfnisse von Produktionsleitenden wie «Erhöhung der Business Kontinuität durch Reduktion von Ausfällen oder Reduktion der Ausfallzeiten» oder «Vermeidung von operativer Hektik, von Stresssituationen. Weniger reaktiv und dafür proaktiver werden» können damit abgedeckt werden.

Die Praxis-Erhebung hat ergeben, dass sich dabei möglichst einfache Dashboards bewähren, bei denen die Anwender anhand eines einfachen Ampel-systems erkennen, ob eine Maschine in den nächsten Stunden ausfallen wird («rot») oder nicht («grün»).

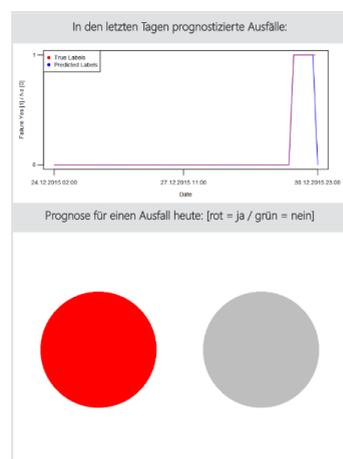
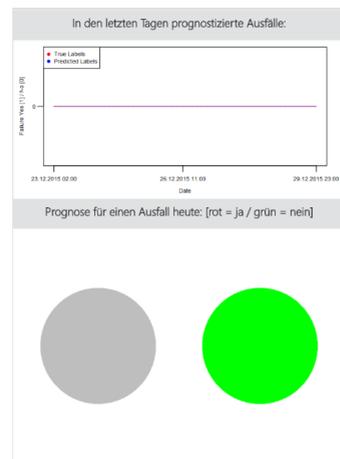


Abbildung 33: Beispiel Dashboard für Service-Konzept Typ 3. Eigene Darstellung.

Service-Konzept Typ 4:

Prozessinstruktion / Entscheidungsunterstützung bei manuellen Tätigkeiten

Beim Service Typ 4 geht es darum, Mitarbeitende bei der Ausführung manueller Tätigkeiten, insbesondere bei Entscheidungspunkten in der Maschinenbedienung, durch Anleitungen oder Instruktionen zu unterstützen. Damit wird es möglich, manuelle Abläufe zu standardisieren oder einen heterogenen Wissensstand bei Mitarbeitenden auszugleichen, womit der Maschinenbetrieb insgesamt verbessert wird.

In der Hierarchie gemäss Abbildung 30 befindet sich dieser Service auf den Stufen «Kontrolle» oder «Optimierung».

Typische Bedürfnisse von Produktionsleitenden wie «Erhöhung der operationellen Exzellenz durch Standardisierung von Prozessabläufen» oder «Reduktion der Abhängigkeit vom Know-How einzelner Mitarbeitender» können damit abgedeckt werden.

Die Praxis-Erhebung hat ergeben, dass sich dabei möglichst einfache Dashboards bewähren, bei denen die Anwender einfache Arbeitsinstruktionen, abhängig vom aktuellen Zustand und Kontext einer Maschine, erhalten.

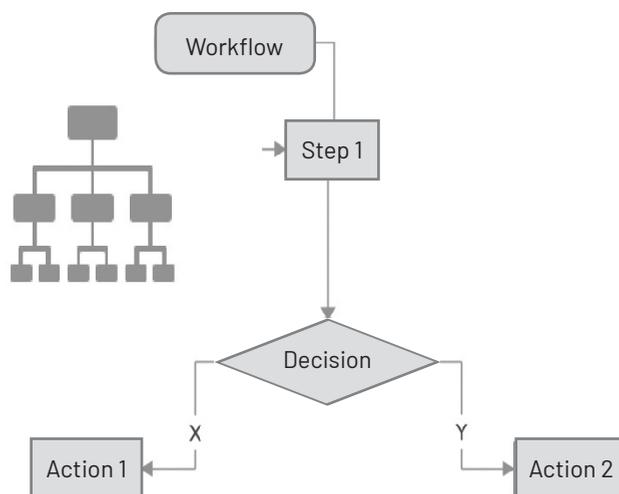


Abbildung 34: Beispiel Dashboard für Service-Konzept Typ 4. Eigene Darstellung.

Was KMU tun können

KMU, die sich für den Schritt in Richtung neuartiger Smart Services entscheiden, sollten diese Entwicklung auf einem klaren Verständnis der Kundenbedürfnisse basieren. Gemäss dem beschriebenen Vorgehen werden dazu die folgenden Schritte vorgenommen:

1. Wer soll potentiell Service-Nutznieser sein? Insbesondere, für welche Individuen soll mit dem Service ein Nutzen erbracht werden? Das können z.B. Individuen in der eigenen Firma (z.B. eigene Service-Techniker oder Operateure) sein oder auch entsprechende Rollen beim Kunden.
2. Welche Service Bedürfnisse hat diese Person und können diese bedient werden? Dazu bewähren sich in der Praxis die Methoden des Value Proposition Designs, bei dem die Bedürfnisse mit den Begriffen Jobs (Kundenaufgaben), Gains (Kundengewinne) und Pains (Kundenproblempunkte) beschrieben. Entsprechend wird dazu eine mögliche Value Proposition beschrieben.
3. Sodann wird anhand der Darstellung gemäss Abbildung 29 untersucht, in welchem der vier Quadranten die Value Proposition verortet werden kann. In den üblichen Fällen handelt es sich dabei um eine Dienstleistung, die sich auf das verkaufte Produkt beziehen, d.h. um Product Lifecycle Services (PLS) oder Asset Efficiency Services (AES).
4. Auf dieser Basis wird die Möglichkeit geprüft, ob der Service mit Hilfe von Daten und Analytik als Output-orientierter Service realisiert werden kann – womit sich der Service in der Kategorie der Asset Efficiency Services befinden würde. Voraussetzung dafür ist die Verfügbarkeit von Daten, z.B. Messdaten von Maschinen oder Prozessen. Für eine erste Pilotierung können diese Daten auch manuell erhoben werden. Zeigt dann diese Pilotierung, dass mit dem Service ein klarer Nutzen für die Anwender entsteht, dann kann in der Folge eine systematische Datenerfassung geplant und umgesetzt werden, was in der Regel zu einem eigens dafür ausgelegten Projekt führt.
5. Für die Entwicklung eines konkreten Services empfiehlt sich ein Blick auf die vier Typen von Service-Konzepten, die in diesem Kapitel beschrieben sind. Daraus können sich Ideen für erste Wertangebote ergeben, die natürlich auf die spezifische Situation angepasst und weiterentwickelt werden können.

Die wichtigsten Erkenntnisse

- Dienstleistungen werden zu einem wesentlichen wirtschaftlichen Faktor und sie werden für den Wert eines Unternehmens relevant, wenn sie mindestens 20 bis 30% des Gesamtumsatzes ausmachen.
- Die Entwicklung geht in Richtung sog. «Advanced Services», Dienstleistungen, bei denen den Kunden eine Outputleistung garantiert wird. Dies geschieht mit entsprechender Übernahme des operativen Risikos durch die Anbieter.
- Für das Management derartiger Dienstleistungen ist daher die Beherrschung von Data Science (Daten und Analyse) unerlässlich. Zentral im Fokus stehen daher dabei datengetriebene Dienstleistungen, sog. «Smart Services».
- Die Wertangebote von Smart Services für die Kunden orientieren sich an einer aufsteigenden Wertehierarchie mit den Stufen Überwachung – Kontrolle – Optimierung – Autonomie.
- In den Praxisfällen wurde bestätigt, dass im operativen Einsatz in produzierenden Umgebungen der Fokus auf der Einfachheit für die Anwender liegen muss – einfache Anzeigen, aus denen in der operativen Hektik rasch erkennbar ist, ob eine Aktivität zur Verbesserung einer Situation erforderlich ist. Das kann z.B. ein einfaches Ampelsystem «Rot» – «Grün» sein.
- Dazu wurden in den Praxisfällen vier typische, einfache Service-Konzepte mit entsprechenden einfachen Dashboards und einfachen Wertangeboten («Value Proposition») für die Anwender entwickelt.
- In der praktischen Umsetzung anhand einer ersten Herangehensweise (Pilotierung) ist es für ein Unternehmen zentral, zuerst zu verstehen, bei welchen Anwendern welche Probleme mit welchen Wertangeboten adressiert werden sollen. Erst dann wird geprüft, ob mit Daten und deren Analyse ein Beitrag dazu geleistet werden kann.
- Für konkrete Wertangebote in einer ersten Pilotierung können die vier Typen von Service-Konzepten als mögliche Ausgangspunkte herbeigezogen werden.

Platz für Ihre Notizen:

Data Science und Prozesse

Kapitelinhalt Arbeitspaket 5 (AP5)

- **Business Process Management und Prozessoptimierung**
Seite 82 - 84
- **Process Mining und Data Science**
Seite 85 - 86
- **Einsatzgebiete und Beispiele**
Seite 87
- **Robotic Process Automation**
Seite 88
- **Was KMU tun können**
Seite 90
- **Die wichtigsten Erkenntnisse**
Seite 91

Autoren:

Prof. Dr. Christian Thiel (FHS St. Gallen Hochschule für Angewandte Wissenschaften)

Business Process Management und Prozessoptimierung

Das klassische Geschäftsprozessmanagement strebt an, die Kernprozesse des Unternehmens hinsichtlich Kosten, Qualität, Zeit, Effizienz und Volumen zu analysieren und zu optimieren, um die Unternehmensziele zu erreichen. Ob Zugewinn an Marktanteilen oder Erschliessung neuer Märkte, Kostensenkung in Produktion oder Vertrieb, Erhöhung von Kunden- oder Mitarbeiterzufriedenheit, all diese Ziele werden anhand von Key Performance Indicators (KPIs) formuliert, visualisiert, analysiert und optimiert. Die Stellschrauben für die Erreichung der Unternehmensziele liegen in den Geschäftsprozessen, den logisch verknüpften Tätigkeiten von Mitarbeitern und Maschinen, die miteinander sowie mit Lieferanten, Kunden und externen Partnern interagieren.

Bei Business Process Management (BPM) oder Geschäftsprozess-Management handelt es sich um eine Methodik zum Management der Prozesse in einer Organisation. Weiterhin beinhaltet BPM Methoden, Konzepte und Technologien für das Design, die Implementierung, die Analyse und die Steuerung operativer Geschäftsprozesse. Sie umfasst Menschen, Systeme, Funktionen, Unternehmen, Kunden, Lieferanten und Partner. BPM definiert Prozesse und spiegelt verschiedene Geschäftsabläufe wider. Geschäftsprozesse sind zeitlich logische Abfolgen von Aktivitäten. Dank BPM werden innerhalb eines Unternehmens diese Prozesse analysiert, optimiert, automatisiert und transparenter gemacht.

BPM hat das Ziel, alle in einem Unternehmen existierenden Informationen zu den eigenen Geschäftsprozessen zu nutzen, um sich auf den Kunden auszurichten und als Ergebnis die Unternehmensziele besser zu erreichen. Prozessmanagement ist damit eine wesentliche Grundlage, um digitale Strategien und Initiativen erfolgreich umzusetzen.

Auch wenn in einem Unternehmen noch keine Prozessbeschreibungen vorhanden sind, existieren mindestens «defacto»-Prozesse durch die gelebte Art und Weise, wie Aufgaben abgearbeitet und weitergegeben werden. BPM unterstützt den gesamten Lebenszyklus («Life-Cycle») von Geschäftsprozessen und liefert Lösungen für die Modellierung, Implementierung, Überwachung sowie Analyse und Optimierung von Prozessen. Die im Rahmen der Studie befragten Unternehmen sehen in der Prozessoptimierung, und damit auch in der erhofften Kostenoptimierung heute einen grossen Nutzen (Platz 3 im Vergleich zu anderen Aspekten, vgl. Abbildung 13).

Im Umgang mit BPM sehen sich Geschäfts- und Prozessanalysten typischerweise mit mindestens zwei wichtigen Datensäulen konfrontiert: transaktionsbezogene Daten und formular- und integrationsbasierte Geschäftsdaten.

Typische Beispiele transaktionsbezogener BPM Daten sind:

- **ID** (Eindeutige Prozessereignis- oder Fall-ID)
- **Anfangsdatum** (Datum, an dem der Vorfall / Fall «gestartet» wurde)
- **Initiator** (Benutzer, der den Vorfall / Fall eingeleitet hat; kann ein benannter oder anonymer Benutzer sein, der später durch andere Mittel identifiziert werden kann)
- **Abschluss der Transaktion**
(Tag zur Identifizierung, ob und wie das Ereignis abgeschlossen wurde; z.B.: nicht abgeschlossen / noch nicht abgeschlossen, abgeschlossen durch Fallabbruch etc.)
- **Abschlussdatum**
(Datumsstempel, falls zutreffend)
- **Lebenszyklus** (Zeitstempel, falls zutreffend für Vorfall / Falldauer)
- **Aktueller Prozessschritt** (In welchem Prozessschritt befindet sich der Vorfall / Fall aktuell?)
- **Zuordnungsdatum** (Wann wurde dem Vorfall / Fall sein aktueller Prozessschritt zugeordnet?)
- **Zugeordnete Benutzer** (Wem wurde der Vorfall / Fall zugeordnet?)
- **Zugeordnete Rolle** (Zu welcher Rolle / Gruppe gehört der zugeordnete Benutzer?)

Anhand dieser Daten allein können bereits viele Informationen gewonnen werden. So kann beispielsweise die Zeit pro Prozess und Fall gemessen und prozessbasierte KPIs formuliert werden (z. B. ist es ein denkbare Ziel bei einem Urlaubsantrag, dass es nicht länger als einen Arbeitstag bis zur Entscheidung dauern soll und nicht länger als zwei Arbeitstage, bis ein genehmigter Antrag in die HR-Systeme eingeloggt und an alle beteiligten Benutzer weitergeleitet wird).

Andererseits hätte man in diesem Beispiel auch Zugriff auf die Vielzahl der prozessabhängigen Daten. Diese hängen eindeutig vom spezifischen Geschäftsszenario ab, für welches die Automatisierungslösung implementiert wurde. Diese Daten können daher so vielfältig sein, wie die verschiedenen Prozesse des Unternehmens, seine Formen sowie interne Funktionen (Geschäftsregeln, Berechnungen, Integrationen, usw.).

Im obigen Beispiel Urlaubsantrag wären dies beispielsweise typische prozessspezifische Datenartefakte:

- **Name des Antragstellers, ID usw.** (Daten, die voraussichtlich in dem Formular angegeben werden)
- **Abteilung des Antragsstellers** (Daten, die voraussichtlich im Formular angegeben werden)
- **Genehmigende (Approver)** (wahrscheinlich das Ergebnis einer Geschäftsregel in Verbindung mit einer Integration in das Active Directory)
- **Gewünschte Termine** (gemeldete Daten)
- **Rest der verfügbaren Urlaubstage** (Geschäftsregel mit einer Kalkulation und wahrscheinlich einer Integration in die HR-Repositories)
- **Entscheidungen und Begründungen** (bei Ablehnungen).

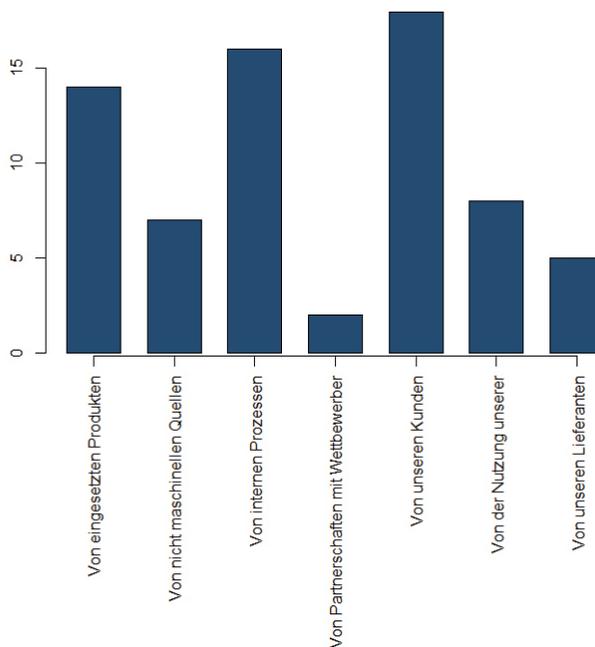


Abbildung 35: Quellen als Zugang zu Daten (KMU und Grossunternehmen). Eigene Darstellung.

Nun können Zusammenhänge analysiert werden, um operative Verbesserungen zu erreichen. Analysten werden in der Lage sein, (eventuell auffällige) Muster zu erkennen, die sich aus den Einflüssen ergeben, die ein bestimmter Benutzer beispielsweise auf Antwortzeiten und Fallvolumina hat. Analysten können diese Muster nachverfolgen und auf sie einzuwirken. In unserem Beispiel wäre es von Interesse zu bestimmen, ob Urlaubsanträge eher spät von einem bestimmten Benutzer geprüft werden und ob diese Tendenzen durch die Saison, wiederkehrende Zyklen oder durch bestimmte Daten verändert werden. Als Reaktion darauf können dann dynamische Regeln in den Geschäftsprozess implementiert werden, die alternative oder zusätzliche Ressourcen bereitstellen, wenn eine bestimmte Tendenz eine festgelegte Toleranzgrenze überschreitet.

Zusammengefasst wird mit der Prozessanalyse gezielt nach Schwachstellen in einem Prozess gesucht. Diese Schwachstellen werden dann im Rahmen der Prozessgestaltung und Prozessverbesserung beseitigt. Dazu müssen wie im Beispiel Geschäftsprozesse einschliesslich aller Beteiligten dokumentiert und mit Kennzahlen versehen werden. Entsprechend häufig nennen die in der Studie befragten Unternehmen Prozesse als Datenquellen (vgl. Abbildung 35).

Process Mining und Data Science

Ein wichtiges Hilfsmittel hin zur Unterstützung und Automatisierung dieser Aufgabe ist Process Mining. Process Mining ist eine innovative, auf elektronischen Daten basierende Methode zur Erkennung realer Prozesse, deren Konformitätsprüfung und folglich deren Optimierung (Schmiedel und Jessensky, 2015). Dabei werden Informationen (EventLog-Daten), welche von IT-Systemen, wie beispielsweise Enterprise-Resource-Planning-System (ERP) oder Customer-Relationship-Management-System (CRM), bei der Abwicklung von Prozessen hinterlassen werden, zur Prozessvisualisierung genutzt (Peters und Nauroth, 2019).

Process Mining ist als Weiterentwicklung aus den Ansätzen des Workflow-Managements, des Geschäftsprozessmanagements und des Data Mining entstanden. Während sich Business Intelligence oder Business Analytics mit der Nutzung von Big Data zur Unternehmenssteuerung und Datenanalyse befassen, kombiniert Process Mining die Prozessmodellierung, Prozessanalyse, Data Mining und Business Intelligence in einem (Peters und Nauroth, 2019). Anhand der Modellierung und Visualisierung wird verborgenes Prozesswissen ersichtlich gemacht. Diese Methode eröffnet neue Möglichkeiten, um Prozesse in einer Vielzahl von Anwendungsbereichen zu erkennen, zu überwachen und zu verbessern (Schmiedel und Jessensky, 2015). Vereinfacht gesagt «sieht» die Software, was Menschen und Maschinen im Unternehmen tun und bildet dies in anschaulichen Flussdiagrammen ab.

Um Businessprozesse im Detail zu analysieren, lässt sich Process Mining in drei Verfahren unterteilen: (1) Discovery, (2) Conformance und (3) Enhancement (van der Aalst, 2016). Beim «Discovery» werden anhand gegebener Event Logs und sog Mining-Algorithmen ohne Verwendung weiterer apriori-Informationen automatisiert Prozessmodelle konstruiert, die eine unvoreingenommene Sicht in die Ablaufstrukturen liefern. Mit diesem Schritt ist es bspw. möglich, Einblicke in die Prozesskomplexität zu erlangen, um Aussagen über Prozessvarianten und deren Häufigkeit zu treffen (Hilbert und Zschech, 2016).

Beim «Conformance Checking» hingegen besteht das Ziel darin, verschiedene Prozessmodelle miteinander zu vergleichen sowie die tatsächliche, in Event Logs dokumentierte Realität anhand gegebener Sollmodelle zu überprüfen. Dadurch können mögliche Abweichungen zwischen dem protokollierten und dem modellierten Verhalten identifiziert, visualisiert und gemessen werden (Hilbert und Zschech, 2016).

Mittels «Enhancement» können darüber hinaus bestehende a-priori-Prozessmodelle durch Berücksichtigung weiterer Aspekte und Perspektiven entweder korrigiert, verbessert oder weiterentwickelt werden. Dazu gehört bspw. auch die explizite Einbeziehung von Prozessleistungen, Durchlaufzeiten oder weiterer Datenattribute, um Performance-Untersuchungen und tiefergehende Analysen durchzuführen (Hilbert und Zschech, 2016).

Dahinter stehen Algorithmen, welche

- die Vermerke in den Log-Dateien der IT-Systeme analysieren
- sinnvoll clustern
- in ein Modell umsetzen und
- die modellierten Standardprozesse auf Abweichungen untersuchen, um Engpässe, häufige Fehlerquellen, etc., zu identifizieren

Das Process Mining bildet damit eine Schnittstelle zwischen dem klassischen Geschäftsprozessmanagement und Data Mining. Mit Process Mining in Kombination mit Machine Learning können noch umfassendere Analyseeblicke generiert werden. Prozessanalysen verfolgen damit nicht mehr alleine das Ziel, vergangene Abläufe zu analysieren, sondern sollen auch zukunftsgerichtete Prognosen ermöglichen. Dadurch können Systeme so konfiguriert werden, dass bei Prognose einer Abweichung von einer bestimmten Soll-Durchlaufzeit automatisch eine Handlungsaufforderung verschickt wird.

Einsatzgebiete und Beispiele

Process Mining kann bei jedem, zumindest teilweise digitalisierten, Prozess angewendet werden. Wie gut ein Prozess funktioniert, wird mit KPPIs (Key Process Performance Indicators) gemessen. Am häufigsten findet man Process Mining bei den Top-Level-Geschäftsprozessen (Heyde, 2019):

Im Einkauf zielt das Process Mining auf die Auswahl geeigneter Lieferanten und die Optimierung der Lagerbestände, auf die verbesserte Performance der Beschaffungsprozesse sowie die Reduzierung von eigenmächtigen Einkäufen durch Abteilungen am Einkauf vorbei. Klassische KPPIs für den Einkauf sind Skonto-Ausschöpfung, Anfrage- und Bestelldurchlaufzeiten oder Nachbearbeitungs- und Reklamationsrate.

In der Produktion werden mit Process Mining konkrete Ansatzpunkte zur Minimierung der Ausschussproduktion, zur Reduzierung der Durchlaufzeiten und zur Optimierung von Lagerhaltung und Auslastung ermittelt. Wichtige KPPIs für die Produktion sind Lagerbestand, Durchlaufzeiten, Lieferzeit und -genauigkeit oder Kundenbeschwerden.

Im Vertrieb hilft Process Mining bei der Identifikation problematischer Ereignisse, insbesondere der Ablehnung, Verzögerung oder Stornierung von Bestellungen infolge fehlerhafter Bestelldaten, fehlerhafter Auftragslimits, langwieriger Bonitätsprüfungen oder Bestandsproblemen, fehlerhafter Rechnungsstellung sowie unvollständiger oder

verspäteter Lieferung. Zentrale KPPIs für die Vertriebskanäle sind Angebots- und Auftragsdurchlaufzeiten, Bestellkorrekturen, termintreue Lieferungen, Retouren oder termingerechter Zahlungseingang.

Anhand des Logistik- und Supply Chain Managements können Verzögerungen und Fehler in der Supply Chain analysiert werden, Zulieferer fundiert bewertet werden und dafür gesorgt werden, dass stets alles pünktlich am richtigen Ort ist. Essenzielle KPPIs für den Logistik-Bereich sind präzise Lagerbestände, Sendungszahl, Lager-, Transport- und Lieferkosten, termintreuer Versand oder Bestellungen (in %).

Im Finanzmanagement bietet Process Mining ein Instrumentarium zur Schaffung effizienter Prozesse und damit ganz konkret zur Freisetzung von gebundenem Kapital. Typische KPPIs für den Finanzbereich sind Skonto-Ausschöpfung, Verzugszinsen, Durchlaufzeiten (Rechnungseingang -> Verbuchung, Rechnungsstellung -> Zahlungseingang), Kosten pro Rechnung oder Rechnungen je Mitarbeiter.

Im IT-Service-Management zeigt Process Mining schliesslich, wo man ansetzen muss, um SLAs einzuhalten, Service Excellence zu erreichen und den Personaleinsatz zu optimieren. Relevante KPPIs für das IT-Service-Management sind Bearbeiter pro Ticket, Ticketqualität, Reaktionszeiten, Ticket-Liegezeiten, Lösungszeiten, (Sofort-) Lösungsquoten.

Robotic Process Automation

Während Process Mining und Business Intelligence zusammenwachsen, versucht auch die «Gegenseite», nämlich ERP- und andere IT-Systeme, teilweise bereits einen Schritt in Richtung dieser Analysemethodik zu gehen und zumindest die Datenbereitstellung zu erleichtern. Künftig wird auch die Robotic Process Automation (RPA) mit Process Mining enger verzahnt werden.

Ein Roboter im Sinne der Prozessautomatisierung ist eine Software, die menschliche Interaktionen als virtuelle Arbeitskraft auf der Benutzeroberfläche ausführt. Es handelt sich um Lösungen, welche hochvolumige, manuelle Aufgaben über Desktop-basierte Anwendungen hinweg automatisieren (Rouse, 2015).

Der Roboter kann einen menschlichen Mitarbeiter einerseits unterstützen und andererseits Aufgaben vollständig übernehmen. Dadurch verlagert sich das Aufgabengebiet des Mitarbeiters von repetitiven zu dedizierten und kreativeren Aufgaben. Dies kann zur Steigerung der Motivation und der Produktivität im Unternehmen führen. RPA vereinen folgende Eigenschaften:

- Sie agieren als virtuelle Arbeitskräfte, die durch Menschen überwacht werden.
- Sie automatisieren repetitive Aufgaben des Menschen.

- Sie sind konfigurierbar und lernfähig, im besten Fall selbstlernend.
- Sie sind in die aktuelle IT-Architektur integriert und benötigen keine komplexen Schnittstellen.

RPA verfügen zurzeit nur über so viel Intelligenz, wie die im Workflow festgelegten Regeln es zulassen. Basierend auf Algorithmen der Künstlichen Intelligenz können die Einsatzmöglichkeiten von RPA aber zukünftig erweitert werden. In der Folge können die Software-Roboter komplexe Prozesse weitgehend selbständig bearbeiten, ohne für einen bestimmten Prozess vorkonfiguriert oder programmiert worden zu sein. Sie werden in der Lage sein, automatisch Inhalte von Textdokumenten wie ein Mensch zu verstehen, menschliche Sprache zu analysieren und unmittelbar mit dem Menschen zu interagieren. Während sich Business Process Management auf die Gesamtabläufe fokussiert und das grosse Ganze überwacht, Potenziale sucht und Prozesse verbessert, kommt RPA eher punktuell zum Einsatz. Die Software-Roboter lassen sich sowohl bei einzelnen Abläufen als auch bei übergeordneten Geschäftsprozessen anwenden, arbeiten jedoch operativ und bilden kein Konzept für das gesamte Unternehmen.

RPA automatisiert und beschleunigt Prozesse, setzt aber nicht bei der Fehlerbehebung an. Wird also ein fehlerhafter Prozess automatisiert, läuft er dadurch zwar oft schneller, nicht aber effizienter ab.



Was KMU tun können

Im ersten Schritt ist es wichtig, zu identifizieren, welche Prozesse und Tools im Unternehmen vorhanden sind, und sie zu bewerten. Welche Prozesse funktionieren richtig gut? In welchen schlummert ein noch ungenutztes Optimierung- und Automatisierungspotential? Process Mining ermöglicht eine anfängliche Bestandsaufnahme: Die Software rekonstruiert und visualisiert die Ist-Prozesse eines Unternehmens, bevor diese automatisiert werden.

Da die Programmierung von Software-Robotern teuer ist, sollte vorab abgewogen werden, bei welchen Prozessen sich eine Automatisierung am meisten lohnt und den grössten ROI verspricht.

RPA-Roboter werden nicht über code-basierte Anweisungen programmiert, sondern mit Demonstrationsschritten konfiguriert und sind dadurch flexibler als codebasierte Software.

Process Mining kommt nicht nur vor, sondern auch nach der RPA-Implementierung zum Einsatz – und ist ab diesem Zeitpunkt kontinuierlich für das Monitoring der Prozessperformance und –compliance zuständig.

Für den Einstieg in Process Mining gibt es mittlerweile eine Auswahl an Tool-Anbietern mit unterschiedlichen Stärken und Schwächen. Welches Tool das richtige für ein Unternehmen ist, hängt stark stark ab von den erwarteten Anwendungsfällen, der Integration in das Unternehmen und in bestehende IT- und BI-Infrastruktur sowie von dem Anspruch an die Art der Analyse, etwa von kurzfristigen Projekten bis hin zum Langzeit-Monitoring von Prozessen mit Analyse nahezu in Echtzeit.

Die jeweiligen Tool-Anbieter bieten oft Trainings oder sogenannte Bootcamp-Events an, um an die Thematik heranzuführen. Eine neutralere Veranstaltung ist die ICPM Conference, die Process Mining als Analyse-Methode jährlich in den Vordergrund stellt.

Eine andere Möglichkeit ist das Hinzuziehen von Datenexperten, die bereits Erfahrung mit Process Mining haben und die Mitarbeiter parallel zur Einführung begleiten. Diese sollten idealerweise aus dem Fachbereich oder der Branche des Unternehmens kommen. Bestenfalls verfügen diese Personen über Erfahrung mit mehr als nur einem Tool-Anbieter, so dass von Anfang an unabhängige Lösungen gefunden werden können.

Data Engineers entwickeln Data Warehouses und stellen Daten über bestimmte Kanäle in gewünschten Formaten bereit. Dies unterscheidet sie von Data Analysten, die Daten statistisch analysieren, und von Data Scientists, die Statistik noch umfassender anwenden und auch Modelle des maschinellen Lernens entwickeln, um Muster in Daten aufzuspüren.

Die Data Engineers spielen gerade zu Beginn der Process-Mining-Einführung die wichtigste Rolle. Sie identifizieren die relevanten Daten in den Datenbanken - das Daten-Backend der ERP-, CRM- und aller anderen IT-Systeme - und sie fusionieren und transformieren sie zu der zuvor erwähnten protokollartigen Struktur eines Event-Logs. Dieses Event-Log ist die Datengrundlage für die Process-Mining-Tools.

Dies erfolgt über Datenfluss-Ketten (ETL oder ELT), die den Datenfluss von den Quellsystemen über die Fusion und Transformation bis hin in das Process-Mining-Tool automatisieren. Werden bei der Erstellung des Event-Logs einige Aspekte der Datenformate sowie der Bereitstellung dieser Daten beachtet, kann es universell verwendet werden. Die technische Organisation bleibt somit offen für jedes Process-Mining-Tool und macht sich von bestimmten Anbietern unabhängig.

Die wichtigsten Erkenntnisse

Der Ansatz, Prozess-Management-Tools mit Process Mining und BI-Fähigkeiten zu erweitern, hat verschiedene Vorteile:

- Das manuelle Modellieren von Prozessen entfällt, stattdessen werden Prozessmodelle automatisch aktualisiert.
- Das Prozess-Management wird intelligent, Erkenntnisse aus operativen Daten lassen sich für das Optimieren und Steuern von Geschäftsprozessen nutzen.
- Regeln zu Führung, Organisation und Überwachung von Prozessen (Governance) lassen sich einfacher vorgeben.

Während sich Business Process Management (BPM) auf die Gesamtabläufe fokussiert und das grosse Ganze überwacht, Potenziale sucht und Prozesse verbessert, kommt Robotic Process Automation (RPA) eher punktuell zum Einsatz.

Platz für Ihre Notizen:

Datenkompetenz in Organisationen

Kapitelinhalt Arbeitspaket 6 (AP6)

- **Future Skills und Digitalisierung: Auf Daten bezogen**
Seite 94
- **Funktion «Data Scientist»**
Seite 95
- **Data Science: Anforderungsprofile und Ansprüche der Unternehmen**
Seite 96 - 97
- **Steigerung der individuellen und kollektiven Digitalkompetenz einer Organisation**
Seite 99 - 101
- **Steigerung der Digitalkompetenz am Beispiel ADLON Intelligent Solutions GmbH**
Seite 102
- **Steigerung Innovationsfähigkeit für Kunden-Digitalisierungsprojekte**
Seite 102
- **Digitale Kompetenzen bei ADLON**
Seite 103
- **Kompetenzen-Landkarte**
Seite 103 - 106
- **Rolle Digital Transformation Coaches**
Seite 107
- **Digitale Maturity der Kunden**
Seite 107
- **Was KMU tun können**
Seite 108
- **Die wichtigsten Erkenntnisse**
Seite 109

Autoren:

Prof. Dr. Sibylle Olbert-Bock, Abdullah Redzepi
(FHS St. Gallen Hochschule für Angewandte Wissenschaften)

Future Skills und Digitalisierung: Auf Daten bezogen

Aussagen über «Future Skills» werden von einer grossen Neugier begleitet - unabhängig davon, ob es sich um die Entstehung völlig neuer Berufe oder die Veränderung bestehender Berufe handelt.

Daten und künstliche Intelligenz gehören zu den Handlungsfeldern, von denen man die grössten Veränderungen des Wirtschaftens und der Leistungserstellung erwartet. In Zusammenhang mit der digitalen Transformation, die bisher sehr IT-getrieben und / oder deutlich stärker von Grossunternehmen getrieben erfolgt, ist das neue Berufsbild des «Data Scientist» entstanden, der sich primär durch seine technologiebezogene Kompetenz ausweist. Der umgekehrte Weg, an fachlichen Fragestellungen anzusetzen und sie im Hinblick auf ihre Expertise im Umgang mit Daten weiter zu entwickeln, wird im Verhältnis dazu vergleichsweise wenig diskutiert.

Während auf diese Weise suggeriert wird, dass es eine neue organisatorische Einheit braucht, sind auch Ansätze eines «shared» Data-Scientist, der Entwicklung der Kompetenz von Fachfunktionen oder der Kooperation innerbetrieblicher Fachfunktionen mit externen Partnern, spezialisiert auf Datensammlung, -verarbeitung, -interpretation und -kontrolle vergleichsweise unterdiskutiert.

Funktion «Data Scientist»

Die Beschreibung der Funktion «Data Scientist» nimmt ihren Ausgangspunkt an den wachsenden Mengen an Daten, die einen steigenden Bedarf mit sich bringt, diese zu strukturieren. Datenanalysten arbeiten mit Datenbanken, Netzwerktechniken und Programmierungen. Mit Hilfe von Algorithmen sollen für das Unternehmen nützliche und verwertbare Informationen aus den bestehenden Datenmassen extrahiert werden. In den USA ist die Ausbildung zum Data Scientist bereits sehr beliebt, in Deutschland steht sie noch eher am Anfang. (Dämon, 2017)

In einem erweiterten Verständnis der Funktion arbeiteten Data Scientisten an der Schnittstelle von reiner Analyse und Domänenexpertise. Sie bewegen sich zwischen Informationstechnologie sowie Strategie und müssen insbesondere in der Lage sein, Daten in verständliche und zielführende Handlungsanweisungen zu übersetzen. Der Kern der erfolgreichen Aufgabenerfüllung besteht darin, Muster und Abhängigkeiten zu erkennen, um schneller, fundierter und faktenbasiert Entscheidungen treffen zu können. Eine weitere Zielsetzung dieser Funktion ist auch, Prozesse effektiver zu gestalten und Kosten zu senken (Pankow, 2017). Damit werden sehr deutliche Funktionsansprüche formuliert, die neben der Gewinnung und Analyse der Daten die angemessene Interpretation von Daten zur Ableitung adäquater Handlungen einbeziehen.

Eine solche Handlungskompetenz setzt neben statistischen, mathematischen und technischen Kenntnissen im Weiteren auch Fachkenntnisse im Anwendungsfeld sowie darauf bezogene Reflexionsfähigkeit und umfassende soziale Kompetenzen in der Zusammenarbeit mit Fachdisziplinen voraus.

Mit der Digitalisierung ist nicht lediglich die Entstehung neuer Berufsbilder verbunden. Viele Berufe werden sich deutlich verändern, was in Konsequenz ein Re- oder Up-Skilling in bereits etablierten beruflichen Funktionen bedeutet. Die in diesem Zusammenhang betroffene Funktion ist die des Controllers (Seufert, 2017). Aus diesem Grund wurden im Rahmen des Forschungsprojektes nicht nur die Anforderungen an das neue Berufsbild des «Data Scientist» recherchiert, sondern auch veränderte Anforderungen an die Funktion des Controllers in der Digitalisierung. Sie wird im Hinblick auf eine veränderte Generierung und Kontrolle von Daten und ihrer Interpretationsfähigkeit angereichert. Durch die bestehende Integration in betriebliche Entscheidungsprozesse wird erwartet, dass auf den Anwendungskontext bezogene Kompetenzen bereits vorhanden sind.

Data Science: Anforderungsprofile und Ansprüche der Unternehmen

Auskunft über die bestehenden Kompetenzanforderungen an «Data Scientist» finden sich u.a. in Darstellungen entsprechender Bildungsgänge und Stellanzeigen von Unternehmen. Letztere fallen durch eine hohe Diversität auf und weisen in unterschiedlichem Mass Anforderungen aus, die über statistische, mathematische und technische Kompetenzen hinausgehen. Eine Analyse von 64'000 Stellanzeigen für Datenexperten der Jobbörse Joblift (2018) kommt zu folgendem Ergebnis (siehe Abbildung 36).

Auffällig in dieser Anforderungsanalyse ist die Bedeutung sozialer Fähigkeiten. Personale und / oder fachliche Kompetenzen im Anwendungsfeld werden hingegen zu wenig oder zu divers adressiert,

auch wenn oft versucht wird, in Stellanzeigen vorausgehende Berufserfahrung abzufangen.

Ergänzend zu der Frage, welche Kompetenzen für Data Scientist als erforderlich betrachtet werden, ist die Frage nach ihrer Ausprägung sowie der Anforderungshöhe zu klären. Ein Rahmenvorschlag zur Unterscheidung von Anforderungsniveaus für verschiedene Kompetenzen des Data Scientist findet sich bei Kugelmeier (2019).

Insgesamt scheinen die bestehenden Konzipierungen des Data Scientist bisher einem Verständnis der Digitalisierung als soziotechnischem Wandel wenig Rechnung zu tragen – überfachliche, soziale und interdisziplinäre Kompetenzen finden sich in den

Rang	Studienfach	Programmiersprachen	Fachwissen	Soft Skills
1.	Informatik	SQL	Machine Learning	Kommunikationsstärke
2.	Mathematik / Statistik	R	Datenvisualisierung	Analytische Fähigkeiten
3.	Wirtschaftswissenschaften	Python	Cloud-Technologie	Kreativität
4.	Physik		Künstliche Intelligenz	Teamfähigkeit
5.	Ingenieurwissenschaften	Java	Deep Learning	Eigeninitiative

Abbildung 36: Anforderungen aus Stellanzeigen für Datenexperten. Eigene Darstellung in Anlehnung an Joblift, 2018.

Beschreibungen wenig. Auch an anderer Stelle ist die Diskussion der Digitalisierung bisher durch eine Technologielastigkeit gekennzeichnet, während Fragestellungen, wie der Einzelne oder Gruppen zu einem geeigneten Umgang mit den Technologien zu befähigen sind, oder was Technikkompetenz mit Blick auf Mensch und Zusammenarbeit bedeutet, vernachlässigt wurden (Olbert-Bock und Redzepi, 2018). Der Bedarfs- und Ressourcenlage von KMU entspricht dies nur wenig, da ein Einzelunternehmen sich nicht unbedingt eine so spezialisierte und eher gering generalistisch ausgebildete Person wird

leisten können. Interessant sind sie in Lösungsformaten, bei denen mehrere Unternehmen im Netzwerk gemeinsam z.B. einen «Data Science Center» unterhalten oder externe Dienstleister hinzunehmen. Mit Blick auf Data Science stellt sich dann die Frage, wie die Gesamtorganisation zu einer angemessenen Nutzung von Daten befähigt wird. Neben dem Einbringen von fachlicher Expertise durch eine datenversierte Person (z.B. ein Data Scientist) ist ein «Enabling» der Gesamtorganisation, ihrer Teams und des Einzelnen vorzusehen.

»Data Scientist Basic Level«	»Certified Senior Data Scientist«
<ul style="list-style-type: none"> • ist informiert über alle Ebenen der Data Science Wertschöpfungskette, ist in der Lage aus grossen Datenmengen Informationen abzuleiten, die für das Unternehmen nutzbringend verwendet werden können, 	<ul style="list-style-type: none"> • hat einen umfassenden Überblick über die Data Science-Wertschöpfungskette,
<ul style="list-style-type: none"> • verwendet dabei Methoden u.a. aus der Informatik, der Mathematik, der Statistik, des maschinellen Lernens und der Mustererkennung, 	<ul style="list-style-type: none"> • beherrscht die Methoden des Data Science und in seinem Spezialgebiet,
<ul style="list-style-type: none"> • verbindet analytische Fähigkeiten mit technischem Verständnis für verarbeitende Software-Architekturen und Geschäftsverständnis und stellt ein Bindeglied zwischen verschiedenen Ebenen eines Unternehmens dar. 	<ul style="list-style-type: none"> • wendet die Data Science-Methoden im beruflichen Kontext zielgerichtet und effizient an, • plant Data Science-Projekte, berät Stakeholder bei der Planung, Durchführung und Auswertung von Data Science-Projekten.

Abbildung 37: Unterscheidung von Anforderungsniveaus an unterschiedlich erfahrene Data Scientist (Kugelmeier, 2019).



Steigerung der individuellen und kollektiven Digitalkompetenz einer Organisation

Um die Digitalkompetenz der Gesamtorganisation zu fördern, stellt einen Ansatzpunkt die Entwicklung von individuellen Kompetenzen dar. Sie lässt sich aber auch als Gegenstand von Organisationsentwicklung betrachten, um auf Ebene der Gesamtorganisation die Digitalkompetenz zu steigern.

In vielen Unternehmen besteht ein diffuses Wissen, was die Anforderungen der Digitalisierung an den Einzelnen anbetrifft. Führungskräfte sollen so letztlich eine Kompetenz fördern, über die sie selbst noch nicht ausreichendes Wissen haben. Generell wird zunehmend der Begriff von «Digitalkompetenz» verwendet. Nach wie vor wird er aber selten präzisiert und es bestehen von wissenschaftlicher Seite unterschiedliche Konzepte (Olbert-Bock und Redzepi, 2019). Das IFLA (2017) betrachtet «Digitalkompetenz» als Fähigkeit, das Potenzial digitaler Werkzeuge angemessen und reflektiert zu nutzen und Nebenwirkungen zu reduzieren. Für Ala-Mutka (2011) umfasst sie instrumentales Wissen und Fähigkeiten zur Nutzung digitaler Medien und Technologien, erweiterte Fähigkeiten und Kenntnisse zur Kommunikation und Zusammenarbeit sowie Einstellungen zur Nutzung strategischer Fähigkeiten in kreativer, verantwortungsvoller und autonomer Weise.

Aus den Definitionen werden unterschiedliche, mögliche Bestandteile von «Digitalkompetenz» erkennbar. Digitalkompetenz beinhaltet zunächst eine funktionsbezogene Technologiekompetenz.

Sie umfasst:

- einen instrumentellen Anteil in Form von «Werkzeugen», ihren funktionsbezogenen Anwendungszielen und den zu ihrer Nutzung erforderlichen Sachkompetenzen
- ein Anteil, der einen aus Unternehmenssicht sinnvollen Einsatz und angemessenen Umgang mit den Werkzeugen beschreibt.

Ergänzend können hinzukommen:

- vielfältige kommunikative bzw. auf Kooperation bezogene Kompetenzen, die im Beispiel den interdisziplinären Dialog mit dem Data Scientist ermöglichen
- Komplexitäts-, Abstraktions- und Problemlösungsfähigkeiten.



Abbildung 38: Relevante Daten-orientierte Kompetenzen für Fachexperten und Management. Eigene Darstellung.

Kompetenzmanagement kann ein Vehikel sein, um die Digitalkompetenz des Einzelnen sowie auf Ebene der Gesamtorganisation zu steigern. Wichtig ist es zu diesem Zweck, «Digitalkompetenz» ausdrücklich in bestehende Kompetenzmodelle mit aufzunehmen bzw. sie bei der Definition von neuen Kompetenzmodellen zu berücksichtigen (Olbert-Bock und Redzepi, 2019). Digitalkompetenz auf Ebene der Gesamtorganisation lässt sich beispielsweise verstehen als die technologische Gesamt-Ausstattung, die Verbreitung und die Stärke der technologiebezogenen Kompetenz der Beteiligten im Umgang mit den verwendeten Technologien in den jeweiligen Funktionen und die kollektive Fähigkeit zur technologiebezogenen Weiterentwicklung.

Darüber hinaus wenden viele Unternehmen Reifegradmodelle zur Bewertung des Stands der Digitalisierung an, und um Handlungsfelder für die weitere Unternehmensentwicklung abzuleiten. Optimal ist es, Kompetenz- und Reifegradmodelle aufeinander abzustimmen. So liesse sich beispielsweise die Qualität des Kompetenzmodells im Hinblick auf Digitalkompetenz und das Ausmass seiner operativen Umsetzung als Bewertungspunkt in einem Reifegradmodell vorsehen.

Aus den vorausgehenden Darstellungen (Abbildung 38) lassen sich die drei folgenden Bereiche ableiten, in denen Fachexperten und das Management datenorientierte Kompetenzen erwerben sollten (Abbildung 38).

Als Beispiel, wie Digitalkompetenz auf gesamtorganisationaler Ebene gesteigert werden kann, wird nachfolgend die Firma ADLON Intelligent Solutions GmbH mit ihren Konzepten und Aktivitäten vorgestellt.

Beispiel: ADLON Intelligent Solutions GmbH

Als IT-Beratungsunternehmen plant, entwirft und betreibt ADLON IT-Infrastrukturen, welche die Stärken der Kunden bündeln. Auch 30 Jahre nach der Gründung hat das Unternehmen seine Start-up-Energie erhalten und kombiniert diese mit der Substanz eines stabil wachsenden, etablierten IT-Dienstleisters und dem Spirit eines familiär geführten Unternehmens.

Steigerung Innovationsfähigkeit für Kunden-Digitalisierungsprojekte

Adlon betrachtet die Steigerung der Digitalkompetenzen in der Gesamtorganisation als zentral, um dauerhaft die zu Beginn oftmals «unscharfen» Digitalisierungsanliegen von Kunden zusammen mit den Kunden zu Projekten zu entwickeln und zukunftsorientierte Beratung leisten zu können.

Die Initiative «Adlon goes digital» bündelt verschiedene innerbetriebliche Aktivitäten, u.a. die Förderung einer innovativen Kultur sowie die gezielte Steigerung der Methoden- und technologiebezogenen und Kompetenzen. Der innerbetriebliche Prozess zur Verstetigung der kundenbezogenen Innovationsfähigkeit wird durch interne Transformation Coaches unterstützt.

Strategie und Vision

Erde, Feuer, Wasser, Luft und IT: Informationstechnologie wird zum ganz natürlichen, unverzichtbaren, allgegenwärtigen fünften Element unseres gesamten menschlichen Lebens. ADLON ist der verantwortungsvolle Gestalter und Berater dieser ITvolution, in der das fünfte Element eine globale, vernetzte und inspirierende Lebenswelt erschaffen hat.

ADLON Fokusthemen

Digital Workplace mit Microsoft 365 - Gemeinsam mit dem Kunden schaut ADLON, wie mit Hilfe von Microsoft 365 der digitale Arbeitsplatz in Unternehmen gestaltet und von allen relevanten Funktionen profitiert werden kann.

Digitale Transformation – Digitalisierung für den Mittelstand

ADLON setzt mittels einer pragmatischen Herangehensweise den Startschuss für die Digitale Transformation in Unternehmen.

Digitale Kompetenzen bei ADLON

Adlon verfügt über ein Kompetenzmodell zum Aufbau bzw. der Weiterentwicklung digitaler Kompetenzen. Die Vorgehensweise im Aufbau des Kompetenzmodells, die Auswahl relevanter Kompetenzen und Bestimmung des erforderlichen Anforderungsniveaus bis hin zur Ableitung von Entwicklungsmaßnahmen ist in Abbildung 40 dargestellt. Im Kompetenzmodell abgebildet werden Fach-, Methoden-, soziale - und personelle Kompetenzen (z.B. zur interdisziplinären Kooperation).

Bezogen auf technikbezogene Handlungsfelder der Digitalisierung, z.B. Daten, KI, VR / AR, Blockchain sowie Methoden wie z.B. Analysemethoden, Strategieerstellung oder agile Methoden besteht ein Kompetenzen-Überblick (Abbildung 41). Daraus

wurden relevante Technologien und Methoden je Funktion ausgewählt und für die Konkretisierung von Anforderungen genutzt.

Kompetenzen-Landkarte

Für alle Funktionen des Unternehmens sind die erforderlichen Kompetenzen in ihrer Soll-Ausprägung definiert und um Massnahmen zum Aufbau der Kompetenzen beim erforderlichen Personenkreis konkretisiert. Exemplarisch für den «Daten» stellt sie sich wie in Abbildung 42 abgebildet dar.

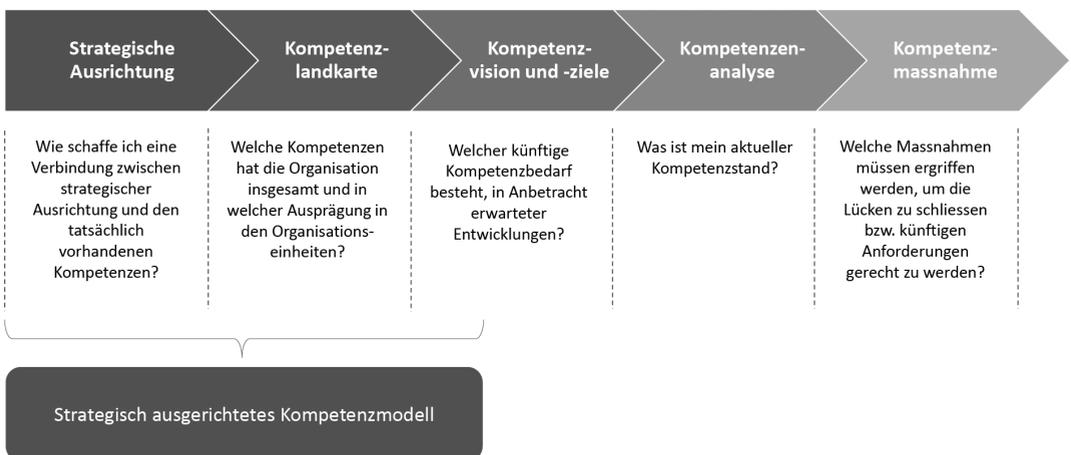


Abbildung 40: Auszug strategische Ausrichtung des Kompetenzmodells (Adlon, 2019a).

Kompetenzbereich	Beschreibung
Fachbezogene Kompetenzen	
Daten	Daten als Grundlage für eine erfolgreiche Digitalisierung sind unumgänglich. Um dies entsprechend zu gestalten sind Kompetenzen im Bereich der Daten (Stichwort «Big Data») notwendig.
Künstliche Intelligenz	Die Ansätze aus dem Feld der Künstlichen Intelligenz und deren Anwendung zur Gestaltung der Digitalisierung sind ein elementarer Bestandteil der notwendigen digitalen Kompetenz bei ADLON.
AR/VR	Virtual und Augmented Reality bieten vielzählige Ansätze zur Schaffung von digitaler Unterstützung in verschiedensten Arbeitsbereichen, die von ADLON zur Schaffung von konkreten Mehrwerten betrachtet werden müssen.
Blockchain	Der grundsätzliche Ansatz von Blockchains bietet Potentiale in dezentraler Verwaltung und Gestaltung von Arbeits- und Verwaltungsabläufen. Es ist zu beobachten inwieweit eine derartige Grundsatztechnologie einsetzbare Innovationen hervorbringt.
Methodenkompetenzen	
Design Thinking	Der Prozess des Design Thinkings dient zur Generierung von Ideen basierend auf Problemstellung oder Anforderungen, die dann entsprechend erprobt werden können (durch Prototyping, etc.).
Lean Startup	Schlanker Ansatz, wo das Konstrukt eines Startups als eine menschliche Institution, die ein neues Produkt oder eine neue Dienstleistung unter extremen Unsicherheiten liefern soll, beschreibt. Kernaussagen aus Lean Startup sind bei der Generierung von neuen Services zu kennen.
Soziale Kompetenzen	
Kommunikationsfähigkeiten	Die Art und Weise der Kommunikation gerade in einer digitalen Welt umgebungskonform zu gestalten, dabei die entsprechenden Medien zielführend einzusetzen, Kommunikationsformen.
Personelle Kompetenzen	
Reflexionsfähigkeit	Die Fähigkeit der Selbstreflexion und der Identifikation von Bestätigung und / oder Verbesserung.

Abbildung 41: Kompetenzen im Überblick (Adlon, 2019a).

Kompetenzlevel	Kompetenzausprägung der Belegschaft (SOLL-Stand 02/19)
Level Wissen	ADLON weit
Level Handeln	<p>Kenntnisse benötigt für</p> <ul style="list-style-type: none"> • Innovation Intelligence Consultants <ul style="list-style-type: none"> ◦ Betroffene ◦ ... • Digital Workplace Senior Consultants <ul style="list-style-type: none"> ◦ Betroffene ◦ ... • Transformation Coaches • Managed Service <ul style="list-style-type: none"> ◦ Betroffene ◦ ... • BRM <p>ADLON Goes Digital Kernteam</p>
Level Können	<p>Kenntnisse benötigt für</p> <ul style="list-style-type: none"> • Projekt Dynamics 365 / Datenbasis ADLON <ul style="list-style-type: none"> ◦ Betroffene ◦ ... • Digital Operations <ul style="list-style-type: none"> ◦ Betroffene ◦ ... • Managed Services <ul style="list-style-type: none"> ◦ Betroffene ◦ ... <p>Zusätzlich Bedarf an externer Kompetenz zur Umsetzung durch Partner in Spezialfällen (Stichwort «Big Data»)</p>
Level Experten	Keine Kompetenzen benötigt
Massnahmen	<ul style="list-style-type: none"> • Aufbau von einem grundlegenden Know-how firmenweit • Aufbau von weiterführenden Kompetenzen Level 200 im definierten Personenkreis • Aufbau von vertieften Kompetenzen Level 300 im definierten Personenkreis • Definition eines Partners

Abbildung 42: Auszug Kompetenzen-Landkarte für «Data» (Adlon, 2019a).

Handlungsfeld «Datenreife & Big Data»	Items des Assessments
Technologiestrategie	<ul style="list-style-type: none"> • Wir besitzen eine Datenstrategie oder Big Data ist Bestandteil unserer IT-Strategie • Wir haben die Ziele unserer Big Data Ansätze / Initiativen definiert
Wissen um Technologie, Relevanz und Anwendungsmöglichkeiten	<ul style="list-style-type: none"> • Wir haben in unserer Organisation ein grundsätzliches Verständnis für Big Data
Nutzung und Angebot	<ul style="list-style-type: none"> • Wir haben einen Überblick über alle vorhandenen Daten und Datenquellen in unserer Organisation • Wir haben bereits Big Data Use Cases identifiziert • Wir haben bereits Big Data PoCs / Projekte durchgeführt • Wir visualisieren Daten und Informationen auf Dashboards • Wir analysieren und verwenden externe Daten • Wir erhalten Datenanalysen in Echtzeit
Auf- und Ausbau interner Kompetenz	<ul style="list-style-type: none"> • Wir haben eine zentrale Data / BI Einheit / Abteilung in unserer Organisation • Wir haben Richtlinien für den Umgang mit Daten (interne und externe) definiert (Datenschutz / Datensicherheit)
Technische Voraussetzungen	<ul style="list-style-type: none"> • Wir haben eine zentrale Big Data / Daten Plattform • Wir überprüfen regelmässig die Qualität (z.B. Korrektheit, Vollständigkeit, Aktualität) unserer Daten

Abbildung 43: Auszug aus dem «Digital Maturity Assessment» von ADLON zu «Datenreife & Big Data» (Adlon, 2019b).

Rolle Digital Transformation Coaches

Digital Transformation Coaches sind im Unternehmen aktiv, um als Multiplikatoren auf operativer Ebene eine neue Form der Zusammenarbeit und digitales Wissen in die Belegschaft zu tragen. Sie verfügen zum einen über spezielles Wissen zu agiler Zusammenarbeit, Methoden des Design Thinking, Innovation Discovery, Change, Rapid Prototyping, Kreativtechniken und bezogen auf Technologie Wissen, wie Big Data, Cloud, KI, AR/VR/MR, Bots, Workflow. Zum anderen sind sie in der Lage, die Kompetenzen der Adlon Mitarbeitenden zusammen zu bringen und Innovationsprozesse wirksam voran zu treiben.

Digitale Maturity der Kunden

Adlon bietet seinen Kunden ein Modell zur Bewertung und Weiterentwicklung ihrer digitalen Reife. Zwar ist es wichtig, mit der Erfahrung aus Digitalisierungsprojekten den Kunden voraus sein. Der immer dynamischere Wandel von Technologien, ihren Einsatzgebieten und Geschäftsmodellen bedingt aber auch, sich mit dem Kundencluster und ihren Anforderungen partnerschaftlich weiter zu entwickeln. Es liegt daher nahe, das Maturity-Modell auch auf die eigene Organisation anzuwenden, mit dem Kompetenzmodell abzustimmen und beides permanent weiter zu entwickeln.

Was KMU tun können

Mit Blick auf die KMU-Landschaft scheint es notwendig, ein integratives Kompetenzmodell zu definieren, das sowohl die neuen Anforderungen des Berufsbildes «Data Scientist» als auch die herkömmlichen Anforderungen des Controllers integriert.

Parallel dazu sind KMU gefordert, die für sie geeignete Organisationsstruktur zu definieren und die Funktion «Data Scientist» im Unternehmen zu integrieren. Mögliche Organisationsformen wären beispielsweise folgende:

- Die Schaffung einer eigenen Stelle, die mit Controlling, Management oder Fachabteilungen zusammenarbeitet.
- Die Integration dieser Funktion in Controlling bzw. Fachfunktion
- Die fall- bzw. bedarfsweise Kooperation mit z.B. externen Dienstleistern oder Fachspezialisten.
- Die Schaffung und Beschäftigung einer Stelle im Verbund mit anderen KMU im Sinne eines «shared» Data Scientist.

Je nachdem, ob sich KMU überhaupt aufgrund einer ausreichend hohen Datenverfügbarkeit dazu entscheiden, eine als «Data Scientist» qualifizierte Person (gemeinsam) einzustellen (a) oder die Anforderungen an ihre Controller zu erweitern (b), ergibt sich ein

- (a) umfassender Weiterbildungs- und Integrationsbedarf der neu eingestellten Person im Hinblick auf den Anwendungskontext, um wirksam informieren und Entscheidungen unterstützen zu können.
- (b) Re-Skillingbedarf der vorhandenen Controller im Hinblick auf Datengenerierung, -verarbeitung und -interpretation.

Sowohl Möglichkeit (a) als auch (b) sind mit Entwicklungsinvestitionen verbunden. Es scheint wenig opportun, unmittelbar Variante (a) zu bevorzugen. Wichtig für Alternative (b) sind allerdings die Bereitschaft und das Zutrauen der Beteiligten in den Erwerb neuartiger Kompetenzen.

Die wichtigsten Erkenntnisse

- Daten und künstliche Intelligenz gehören zu den Handlungsfeldern, von denen man die grössten Veränderungen des Wirtschaftens und der Leistungserstellung erwartet.
- Es entstehen neue Berufe, weshalb auch die Frage nach den «Future Skills» von einer grossen Neugier begleitet wird.
- Unternehmen messen bei der Suche nach Data Scientisten auffällig hohe Bedeutung den sozialen Fähigkeiten bei, um u.a. eine einwandfreie Zusammenarbeit mit relevanten Fachdisziplinen zu gewährleisten.
- Neben den Fähigkeiten zur Gewinnung, Analyse und zur angemessenen Interpretation von Daten sowie zur Ableitung adäquater Handlungen sollten Data Scientisten des Weiteren über Handlungskompetenzen wie statistische, mathematische und technische Kenntnisse sowie Fachkenntnisse im Anwendungsfeld und darauf bezogene Reflexionsfähigkeit verfügen.
- Vielfach wird suggeriert, dass «Data Science» und die damit verbundenen Rollen / Aufgaben eine neue organisatorische Einheit sein sollte. Unternehmen täten sich gut daran, Ansätze eines «shared» Data Scientist, der Entwicklung der Kompetenz von Fachfunktionen oder der Kooperation innerbetrieblicher Fachfunktionen mit externen Partnern zu diskutieren und zu prüfen.

Platz für Ihre Notizen:

Data Science braucht Organisationskultur und Ganzheitlichkeit

Kapitelinhalt Arbeitspaket 7 (AP7)

- **Veränderte Situation durch Daten**
Seite 112
- **Mehr Daten führen nicht automatisch zu mehr Erfolg**
Seite 112 - 113
- **Datenorientierte Organisationskultur und Mindset**
Seite 114 - 117
- **Fehlendes Wissen und Kompetenzen zu Data Science**
Seite 117 -118
- **Alle Ebenen des Unternehmens**
Seite 119 - 120
- **Was KMU tun können**
Seite 121 - 124
- **Die wichtigsten Erkenntnisse**
Seite 125

Autoren:

Prof. Dr. Petra Kugler (FHS St. Gallen Hochschule für Angewandte Wissenschaften)

Veränderte Situation durch Daten

Sowohl KMU als auch Grossunternehmen berichten, dass sie grundlegende Veränderungen durch Daten und Data Science in ihrem Wettbewerbsumfeld heute schon wahrnehmen und von einer weiteren Verstärkung dieser Entwicklung für die kommenden Jahre ausgehen. Die Bedeutung von Daten und Data Science ist damit unbestritten (siehe Kapitel 1 und 2). Es wurde auch gezeigt, dass das in Daten liegende Potenzial heute noch nicht ausgeschöpft ist und vor allem KMU auch noch zögern, Daten und Data Science in die Wertschöpfung ihres Unternehmens zu integrieren. In diesem Kapitel werden Gründe aufgezeigt, die in der bestehenden Kultur und im Mindset etablierter Unternehmen zugrunde liegen. Es ist davon auszugehen, dass das volle Potenzial von Daten und Data Science erst ausgeschöpft werden kann, wenn Daten eine ganzheitliche Berücksichtigung im Unternehmen erhalten, das Unternehmen muss auf die Integration von Daten in die Wertschöpfung neu ausgerichtet werden.

Mehr Daten führen nicht automatisch zu mehr Erfolg

So zeigt sich zum aktuellen Zeitpunkt, dass sowohl Grossunternehmen als auch KMU den Beitrag von Daten zum Erfolg des Unternehmens noch nicht klar erkennen oder messen können (siehe Abbildung 44 und Abbildung 45). Dies liegt auch darin begründet, dass die Wirkung von Daten auf Erfolgsgrössen, ebenso wie die Möglichkeiten, die an Daten geknüpft sind, noch nicht vollständig transparent sind. Für die Zeit in fünf Jahren gehen vor allem KMUs davon aus, dass sich ihr Wissensstand zu Daten und Data Science verbessert, während Grossunternehmen keine signifikante Verbesserung oder Veränderung der Situation erwarten.

Anhand dieser Ergebnisse zeigt sich auch, dass die Verfügbarkeit grosser Datenmengen oder neuer Technologien noch nicht automatisch zu mehr oder besseren Erkenntnissen, zu mehr Wissen oder zu grösserem Erfolg von Unternehmen führt. Vielmehr brauchen Daten ein adäquates Verständnis und einen adäquaten Umgang mit ihnen in unternehmerischen Systemen, so dass sie in neue Werte transferiert werden können. Unternehmen scheinen heute zwar Daten zu sammeln, aber sie sind (noch) nicht in der Lage, mit den Daten wert- oder nutzenstiftend umzugehen. Es mangelt dabei an Wissen, an Kompetenzen und an einer geeigneten Organisationskultur und -Denkweise, um Daten überhaupt einordnen zu können. Viele Unternehmen haben noch kein Handlungsrepertoire im Umgang mit Daten entwickelt. Ihr Fehlen führt oft zu diffusen Ängsten vor dem Unbekannten in Organisationen.

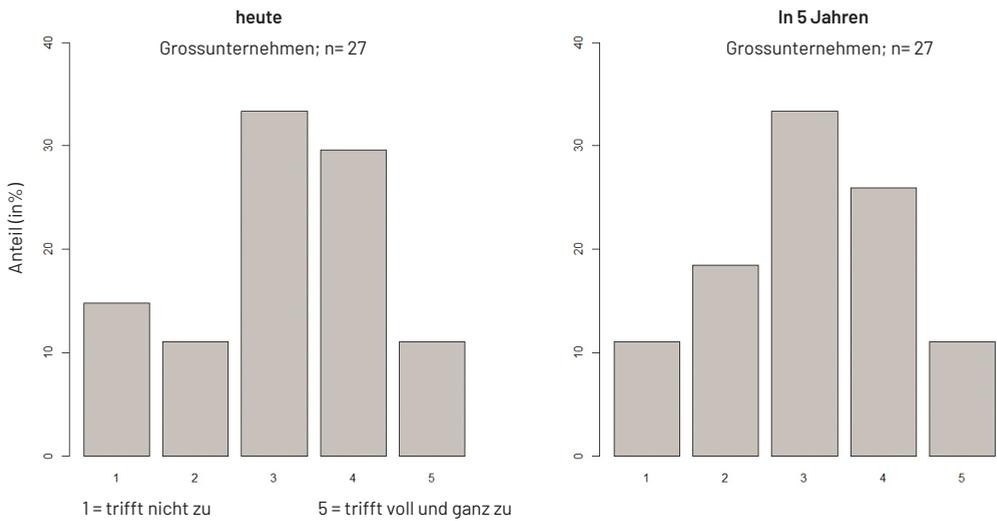


Abbildung 44: Der Erfolg von Daten ist nicht messbar: Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

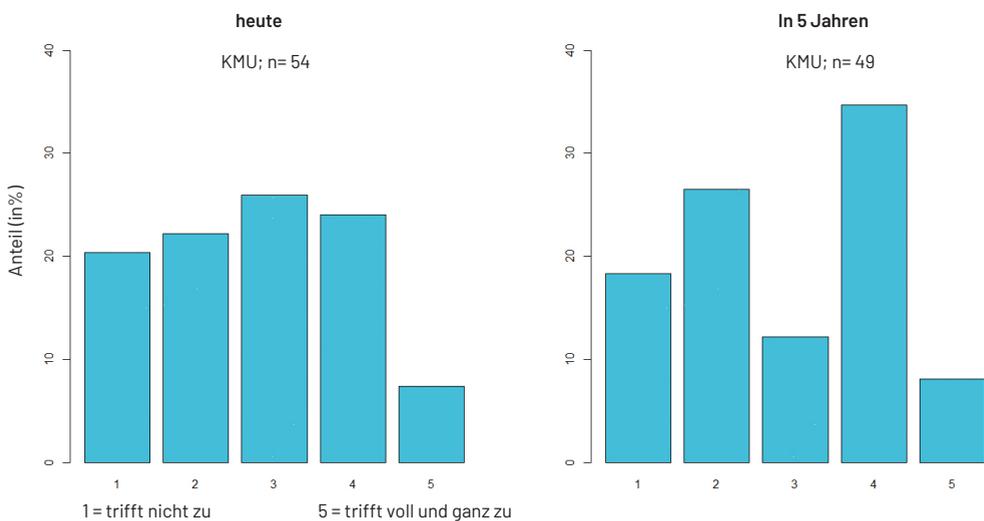


Abbildung 45: Der Erfolg von Daten ist nicht messbar: KMU (heute und in 5 Jahren). Eigene Darstellung.

Datenorientierte Organisationskultur und Mindset

Indem viele Unternehmen Daten und Data Science (noch) nicht als selbstverständlichen Bestandteil ihrer Wertschöpfung betrachten, ist das Thema ebenso noch kein Bestandteil ihrer Unternehmenskultur. Allgemein werden unter dem Begriff «Organisationskultur» informelle Mechanismen verstanden, die eine koordinierende Wirkung in Unternehmen erzeugen. Dazu gehören geteilte Werte, Anschauungen, Symbole und Rituale, die im Zeitverlauf stabil sind. Organisationskultur wirkt daher zu einem grossen Teil informell und wird als selbstverständlich wahrgenommen. Es können drei Bestandteile der Organisationskultur unterschieden werden (Schein, 1985), (1) sichtbare Artefakte, (2) zum Teil sichtbare Werte und Normen, und (3) unsichtbare, als selbstverständlich geltende Grundannahmen (Mindset). Organisationskultur ist im Zeitverlauf meist sehr stabil und nur langsam veränderbar oder beeinflussbar.

Im Zusammenhang von Unternehmen, die ihre Wertschöpfung auf Data Science aufbauen, wird sowohl allgemein von einer «digitalen Organisationskultur» (z.B. Westerman et al., 2019) oder einer «datengetriebene Organisationskultur» (z.B. Brown et al., 2013; New Vantage Partners, 2017) gesprochen. In einer solchen Unternehmenskultur werden digitale Elemente als selbstverständlich und als handlungsleitend betrachtet. Als wichtige Elemente einer digitalen Organisationskultur gelten Einfluss, Geschwindigkeit, Offenheit und Autonomie (siehe Abbildung 45), welche das gesamte Unternehmen betreffen (vergleichbare Elemente finden sich auch in einer «Service-dominanten Logik», Vargo und Lusch, 2004).

In einer digitalen oder datengetriebenen Organisationskultur gelten im Vergleich zu einer «analogen» Organisationskultur neue Spielregeln und Selbstverständlichkeiten.

Einfluss	Geschwindigkeit	Offenheit	Autonomie
Die Welt radikal durch ständige Innovationen verändern.	Schnelles Handeln und Iteration statt Streben nach Perfektion bevor gehandelt wird.	Öffnung des Unternehmens nach aussen und Integration von vielen externen Informationsquellen. Wissen wird offen mit anderen geteilt.	Mitarbeiter haben einen hohen Grad an Selbstbestimmung und -Verantwortung. Formelle Strukturen und Vorgaben sind eher unwichtig

Abbildung 46: Elemente einer digitalen Organisationskultur. Westerman et al., 2019.

Was bisher handlungsleitend und selbstverständlich war, verliert dann an Bedeutung. Ein KMU aus der Maschinenindustrie berichtet:

«Und da ist ganz stark eine Kulturfrage. Als Maschinenbauunternehmen sind wir seit 60 Jahren in dieser guten Position. Wir haben das Blech noch besser gemacht, die Düse effizienter gemacht. Wir feilen wirklich bis wir richtig gut sind und dann gehen wir auf den Markt. Jetzt auf einmal haben wir Produkte, die sind nur rein Software. Da sagen wir gerade komplett das Gegenteil von dem was wir zuvor 60 Jahre gemacht haben. Schneller Prototyp, schnell raus auf den Markt, testen, wohlwissend wir werden da auf die

Nase fallen, dann zurück, nochmals feilen, vor, zurück, vor, zurück. Da fragen schon einige, 60 Jahre haben wir das bis zur Perfektion gemacht, geht das jetzt nicht mehr? Sowohl das eine ist noch wahnsinnig wichtig aber das neue müssen wir eben auch haben. Nicht «entweder oder», sondern «sowohl als auch».» (Unternehmen 3, Maschinenbau)

Neue Werte, an denen sich das Unternehmen und die Mitarbeitenden orientieren können, müssen dann erst etabliert werden. Abbildung 47 zeigt beispielhaft welche Rolle Daten in einer solchen Kultur spielen können. Daten nehmen dabei eine selbstverständliche und zentrale Rolle im Unternehmen ein.

Kulturelle «Schicht» nach Schein (1985)	Datengetriebene Kultur: Beispiele
Artefakte	Stellenausschreibungen, Einstellung Data Scientist Positionen und Organisationseinheiten im Unternehmen
Normen und Werte	Daten sind zentraler Teil der Wertschöpfung / des Geschäftsmodells Es existiert eine Daten-Strategie Zusammenarbeit mit Kunden, Lieferanten, ggfs. Wettbewerbern, um Daten zu generieren
Unausgesprochene Grundannahmen	Daten haben einen Wert Entscheidungen, die auf Daten basieren, sind besser als intuitive Entscheide

Abbildung 47: Datengetriebene Unternehmenskultur. Eigene Darstellung.

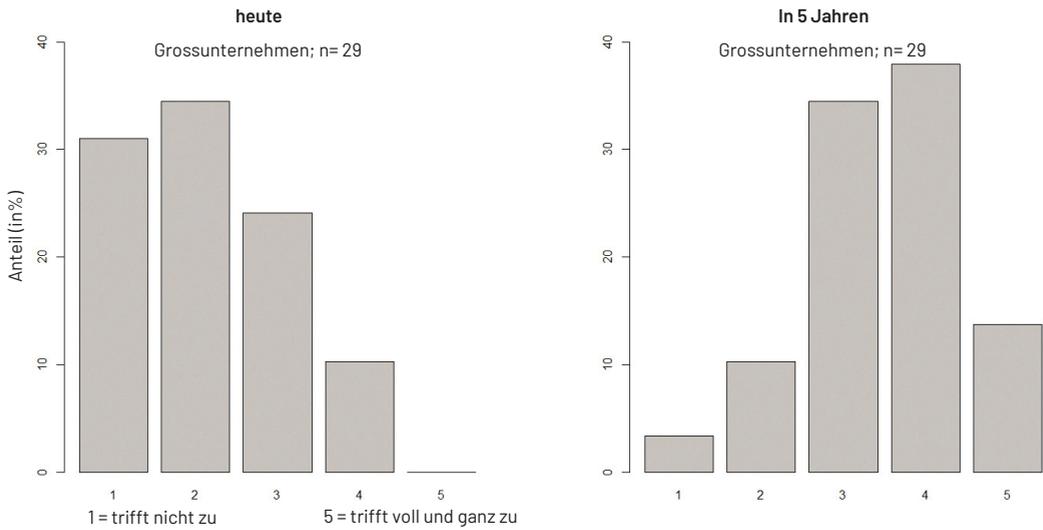


Abbildung 48: Verständnis für die Bedeutung von Daten in Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

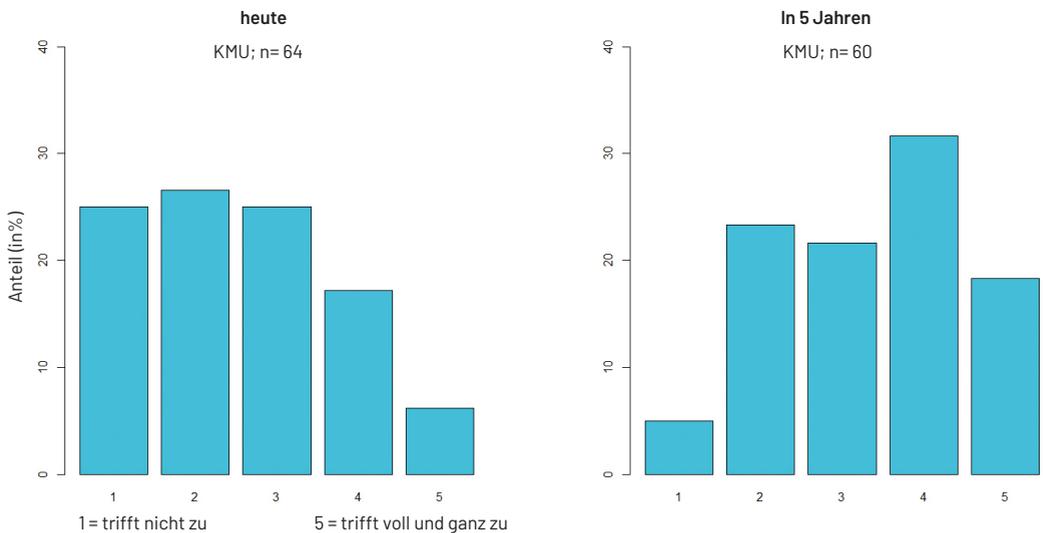


Abbildung 49: Verständnis für die Bedeutung von Daten in KMU (heute und in 5 Jahren). Eigene Darstellung.

Für den künftigen Zeitpunkt in fünf Jahren gehen die Unternehmen beider Kategorien von einer deutlichen Verbesserung ihres Verständnisses für die Bedeutung von Daten aus. Jedoch vermutet jeweils nur ein geringer Anteil der Unternehmen (KMU: ca. 20%, Grossunternehmen: ca. 10%) in fünf Jahren «Experten» für die Bedeutung von Daten zu sein. Interessanterweise sind die KMU auch an dieser Stelle optimistischer als die an der Studie teilnehmenden Grossunternehmen.

Das heisst, die Relevanz von Daten oder Möglichkeiten für deren Einsatz, ebenso wie die Interpretation von Daten, werden heute noch nicht als relevant erkannt. Den Mitarbeitenden auf allen Stufen der Organisation ist es dann möglicherweise (noch) nicht bewusst, wie sie Daten im eigenen Unternehmen selbst wertschöpfend einsetzen können, wie ihre Wettbewerber dies tun, oder zu welchen Konsequenzen dies führen kann. Etliche Möglichkeiten zur Wertschöpfung von Daten werden dann noch nicht ausgeschöpft (z.B. Henke et al., 2016; Chin et al., 2017). Die Unternehmen erkennen nicht, wie Daten ihr Geschäft und den Wettbewerb grundlegend verändern können. Sie sind dann der Gefahr einer Disruption in besonderem Masse ausgesetzt.

Fehlendes Wissen und Kompetenzen zu Data Science

Vielen Unternehmen fehlt es an inhaltlichem Wissen zu Daten (siehe Kapitel 1). Obwohl vielen Unternehmen klar ist, dass ein Engagement auf dem Gebiet der Daten notwendig ist, fehlt es aber auch an Wissen dazu, welchen Mehrwert Daten für das Unternehmen generieren können. Dann ist unklar, wie Daten in unternehmerische Werte transferiert werden können. Dieses Wissen wird erst im Laufe der Zeit durch die Ausübung der Tätigkeit selbst aufgebaut:

«Was mache ich überhaupt mit Daten? Das wissen die Unternehmen oft noch gar nicht. Das heisst dieser Mehrwert der Daten, der Mehrwert der Digitalisierung ist oft noch schwierig.»
(Unternehmen 2, IT-Consulting)

In der Vergangenheit konnten viele Unternehmen dieses Wissen und die erforderlichen Fähigkeiten nicht aufbauen, der Umgang mit Daten ist neu für sie. So verfügten in Deutschland im Jahr 2017 lediglich 13% der Unternehmen über Mitarbeiter mit den erforderlichen Fähigkeiten zum Umgang mit Data Analytics (KPMG, 2017).

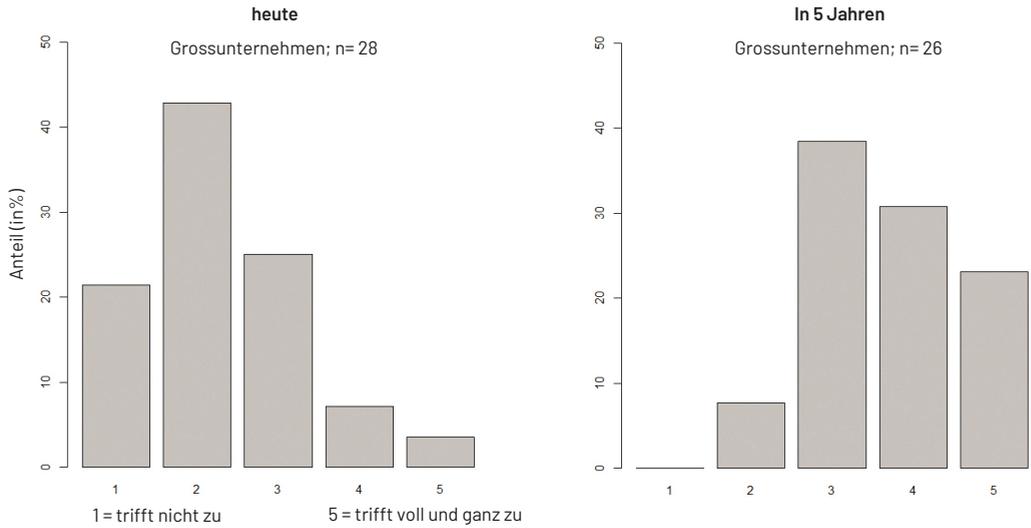


Abbildung 50: Kompetenzen der Führung im Umgang mit Daten in Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

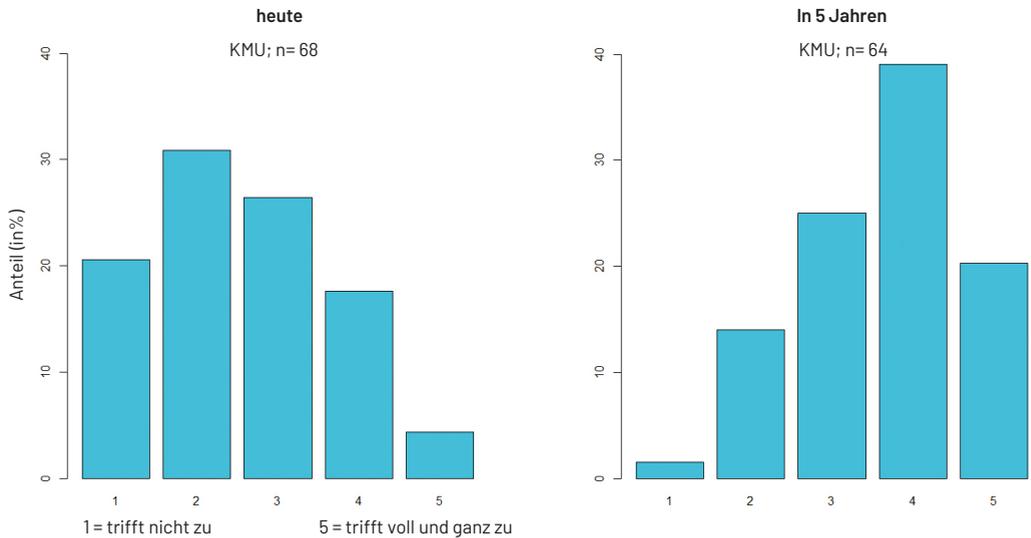


Abbildung 51: Kompetenzen der Führung im Umgang mit Daten in KMU (heute und in 5 Jahren). Eigene Darstellung.

Alle Ebenen des Unternehmens

Das Wissen fehlt dabei auf allen unternehmerischen Hierarchiestufen, Unternehmensführung ebenso wie Mitarbeitende und Aufsichts- oder Verwaltungsrat (siehe Abbildung 50 und Abbildung 51). Dabei fällt auf, dass Mitarbeitende von Grossunternehmen sowohl auf Führungsebene als auch auf der Ebene der Mitarbeitenden ihre Daten-Kompetenzen verhaltener einschätzen als dies in KMU der Fall ist. Dies gilt sowohl für die aktuelle Situation als auch für die erwartete Situation in 5 Jahren.

Auf der Ebene der Mitarbeitenden werden Daten-Kompetenzen in KMU heute deutlich schwächer eingestuft als in Grossunternehmen. Für die Zeit in 5 Jahren sind jedoch die Erwartungen grösser. Erneut scheinen KMU davon auszugehen, dass die notwendigen Kompetenzen in einem kurzen Zeitraum angeeignet werden können. Es ist möglich, dass die Komplexität im Umgang mit Daten von den KMU nicht vollständig erkannt wird.

Neues Wissen, neue Technologien oder neue Wettbewerber werden dann häufig nicht als wichtig oder relevant erkannt. Auch fällt es den Unternehmen dann schwer, notwendige Entscheide zu fällen, kompetente Mitarbeitende zu rekrutieren oder Aufträge an externe, datengetriebene Geschäftsmodelle oder interne Prozesse zu definieren (siehe auch Kapitel 1). Darüber hinaus geben die Teilnehmenden beider Unternehmenskategorien an, dass es massiv an Zeit fehlt, um sich mit neuen Themen wie Data Science auseinanderzusetzen. Das heisst, obwohl dem Thema eine grosse Bedeutung beigemessen wird und gleichzeitig ein Mangel an Wissen und Kompetenzen im Umgang damit besteht, wird anderen Themen eine grössere Bedeutung eingeräumt. Die Beschäftigung mit Data Science wird im Wettbewerb um Zeit und Aufmerksamkeit als nicht hinreichend bedeutsam interpretiert.

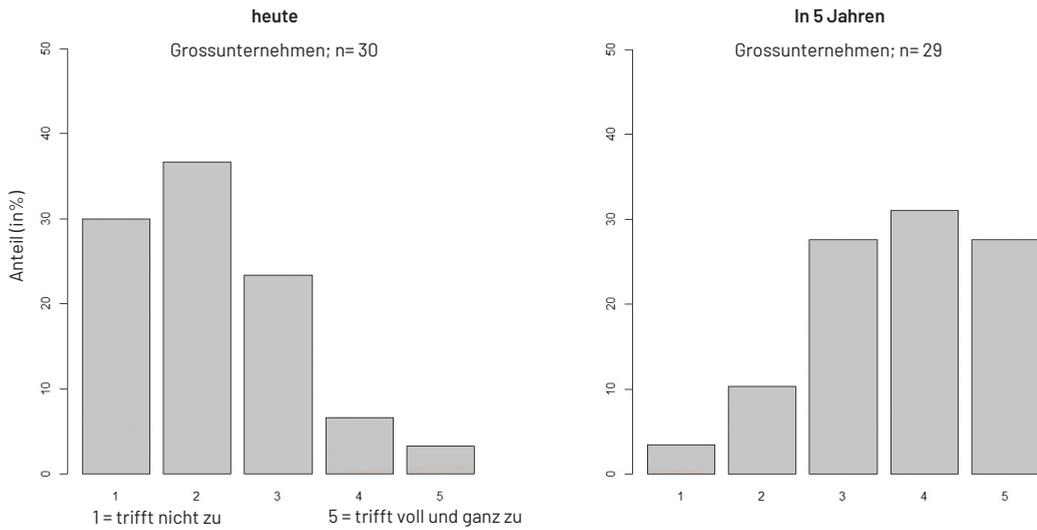


Abbildung 52: Kompetenzen der Mitarbeitenden im Umgang mit Daten in Grossunternehmen (heute und in 5 Jahren). Eigene Darstellung.

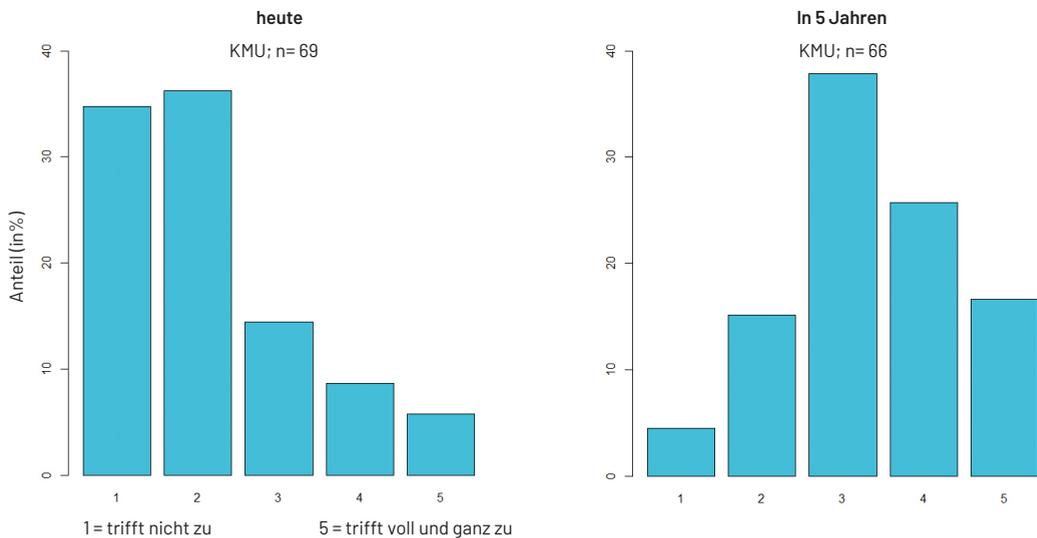


Abbildung 53: Kompetenzen der Mitarbeitenden im Umgang mit Daten in KMU (heute und in 5 Jahren). Eigene Darstellung.

Was KMU tun können

Mit Daten und Data Science zu arbeiten stellt für Unternehmen eine neue Situation dar, welche erst erkannt und dann für die alltägliche Wertschöpfung berücksichtigt werden muss. Bildlich gesprochen hat sich die Umwelt von Unternehmen von einer «analogen» Situation hin zu einer «digitalen» oder «datengetriebenen» Situation verändert. Viele Unternehmen sind aber im Hinblick auf die Art und Weise wie ihre Wertschöpfung vorgenommen wird, wie sie organisiert ist, wie sie in der Organisationskultur verankert und im kollektiven Gedächtnis (Mindset) des Unternehmens abgebildet wird, stehen geblieben. Umwelt und Unternehmen passen dann (noch) nicht zusammen. Sofern Daten eine (wichtige) Rolle im Unternehmen spielen sollen, geht es darum,

das Unternehmen schrittweise in die neue Realität zu überführen. Oft kommt dies einem Paradigmenwechsel gleich, der für jedes etablierte Unternehmen eine grosse Herausforderung darstellt. Junge Unternehmen, z.B. ein Start-up, welches sein Geschäft direkt auf Daten aufbaut, müssen diesen Schritt nicht vornehmen und sie tun sich daher oft leichter in einem datengetriebenen Umfeld (siehe Abbildung 54). Auf dem Weg zum datengetriebenen Unternehmen sind insbesondere zwei Aspekte zentral: Erstens muss der Wandel ganzheitlich im Unternehmen angestrebt werden, und zweitens, braucht es ein Change-Management, das alle Mitarbeitenden am Prozess beteiligt.

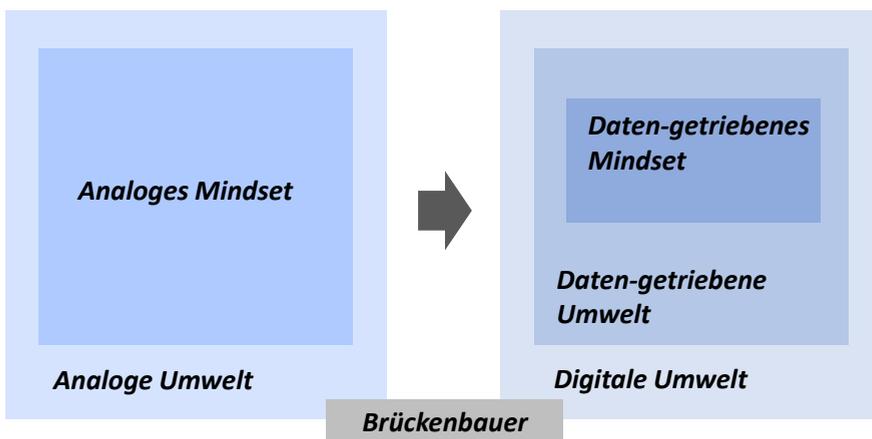


Abbildung 54: Paradigmenwechsel vom «analogen» hin zum «datengetriebenen» Unternehmen. Eigene Darstellung.

Ganzheitlicher Ansatz:

Grundsätzlich können Daten eine kleinere oder grössere Rolle im Unternehmen spielen (siehe hierzu auch die Ausführungen zu Strategie und Geschäftsmodell). Je stärker das Geschäftsmodell auf Daten aufbaut, umso wichtiger wird es, das Unternehmen konsequent an der Nutzung von Daten auszurichten. Dazu sind weniger punktuelle Veränderungen (z.B. durch eine neue Position «Data Science» oder Abteilung im Unternehmen) hilfreich, als eine ganzheitliche Veränderung des Unternehmens, die alle Wertschöpfungsbereiche (Marketing, Produktion, Mitarbeitende, etc.) durchzieht. Die Wertschöpfung wird dann um Daten herum organisiert, was eine grundlegende Transformation nach sich ziehen kann. Davon gehen auch die in der quantitativen Studie befragten KMU und Grossunternehmen aus (siehe Abbildung 55).

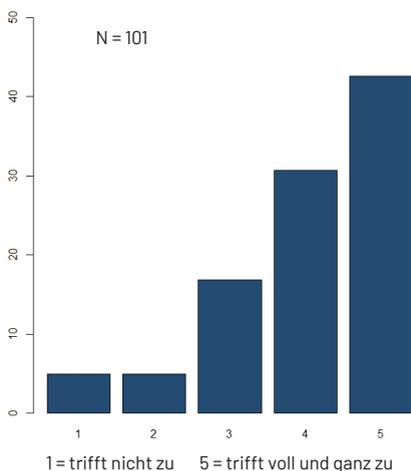


Abbildung 55: Datennutzung braucht einen ganzheitlichen Ansatz: KMU und Grossunternehmen gemeinsam. Eigene Darstellung.

Ob, wann und wie (gut) ein solch grundlegender Wandel möglich ist, ist schwer abschätzbar. In den meisten Fällen braucht es dazu jedoch einen erheblichen Einsatz von Zeit und Ressourcen. Sowohl auf der Ebene der Unternehmensleitung als auch auf der Ebene der Mitarbeitenden ist damit eine Entwicklung der Unternehmenskultur, also der sichtbaren Signalelemente (Was ist uns wichtig?), der impliziten und expliziten Werte und Normen (Was ist erwünscht?) und der unausgesprochenen Grundannahmen (z.B. lieber schnell, aber mit kleinen Fehlern, die später korrigiert werden können) notwendig. Die bisherige Logik und das bisherige Denken und Handeln stehen dann möglicherweise dem notwendigen neuen Denken und Handeln im Weg. Es kann dann auch notwendig sein, die bisherige Struktur, Prozesse und Funktionsweise des Unternehmens zu hinterfragen. Viele Unternehmen und Mitarbeitende scheinen solche Veränderung bereits zu ahnen, denn häufig lassen sich auch diffuse Ängste wahrnehmen. Unklar ist dann, ob es die eigenen Kompetenzen noch braucht oder ob sich die eigene Position im Unternehmen in der Zukunft grundlegend verändert.

Insbesondere eine Veränderung der Organisationskultur und des Mindset bleibt herausfordernd. Sinnvoll kann es sein, Daten und Data Science schrittweise in den unternehmerischen Alltag von einer Vielzahl von Mitarbeitenden zu integrieren. Dies sowohl auf der Ebene der Mitarbeitenden als auch der Führung. Daten und die Arbeit mit Daten sollen dann normal und selbstverständlich werden.

Change Management:

Ein aktives Change Management, das hilft, den Weg ins neue Paradigma zu gehen, kann diesen Prozess unterstützen. Dazu haben sich im Verlauf der Studie mehrere Erfolgsfaktoren herauskristallisiert. Dazu gehören das Commitment der Unternehmensleitung, der Einsatz eines oder mehrerer «Brückenbauers», und die Beteiligung der Mitarbeitenden (der Betroffenen).

Die befragten Unternehmen sind sich einig darin, dass ein Wandel in Richtung Daten und Data Science zwingend die Unterstützung der Unternehmensleitung braucht. Es soll gar nicht die Idee aufkommen, dass das Ziel keine grosse Bedeutung für das Unternehmen hat. Zudem wird die Idee eines «Brückenbauers» oder eines «Change Agenten» verdeutlicht. Dies ist eine oder mehrere Personen, welche die Idee zu den Mitarbeitern tragen und sie dafür begeistern. Dabei ist es zentral, dass diese Person oder Personen ein Verständnis sowohl der bisherigen Funktionsweise des Unternehmens als auch eine Idee (ein Verständnis) der neuen, angestrebten (datengetriebenen) Funktionsweise des Unternehmens mitbringt. Die Person leistet damit eine Übersetzungsarbeit zwischen der bisherigen und der neuen Welt. Es wird beispielsweise die grosse Bedeutung eines CTO (Chief Technology Officer) genannt, der im Gegensatz zur Serviceleitung das technische und betriebswirtschaftliche Wissen mitbringt, aber auch die notwendige Anerkennung («Gewicht») im Unternehmen hat.

«Benötigt wird eine Person, die den Weg gehen will, und Bereitschaft, mit Partnern zu arbeiten. [...] Der Geschäftsführer kann z.B. diese Motivation haben und setzt dann eine Person ein, die daran arbeitet, z.B. Bereichsleiter Produktion. Es braucht den Sponsoren ganz oben. Wenn das die Geschäftsleitung nicht interessiert, geht das nicht.» (Unternehmen 8, IT-Beratung)

Damit die Unternehmensleitung und Schlüsselpersonen im Unternehmen die Notwendigkeit der Veränderung in Richtung Daten und Data Science wahrnehmen, müssen auch diese zunächst einen Veränderungsprozess durchlaufen. Dabei kann es notwendig sein, auf externe Begleitung zurückzugreifen. Sobald die Veränderung konkret wird, kann es helfen, die Mitarbeitenden in den Wandelprozess aktiv einzubeziehen, ihre Ideen und Anliegen aufzugreifen, und sie zu Verantwortlichen zu machen. Immer wieder wird betont, wie wichtig es in diesem Prozess ist, eine Vision zu entwickeln, wohin die Veränderung strebt. Idealerweise baut diese auf den Zielen und Chancen auf, die mit Daten und Data Science verbunden sind: Was ist der Mehrwert des Engagements für das Unternehmen, für Kunden und andere Stakeholder (siehe auch weiter oben)? Warum lohnt sich eine solche Transformation, warum ist sie sogar notwendig?

Die wichtigsten Erkenntnisse

- KMU und Grossunternehmen erkennen den Beitrag von Daten zum Erfolg des Unternehmens oft noch nicht.
- Mehr Daten führen nicht automatisch zu mehr Erkenntnissen, zu mehr Wissen oder zu mehr Erfolg.
- Der Umgang mit Daten erfordert ausreichend Wissen, Kompetenzen, eine geeignete Organisationskultur und Denkweise, um den Wert von Daten einordnen zu können.
- In einem digitalen bzw. datengetriebenen Unternehmen gelten neue Spielregeln.
- KMU und Grossunternehmen haben häufig noch kein ausgeprägtes Verständnis für die Bedeutung von Daten für ihr Geschäft entwickelt.
- Dies betrifft sowohl die Führungsebene als auch die Mitarbeitenden.
- Ein datengetriebenes Geschäftsmodell braucht eine ganzheitliche Umsetzung im Unternehmen, sowie ein aktives Change Management inklusive Commitment der Unternehmensleitung, den Einsatz eines «Brückenbauers» und die Beteiligung der Mitarbeitenden.



TECHNOLOGY

Platz für Ihre Notizen:

Data Science veranschaulichen: Demonstrator

Kapitelinhalt Arbeitspaket 8 (AP8)

- **Demonstrator Ausgangslage**
Seite 128 - 130
- **Demonstrator «Cloud Service»**
Seite 131
- **Business Case**
Seite 132
- **Datenaufbereitung und Modellauswahl**
Seite 133
- **Aufbau des Dashboard**
Seite 134 - 135
- **Funktion zur Prognose von Ausfällen**
Seite 136
- **Fazit Demonstrator «Cloud Service»**
Seite 136
- **Demonstrator «Edge Service»**
Seite 137 - 139
- **Was KMU tun können**
Seite 140
- **Die wichtigsten Erkenntnisse**
Seite 141

Autoren:

Dr. Jürg Meierhofer, Roman Etschmann (ZHAW School of Engineering),
Martin Dobler (Fachhochschule Vorarlberg)

Demonstrator Ausgangslage

Zahlreiche Initiativen, (Forschungs-)projekte und Lehrangebote auf internationaler, EU und regionaler Ebene beschäftigen sich zurzeit mit der sogenannten «Digital Transformation», also dem Wechsel von traditionellen Geschäftsaktivitäten, -prozessen und -kompetenzen hin zu voll- oder teildigitalisierten Modellen und Organisationsformen, in denen signifikante Innovationen kurzfristig und aus einer strategischen Sichtweise auch längerfristig erreicht werden können. Digital Transformation – und insbesondere Data Science – ist ein Motor für diverse Prozesse der Gesellschaft – inklusive der Industrie – und zielt ultimativ auf eine Abkehr von traditionellen, starren Denkweisen ab, um die Zukunft strategisch-gezielt nach vorgegebenen Zielen mit Hilfe von IKT (Informations- und Kommunikationstechnologien) zu gestalten.

Insbesondere für fertigende Kleinst-, Klein- und Mittelunternehmen (KMU) aus dem Bereich der Produktion stellt dies eine enorme Herausforderung dar. Auf der einen Seite bieten Konzepte der Industrie 4.0 teilweise Lösungen an, um die Digital Transformation voranzutreiben. Auf der anderen Seite drängt der Endkunde, sowie andere produzierende Unternehmen innerhalb der Produktionsketten, zunehmend auf eine rasche Reaktion auf

verändernde Anforderungen. Aus diesen Gründen werden KMU verstärkt dazu genötigt, Innovationen nicht nur zu implementieren und in den Produktionsalltag zu integrieren, sondern auch eigenständig voranzutreiben. Forschungspartner sind hierbei besonders gefragt, sodass garantiert werden kann, dass kleinere Betriebe mit diesen Anforderungen nicht im Regen stehen gelassen werden, sondern dass spezifisches Know-How in den Regionen gezielt aufgebaut, verbessert und gelehrt werden kann.

Abgesehen von oben genannten Herausforderungen findet für fertigende Unternehmen ein zunehmender Wandel zu dienstleistungsbasierten Geschäftsmodellen statt (Servitization). Endkunden kaufen in solchen Fällen nicht mehr ein fertiges Produkt, sondern mieten das Produkt, inklusive der dazugehörigen Installation, Wartung und Instandhaltung, d.h. es wird ein Produkt mit den dazu passenden Dienstleistungen gebucht. In solchen Fällen findet die Digital Transformation nicht nur im eigenen Unternehmen statt, sondern muss auch auf die dazugehörigen Dienstleistungen erweitert werden, erschwert dadurch, dass ein klassisch im Haus geführtes Inventar nun ggf. auch außer Haus verwaltet, parametrisiert und überwacht werden muss.

Dadurch resultieren Geschäftsprozesse, welche vielfältiger einsetzbar und mit den dazugehörigen Daten verknüpft werden müssen. ERP (Enterprise Resource Planning) Systeme müssen in der Zukunft vermehrt den ganzhaltigen Lebenszyklus eines Produktes abbilden können, angefangen von der Zulieferung über die Produktion und Dienstleistungen bis hin zu Wartung und Recycling. Die Entwicklungen der sogenannten «Circular Economy» (Ressourceneffizienter und nachhaltiger Einsatz von Rohstoffen) der letzten Jahre spiegeln diesen Trend ebenso wider.

Die Trends der Logistik- und Produktionsindustrie der letzten zwei Jahrzehnte sehen die intelligente Integration bewährter, datengetriebener, schlanker und agiler Anforderungen an dynamische Produktion, Tracking & Tracing, multimodale Transportketten und prädiktives (Re-)Routing von Gütern und Transportmitteln vor. Allerdings konzentrieren sich diese Konzepte - bei weitgehendem Fokus auf eine ganzheitliche Betrachtung der gesamten Supply Chain - in der Regel auf die Logistik, wobei wesentliche Anforderungen aus der Sicht der Produktion und der Fertigung wegfallen. Mit dem Aufkommen der jüngsten Industrie 4.0-Bewegung wird die Datenintegration nun auch entlang der

Produktionslinie vorangetrieben, was vor allem durch die Verwendung etablierter Konzepte intelligenter Lieferketten möglich wird, wie dem digitalen Avatar, der in ganzheitlichen Systemen für intelligente Transport-Ökosysteme bereits erfolgreich verwendet wird, oder dem Einsatz von Big Data und Künstlicher Intelligenz-Technologien, die mit modernen Produktions- und Lieferketten verflochten sind.

Das übergeordnete Ziel der Demonstratoren von Data4KMU ist es, zu beschreiben, wie Daten aus den verteilten und intelligenten Produktionsketten und Logistiknetzwerken in die Datenökosysteme der Industrie 4.0 integriert werden können. Dabei spielen die Selektion und Darstellung der eruierten Daten eine erhebliche Rolle. Dies ist insbesondere dann als wesentlich zu betrachten, wenn wir bedenken, dass Daten der Industrie 4.0 nicht nur vielfältig sind, im Sinne von «Big» wie in Big Data, sondern auch an vielen Stellen den Nutzerinnen und Nutzern zugeführt werden. Das reicht von einer Vielzahl produzierender Maschinen, über mobile Endgeräte wie Scanner von Transportgütern, bis hin zu Mitarbeitenden im Controlling oder Back-Office-Bereich.

Längerfristig zielen wir deshalb darauf ab, KMU ganzheitlich für Data Science Themen zu sensibilisieren und einen – zumindest prototypischen – Einsatz von Data Science Algorithmen in Unternehmen zu etablieren. Da sich die Demonstratoren hauptsächlich auf produzierende Unternehmen beziehen, wurde hier auch darauf abgezielt, die folgenden aktuellen Forschungsfragen integriert zu betrachten:

- Wie gestaltet man branchenübergreifende Kontextinformationen für Logistik und Produktion (wo, wann und wo werden die Daten gespeichert und verarbeitet; Wo werden sie schlussendlich dargestellt)?
- Wie kann automatisiertes Wissen über Business Services und die zugrundeliegenden Geschäftsprozesse aufgebaut werden? Wie kann das Wissen dargestellt werden ohne den / die konkrete Anwender / in im aktuellen Kontext zu überfordern?
- Wie lässt sich die sich abzeichnende Selbsterkenntnis einzelner Güter oder Gegenstände einbeziehen, die von Produkten (Materiallisten, Stücklisten, Konfigurationsbeschreibungen) über Intelligenz zum Auffinden von (Re-)Routing-Entscheidungen bis hin zu Ad-hoc-übergreifendem ICT-Kommunikationsdesign reicht?

- Wie baut man automatische Vertrauensnetzwerke auf, um sicherzustellen, dass intelligente Avatare von Waren und Gegenständen über Unternehmensgrenzen hinweg und in Echtzeit kommunizieren können? Wie kann die Qualität eines solchen automatisierten Vertrauensnetzwerkes sinnvoll dargestellt werden, sodass auf einen Blick erkennbar ist, ob die Information vertrauenswürdig ist oder nicht?

Die wichtigsten Ergebnisse des Projektes können als Grundlage für die weitere Diskussion auf der Grundlage der zuvor genannten Anforderungen und des Vergleichs mit etablierten und vorgeschlagenen Datenaustauschdesigns angesehen werden, zeigen zukünftige Herausforderungen auf und liefern Hintergrundinformationen darüber, wie die vorgeschlagenen Änderungen in das Tagesgeschäft integriert werden können.

Demonstrator «Cloud Service»

Nicht alle Unternehmen, speziell nicht alle KMU, haben in ihren Reihen ausreichende Data Science Kenntnisse, um die richtigen Schlüsse aus ihren Daten ziehen zu können. Dies bietet Platz für einen externen Service, welcher sich auf die ersten Schritte bei der Datenanalyse mit anschließender Visualisierung spezialisieren kann. In diesem Kapitel wird beschrieben, wie ein solcher Service aussehen könnte. Der beschriebene Demonstrator stellt eine typische KMU-Situation dar, wie sie in der Erhebung vorgefunden wurde, bildet aber nicht direkt eines der Unternehmen ab (im Sinne einer «Persona», ein Archetyp).

Die Zielsetzung dieses Demonstrators kann anhand von Abbildung 56 dargestellt werden. Es sollen zwei Effekte gezeigt werden:

1. Dass mit einem auf Fabrikdaten basierenden Service relevanter Nutzen generiert werden kann für einen Akteuren in der Firma - rechts unten dargestellt in Abbildung 56, in Anlehnung an die Persona «Maintenance Agent».
2. Dass ein solcher Service mit sehr einfachen Mitteln und in kurzer Zeit umgesetzt werden kann - in der Abbildung 56 mit «Blick unter die Motorhaube» dargestellt.

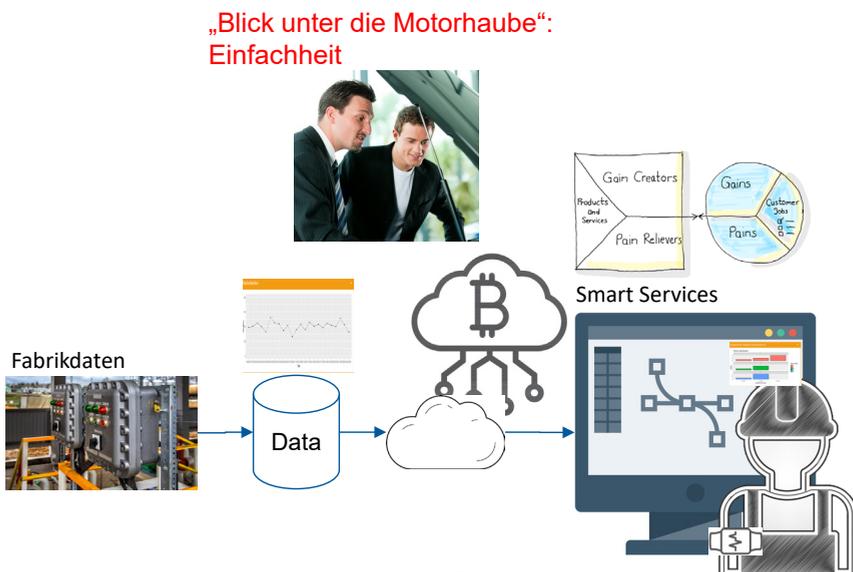


Abbildung 56: Konzeption des Demonstrators für einen Cloud-Service. Eigene Darstellung

Business-Case

Bei den analysierten Daten handelt es sich um Maschinendaten von der fiktiven Firma MillerMills. Der Business-Case wird hier beschrieben.

Im Jahr 2015 startete der Schweizer Kleinmaschinenhersteller MillerMills, der eine lange Tradition in der Herstellung von Hochpräzisionsfräsmaschinen hat, eine Initiative zur Datenerfassung seiner Maschinen in der ganzen Schweiz. Die Initiative soll das Familienunternehmen von einem normalen KMU in ein modernes Produktionsunternehmen mit dem Schwerpunkt IoT (Internet of Things) verwandeln. Ziel der Initiative war es, zu verstehen, wie und wo ihre Maschinen eingesetzt wurden, um sie nach dem Kauf im Auge zu behalten. Die Kenntnis des Standorts aller Maschinen ist notwendig, wenn ein Fehler in einer Maschine auftritt. Die in der ganzen Schweiz ansässigen Instandhalter des Unternehmens müssen vor Ort sein können, um fehlerhafte Komponenten zu reparieren oder zu ersetzen.

Für die Initiative wurden 100 Maschinen aus vier verschiedenen Modellen ausgewählt, die damals auf dem Markt waren. In diesen Maschinen wurde ein Übertragungssystem, das die Firmenzentrale mit den Sensordaten sowie dem Fehlerprotokoll der Maschinen versorgte, platziert. Darüber hinaus

wurde eine Datenbank eingerichtet, in der für jedes Fehlerereignis das Datum, die Maschinen-ID, das Alter und der Standort der Maschine gespeichert werden. Der Maschinenstandort wird auch periodisch an die Zentrale geschickt, so dass ein Umzug automatisch registriert werden kann (in Anlehnung an das Konzept von Abbildung 56).

MillerMills verfügt nun über eine Datenbank mit Messungen und Ereignissen ihrer Maschinen in der Schweiz. Sie wollen nun beurteilen, ob die gesammelten Daten ihnen helfen können, die Maschinen besser zu verstehen, die Beziehung zu ihren Kunden zu verbessern und vielleicht sogar neue Geschäftsmodelle zu entwickeln.

Der Demonstrator wird für den Akteur «Maintenance Agent» entwickelt. Die Aufgaben eines «Maintenance Agent», welchem im weiteren Bericht der Name «John» gegeben wurde, sind unter anderem der Unterhalt und das Verständnis der Maschine sowie der Ersatz defekter Komponenten. Der Demonstrator soll John bei seinen Jobs, Pains und Gains helfen, wie zum Beispiel, dass seine Arbeitszeit schwierig planbar ist oder für schnellere Problemerkennung.

Datenaufbereitung

Für die Aufbereitung der Daten wurde die Statistik-Umgebung «R-Studio» verwendet. In einem ersten Schritt mussten die Daten in das richtige Format gebracht werden. Diese Aufgabe wurde dadurch vereinfacht, dass die Daten aus einer Datenbank kommen und daher bereits gut strukturiert waren.

Die Daten stammen aus einem Zeitraum vom 1. Januar 2015 bis zum 1. Januar 2016. Dabei wurde in die Datenbank stündlich pro Maschine ein Eintrag mit den Sensordaten eingetragen. Die Sensoren messen dabei die elektrische Spannung, den Druck, die Vibration und die Rotation. Zusätzlich zu den Sensordaten, den Zeiten und Daten und der Maschinen-ID werden die Maschinentypen, die Maschinenlokationen und das Alter der Maschine gespeichert sowie Fehler, Ausfälle und Maintenance mit Zeitstempel. Da bei stündlichen Einträgen der Sensordaten viel Schwankungen vorkommen können, wurden zeitliche Mittel für die Analysen verwendet. Einerseits wurde dabei das Mittel über drei Stunden gebraucht und andererseits das Mittel über 24 Stunden. Zusätzlich zum Mittelwert über 3 bzw. 24 Stunden wurde auch die entsprechenden Standardabweichungen berechnet. Die Maintenance wurde so verarbeitet, dass jeweils die Zeitdauer seit der letzten Maintenance angegeben wird. Sobald eine Maintenance durchgeführt wurde, wird die Zeit zurückgesetzt. Die Fehler und die Ausfälle wurden jeweils bis 24 Stunden vor einem Ausfall gekennzeichnet, um später eine Vorhersage machen zu können, ob ein Ausfall in den nächsten 24 Stunden vorhergesagt wird.

Modellauswahl

Der nächste Schritt war, das richtige Modell zu finden. Die Modellauswahl wurde ebenfalls mithilfe von R-Studio gemacht. Bei dieser Aufgabenstellung handelt es sich um eine binäre Klassifizierung. (Entweder Fehler in den nächsten 24 Stunden JA oder NEIN.) Es standen zwei Modelltypen zur Auswahl: Random Forest und Support Vector Machine.

Die Daten werden dabei in ein Trainingsset und ein Testset eingeteilt. Das Trainingsset, in welchem alle Daten zwischen dem 1. Januar 2015 und dem 31. August 2015 sind, wird gebraucht, um das Modell zu trainieren. Mit dem Testset, welches alle Daten zwischen dem 1. Oktober 2015 und dem 1. Januar 2016 beinhaltet, wird das trainierte Modell anschliessend auf die Performance getestet. Der September wird gezielt weggelassen um einen Korrelationseffekt zu vermeiden. Beide Modelle haben in etwa die gleiche Performance. Beide erzielen ein sehr gutes Ergebnis und können die Fehler gut vorhersagen.

Aufbau des Dashboards

Das Dashboard wurde in diesem Beispiel mit Power-BI von Microsoft erstellt. Das Tool eignet sich für die Darstellung von zeitabhängigen Kennzahlen und ist zudem Cloud fähig. Es lassen sich Power-BI Dashboards in Microsoft Azure hochladen und bearbeiten. Dadurch sind auch die Schnittstellen zu den anderen Services wie Datenbanken oder Data-Lakes gewährleistet.

Das Dashboard besteht aus zwei Ansichten. In der einen Ansicht lässt sich das Langzeitverhalten der Maschinen anzeigen. Dabei sind die Kennzahlen über das letzte Jahr ersichtlich. In der anderen Ansicht sind die Kennzahlen über die letzten 7 Tage angezeigt und zusätzlich die Voraussagen für die Ausfälle der Maschinen.

Teil 1 und Teil 3:

Hier werden die Kennzahlen über ein Jahr eingeblendet. Der Druck und die Rotation werden dabei links (Teil 1) und die Vibration und die Spannung auf der rechten Seite (Teil 3) dargestellt. Unter den Kurven wird eingeblendet, wann es zu einem Fehler (Teil 1), einer Maintenance (Teil 3) oder zu einem Ausfall (Teil 1 und 3) in der Maschine geführt hat.

Teil 2:

Im Teil 2 lässt sich durch einen Filter die Maschinen-ID auswählen, welche angezeigt werden soll. Dazu werden zusätzlich noch die wichtigsten Informationen zur Maschine eingeblendet.



Abbildung 57: Dashboard mit Langzeit-Verhalten. Eigene Darstellung

Teil 4:

In diesem Teil ist wieder der Filter für die Maschinen-ID angezeigt. Der zweite Filter ist für das Intervall, in welchem der Algorithmus die Ausfälle prognostizieren soll.

Der Ausfall-Verlauf über die letzten 7 Tage im Teil 4 dient hier nur zur Überprüfung und kann später auch weggelassen werden. Der Fehlerverlauf hingegen ist nützlich und soll dem Anwender aufzeigen, ob es in letzter Zeit eine Fehlermeldung auf der Maschine gab oder nicht.

Teil 5:

Unten im Teil 5 werden dem Anwender die wichtigsten Informationen zu der Maschine eingeblendet. Zusätzlich wird der prognostizierte Ausfall-Verlauf angezeigt. Die Ampel zeigt dem Anwender an, ob es in den nächsten 24h zu einem Ausfall kommen kann (rote Ampel) oder ob die Maschine in Ordnung zu sein scheint (grüne Ampel). Diese zwei Abbildungen sind das Kernstück des Dashboards.

Teil 6:

Im Teil 6 wird dem Anwender der Verlauf der Kennzahlen über die letzten 7 Tage angezeigt. Im Vergleich zum Langzeitverhalten sind so kurzfristige Anstiege oder Abfälle zu erkennen. Zusätzlich ist die Zeit seit der letzten Maintenance ersichtlich.

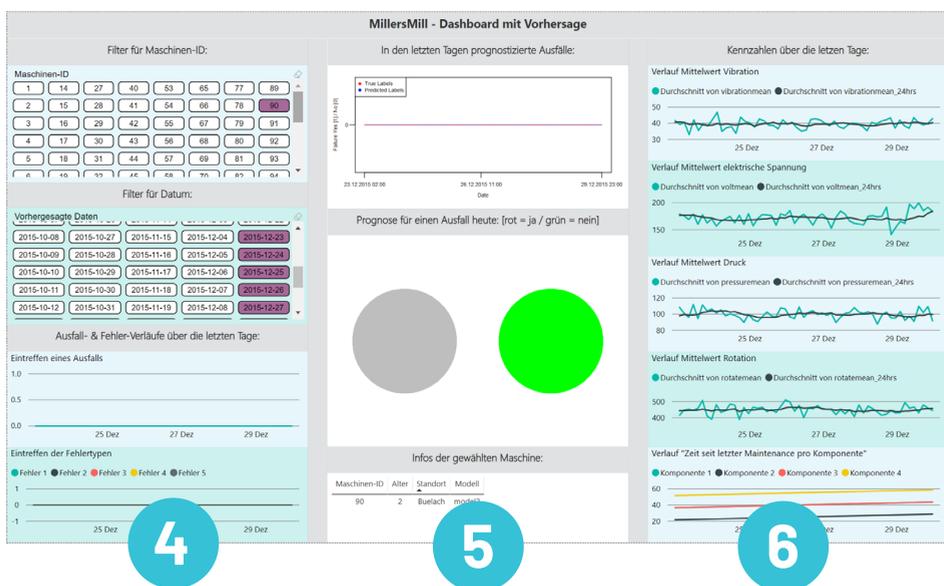


Abbildung 58: Dashboard mit Vorhersage. Eigene Darstellung

Funktion zur Prognose von Ausfällen

Wie im Kapitel «Aufbau des Demonstrators» gezeigt wurde, gibt es im Dashboard zwei Plots, welche anzeigen, ob bei der ausgewählten Maschine in den nächsten 24 Stunden einen Ausfall zu erwarten ist oder nicht. Dafür wird die Support Vector Machine angewendet, wie im Kapitel «Modellauswahl» beschrieben wurde.

In Abbildung 58 ist im mittleren Teil 5 ersichtlich, dass der Algorithmus für die nächsten 24 Stunden keinen Ausfall vorhersagt, siehe auch das Ende der Kurve. Zusätzlich ist sichtbar, dass es in den letzten 7 Tagen keinen Ausfall gegeben hat.

In der Abbildung 59 ist die Ampel nun rot. Dies bedeutet, dass in den nächsten 24 Stunden ein Ausfall wahrscheinlich ist. Dies ist auch in der Kurve im oberen Teil ersichtlich. Die rote Kurve, welche hier zwecks Überprüfung eingeblendet ist, zeigt, dass es dabei tatsächlich zu einem Ausfall gekommen ist. Die Vorhersage ist also richtig.

Ein Tag nach dem Ausfall ist die Ampel wieder grün, die Maschine ist also in Ordnung. In der Kurve ist zusätzlich ersichtlich, ob es in den letzten 7 Tage einen Ausfall gegeben hat.

Fazit Demonstrator «Cloud Service»

Der Aufwand für dieses Dashboard war verhältnismässig gering. Der benötigte R-Code ist sehr kompakt und hat auf etwa einer Bildschirmseite Platz. Es konnte mit diesem Beispiel aufgezeigt werden, dass auch mit einem kleineren Aufwand einen grosser Mehrwert für die Firma erzielt werden kann. Für KMU, welche kein Data Science Know-How in ihren Reihen besitzen, könnte ein solches Dashboard durchaus einen grossen Nutzen für den täglichen Betrieb bringen. Ist eine strukturierte Datenlage im Unternehmen vorhanden und wird von dem Unternehmen vorgegeben, in welchem Bereich der Demonstrator eingesetzt werden soll, kann zudem der Aufwand für die Datenaufbereitung weiter reduziert werden.

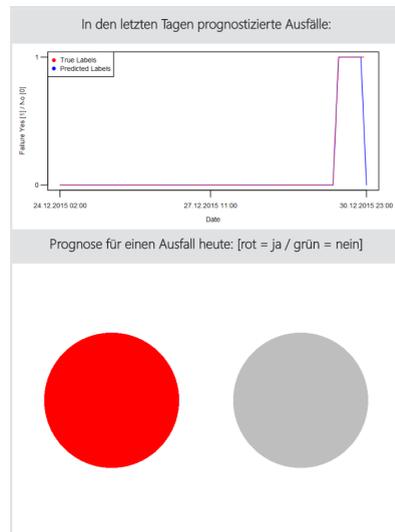


Abbildung 59: Prognose 30.12.2015. Eigene Darstellung.

Demonstrator «Edge Service»

Im «Edge Service» Demonstrator zu Data4KMU wurde ein künstliches neuronales Netzwerk (Artificial Neural Network - ANN) genutzt, um fehlerhafte Produktionsschritte durch Bilderkennung zu erfassen. So zum Beispiel kann – wie in Abbildung 59 sichtbar – ein fehlerhafter Produktionsschritt optisch erkannt werden. Im unten angeführten Beispiel wird eine fehlende Sensoreinheit erkannt und im Bild rot eingefärbt. Ein korrekt montiertes Auto wird im Bild ebenfalls erkannt und mit einem grünen Rahmen versehen. Die Bilderkennung wurde mit einem Intel Movidius Compute Stick – einem USB-Stick großem Beschleuniger für ANN und einer Leistungsaufnahme unter einem Watt – realisiert.

Zudem wurde in Zusammenarbeit mit dem NTB Buchs und dem KMUdigital Teilprojekt i4production ein von dem NTB entwickeltes Programm zur Festigkeitsberechnung so angepasst, dass es auch für 3D-Modelle / CAD-Daten der Reifen des Modellautos aus der verteilten Produktion einsetzbar ist. Die Festigkeitsberechnung wird nun in der Cloud asynchron ausgeführt und kann ebenso in der

Demoplattform KMUdigital Control Centre als Teil der vorhandenen Datenstruktur abgerufen werden.

Der Data4KMU Demonstrator dient hier hauptsächlich dazu, Integration von asynchron generierten Daten / Resultate im Backend zu demonstrieren (siehe Abbildung 61).

Um etwaige Sicherheitsbedenken von KMU auszuräumen wurde ein Demonstrator zu Sicherheit im KMUdigital Daten-Ökosystem entwickelt. Zielsetzung hierbei ist es, dass bestimmte Daten nur von autorisierten Benutzergruppen / Unternehmen ausgelesen werden können. Die Umsetzung erfolgte mittels Attribut-basierter Verschlüsselung (ABE) und der Möglichkeit einer Anbindung an Blockchain-Technologien. Bei der ABE kann für jedes Attribut («Datenfeld» bzw. «Dateneintrag») separat festgelegt werden, von wem das besagte Attribut entschlüsselt werden kann. Dies erlaubt eine feingranulare Verschlüsselung basierend auf Attributen (vgl. Abbildung 62).

II: Demonstrator: integration of rigidity simulation into business process

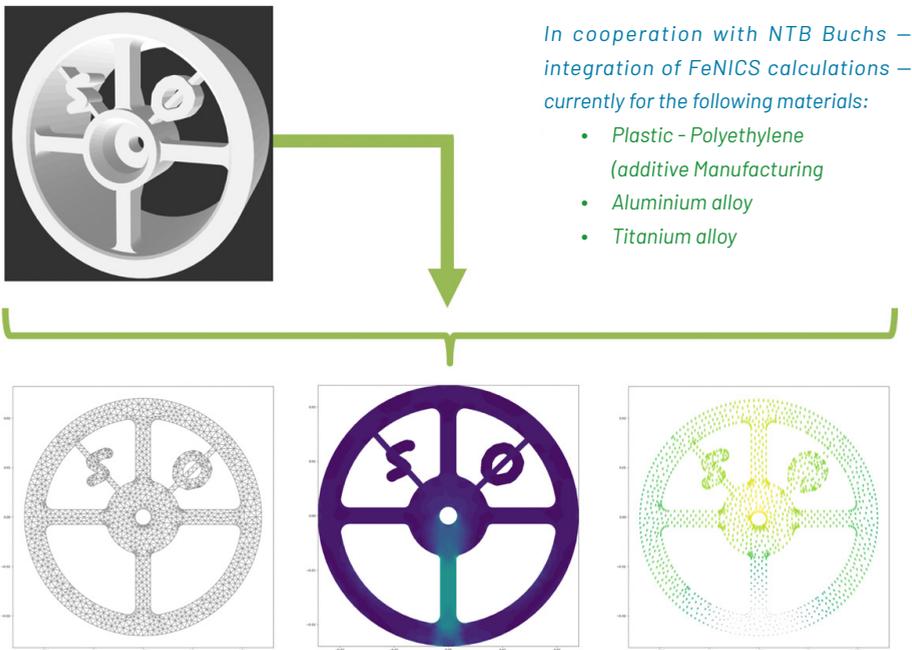


Abbildung 61: Demonstrator zur Festigkeitsberechnung. Eigene Darstellung.

Was KMU tun können

Durch den Datenschatz, den sich bereits viele Unternehmen angesammelt haben, lassen sich nützliche Dashboards erstellen, welche die Unternehmen bei ihrem Tagesgeschäft unterstützen können. Es konnte aufgezeigt werden, dass dabei diverse Ansätze verwendet werden können. Für Unternehmen, welche nur über grundlegendes Data Science Know-How verfügen und zwar Daten sammeln, damit aber noch keinerlei Analysen

vorgenommen haben, lässt sich mit wenig Aufwand ein Dashboard erstellen, welches dem Unternehmen einen grossen Mehrwert liefern kann. Die Tatsache, dass aus verhältnismässig kleinem Aufwand ein grosser Nutzen erzielt werden kann, scheint den Unternehmen oft noch nicht bewusst zu sein. Mit dem «Edge Service»-Demonstrator wurde aufgezeigt, dass auch für Anwendungen mit höheren Anforderungen



Attribute-Based Encryption

Introduction

Access control is an important aspect of data security. Especially in manufacturing it is important to keep your data safe. A new way to enable access control is using encryption. Widely known methods like standard symmetric or asymmetric encryption are not enough. New methods like the attribute-based encryption can be used to have access policies within the encryption on the data. This helps us to use the encryption as an access control mechanism without relying on other applications or tools.

Toggle Decrypt/Encrypt

Example: Production Data (only temperature and humidity sensors)

ID	Entity	Value	Sender	Creation Time	Modification Time
1	Voltage sensor	encrypted value	encrypted value	encrypted value	encrypted value
2	Current sensor	encrypted value	encrypted value	encrypted value	encrypted value
3	Humidity sensor	36.476	FHV/mLab	2019-06-12 18:32:01	2019-06-12 18:32:01

Abbildung 62: Sicherheitseinstellung für Daten via ABE - nur Feuchtigkeitssensoren können ausgelesen werden, andere Daten sind nur verschlüsselt vorhanden. Eigene Darstellung.

ein Dashboard entwickelt werden kann. Beispielsweise lässt sich ein Algorithmus zur Bilderkennung in ein Dashboard einarbeiten. Das Erstellen dieser Dashboards, für welches ein gewisses Know-How im Bereich Data Science nötig ist, könnte ein potentes Geschäftsfeld für einen Service sein. Die Unternehmen können durch solche Dashboards ihr Tagesgeschäft unterstützen und dadurch den Nutzen eines solchen Services aufzeigen und eine Nachfrage erzeugen.

Um die Voraussetzungen für diesen Ansatz zu schaffen, empfiehlt es sich für KMU, angefallene Daten zu sammeln, sofern dies nicht schon gemacht wird. Mit grundlegendem Data Science Know-How lässt sich bereits ein einfaches Dashboard erstellen, welches den Unternehmen einen Mehrwert bringen kann. Parallel dazu sollten Unternehmen mit dem Know-How Aufbau für die Datenanalyse starten. Falls dies nicht möglich ist, sollte die Möglichkeit in Betracht gezogen werden, einen solchen Service von einem externen Anbieter oder in Kooperation mit anderen KMU zu erwerben.

Die wichtigsten Erkenntnisse

- Viele Unternehmen, vor allem KMU, haben zu wenig Data Science Know-How, um aus den internen Daten die richtigen Schlüsse zu ziehen.
- Der Aufwand für ein Dashboard, welches die grundlegendsten Erkenntnisse aus den Daten aufzeigt, ist verhältnismässig gering.
- Voraussetzung für den Einsatz eines solchen Dashboards sind in der Vergangenheit angesammelte Daten.
- Bei den meisten Unternehmen kann ein einfaches Dashboard mit einem Ampel-System bereits einen Mehrwert generieren.
- Ein solcher Demonstrator kann in einem frühen Entwicklungsschritt helfen, kulturelle Anfangshürden («Soft Faktoren») in einer Organisation zu überwinden. Werden damit einmal der potenzielle Nutzen sichtbar und die Bedenken betreffend Aufwand und Komplexität objektiviert, besteht eine Grundlage für eine Weiterentwicklung des Unternehmens in Richtung Data Science.

Platz für Ihre Notizen:

Literaturverzeichnis

Editorial und Einleitende Kapitel

Mayring, P. (1996). Einführung in die qualitative Sozialforschung. Eine Anleitung zu qualitativem Denken (3. Auflage). Weinheim: Psychologie Verlags Union.

Mayring, P. (2000). Qualitative Inhaltsanalyse. Grundlagen und Techniken (7. Auflage, erste Auflage 1983). Weinheim: Deutscher Studien Verlag.

API – Daten und Data Science in KMU und Grossunternehmen: Wo stehen wir?

Amazon (2020). Unternehmenswebsite www.amazon.com. Zugegriffen am 13.01.2020.

Bodensee-Zentrum Innovation 4.0 (2019). Die ersten 10 Prozent – Digitalisierungspioniere berichten. Digitalisierung als Mehrwert begreifen – Winterhalter GmbH Meckenbeuren.
<https://youtu.be/ixT018dnORA>. Zugegriffen am 05.12.2019.

Christensen, C.M. (1997). The innovator's dilemma. When new technologies cause great firms to fail. Cambridge MA: Harvard Business Review Press.

Christensen, C.M., M. Raynor; R. McDonald (2016). Was ist Disruptive Innovation? Harvard Business Manager, Januar, 64-75.

Côrte-Real, N.; T. Oliveira; P. Ruivo (2017). Assessing business value of big data analytics in european firms. Journal of Business Research, Vol. 70, 379-390.

Davenport, T.H. (2006). Competing on analytics. Harvard Business Review, Vol. 84(1), 98-107.

Günther, W.A.; M.H. Rezazade Mehrizi; M. Huysman; F. Feldberg (2017). Debating big data: A literature review on realizing value from big data. Journal of Strategic Information Systems 26 (2017), 191-209.

Gupta, M.; J.F. George (2016). Toward the development of a big data analytics capability, Information and Management, Vol. 53(8), 1049-1064.

Kugler, P. (2019a). Digitale Veränderungen Teil 6/6: Handlungsmöglichkeiten im Umgang mit digitalen Disruptionen. KMU-Magazin Nr. 9/2019, 34-37. <https://www.kmu-magazin.ch/digitalisierung-transformation/handlungsmoeglichkeiten-im-umgang-mit-digitalen-disruptionen>. Zugegriffen am 13.01.2020.

Kugler, P. (2019b). Digitale Veränderungen Teil 5/6: So können digitale Disruptionen erkannt werden. KMU-Magazin Nr. 7-8/2019, 54-58. <https://www.kmu-magazin.ch/digitalisierung-transformation/so-koennen-digitale-disruptionen-erkannt-werden>. Zugegriffen am 13.01.2020.

Kugler, P.; R. Tietz (2015). Strategische Innovationen 2/2: Mehr Potenzial durch Strategische Innovationen. KMU-Magazin, Nr. 1/2, 92-98. <https://www.kmu-magazin.ch/forschung-entwicklung/mehr-potenzial-durch-strategische-innovationen>. Zugegriffen am 13.01.2020.

Kugler, P.; R. Tietz (2019). Digitalisierung in Strategie und Geschäftsmodell (AP2). In Institut für Prozessmanagement der FHS St.Gallen (Hrsg.): Nutzenbasierter Digitalisierungsnavigator. Wie KMU ihre Digitalisierungsstrategie selbst entwickeln können. <http://bzi40.eu/informationen/publikationen/paper/298-nutzenbasierter-digitalisierungsnavigator-wie-kmu-ihre-digitalisierungsstrategie-selbst-entwickeln-koennen/file>. Zugegriffen am 05.09.2019.

Winterhalter Gastronom GmbH (2020). Unternehmenswebsite. www.winterhalter.com. Zugegriffen am 13.01.2020.

AP2 – Data Science, Strategie und Wettbewerb

Barney, J. (1991). Firm resources and sustained competitive advantage. *Journal of Management*, Vol. 17(1), 99-120.

Christensen, C.M. (1997). *The innovator's dilemma. When new technologies cause great firms to fail*. Cambridge MA: Harvard Business Review Press.

Christensen, C.M., M. Raynor; R. McDonald (2016). Was ist Disruptive Innovation? *Harvard Business Manager*, Januar, 64-75.

Chui, M.; J. Manyika (2015). Competition at the digital edge: «Hyperscale» businesses. McKinsey Quarterly, March.

Fosso Wamba, S.; A. Gunasekaran; S. Akter; S. J. Ren; R. Dubey; S.J. Childe (2017). Big data analytics and firm performance: Effects of dynamic capabilities. Journal of Business Research, Vol. 70, (2017), 356–365.

Fosso Wamba, S.; S. Akter; A. Edwards; G. Chopin; D. Guanzou (2015). How «Big Data» can make big impact: Findings from a systematic review and a longitudinal case study. International Journal of Production Economics, Vol. 165, 234–246.

Henke, N. et al. (2016). The age of analytics: Competing in a data-driven world. Research Report Executive Summary. London et al.: McKinsey Global Institute in Collaboration with McKinsey Analytics.

Kugler, P. (2019a). Digitale Veränderungen Teil 6/6: Handlungsmöglichkeiten im Umgang mit digitalen Disruptionen. KMU-Magazin Nr. 9/2019, 34–37. <https://www.kmu-magazin.ch/digitalisierung-transformation/handlungsmoeglichkeiten-im-umgang-mit-digitalen-disruptionen>. Zugegriffen am 13.01.2020.

Kugler, P. (2019b). Digitale Veränderungen Teil 5/6: So können digitale Disruptionen erkannt werden. KMU-Magazin Nr. 7-8/2019, 54–58. <https://www.kmu-magazin.ch/digitalisierung-transformation/so-koennen-digitale-disruptionen-erkannt-werden>. Zugegriffen am 13.01.2020.

Kugler, P. (2019c). Digitale Veränderungen Teil 4/6: Digitales Handeln für nachhaltige Wettbewerbsvorteile. KMU-Magazin Nr. 6/2019, 34–37. <https://www.kmu-magazin.ch/digitalisierung-transformation/digitales-handeln-fuer-nachhaltige-wettbewerbsvorteile>. Zugegriffen am 13.01.2020.

Kugler, P. (2019d). Digitale Veränderungen Teil 3/6: Wo befinden sich Schweizer KMU auf der digitalen Reise? KMU-Magazin Nr. 4–5/2019, 50–53. <https://www.kmu-magazin.ch/digitalisierung-transformation/wo-befinden-sich-schweizer-kmu-auf-der-digitalen-reise>. Zugegriffen am 13.01.2020.

Kugler, P. (2019e). Digitale Veränderungen Teil 2/6: Wie sich Individuen, Organisationen und der Wettbewerb «digitalisieren». KMU-Magazin Nr. 3/2019, 26–30. <https://www.kmu-magazin.ch/digitalisierung-transformation/wie-sich-individuen-organisationen-und-der-wettbewerb-digitalisieren>. Zugegriffen am 13.01.2020.

Kugler, P. (2019f). Digitale Veränderungen Teil 1/6: Strategische Herausforderungen der digitalen Transformation. KMU-Magazin Nr. 1-2/2019, 40-44. <https://www.kmu-magazin.ch/digitalisierung-transformation/strategische-herausforderungen-der-digitalen-transformation>. Zugegriffen am 13.01.2020.

Kugler, P.; R. Tietz (2019). Digitalisierung in Strategie und Geschäftsmodell (AP2). In Institut für Prozessmanagement der FHS St.Gallen (Hrsg.): Nutzenbasierter Digitalisierungsnavigator. Wie KMU ihre Digitalisierungsstrategie selbst entwickeln können. <http://bzi40.eu/informationen/publikationen/paper/298-nutzenbasierter-digitalisierungsnavigator-wie-kmu-ihre-digitalisierungsstrategie-selbst-entwickeln-koennen/file>. Zugegriffen am 05.09.2019.

Remane, G.; A. Hanelt; R.C. Nickerson; L. M. Kolbe (2017). Discovering digital business models in traditional industries. *Journal of Business Strategy*, Vol. 38(2), 41-51, <https://doi.org/10.1108/JBS-10-2016-0127>.

AP3 – Data Science und Geschäftsmodelle

Hartmann, P.M.; M. Zaki; N. Feldmann; A. Neely (2014). Big data for big business? A taxonomy of data-driven business models used by start-up firms. Working Paper, Cambridge: University of Cambridge.

Kollmann, T. (2016). E-Business. Grundlagen elektronischer Geschäftsprozesse in der digitalen Wirtschaft. Wiesbaden: SpringerGabler.

Morabito, V. (2015). Big data driven business models. In: Big data and analytics – strategic and organizational impacts, 65-80. Springer International Publishing.

Opresnik, D.; M. Taisch (2015). The value of big data in servitization. *International Journal of Production Economics*, Vol. 165, C, 174-184.

Porter, M.E.; J.E. Heppelmann (2015). How smart, connected products are transforming companies. *Harvard Business Review*, Vol. 93(10), 96-16.

AP4 – Data Science und Services

Baines, T.; H.W. Lightfoot (2013). Servitization of the manufacturing firm, *International Journal of Operations and Production Management*, Vol. 34(1), 2 – 35.

Chen, Y.G., C.M. Hsu; Z.H. Chen (2010). The service design strategy of manufacturing service industry. In: *PICMET 2010 Technology Management for Global Economic*.

Fang, E.; R.W. Palmatier; S.B.E. Steenkamp (2008). Effect of service transition strategies on firm value. *Journal of Marketing*, Vol. 72(5), 1-14.

Gebauer, H.; G.-J. Ren; A. Valtakoski; J. Reynoso (2012). Service-driven manufacturing, provision, evolution and financial impact of services in industrial firms. *Journal of Service Management*, Vol. 23(1), 120 – 136.

Kindström, D.; C. Kowalkowski (2014). Service innovation in product-centric firms: A multi-dimensional business model perspective. *Journal of Business & Industrial Marketing*, Vol. 29(2), 96 – 111 (2014).

Kowalkowski, C.; W. Ulaga (2017). *Service strategy in action: A practical guide for growing your B2B service and solution business*. Service Strategy Press.

Lay, G. (2014). Introduction. In: *Servitization in industry*, ed. Lay, G., 1 – 20.

Lusch, F.L.; S.L. Vargo (2014). *Service-dominant logic*. Cambridge: Cambridge University Press.

Porter, M. and Heppelmann, J. (2014). How smart, connected products are transforming competition. *Harvard Business Review* Vol. 92(11), 64-88.

Stich, V.; J.V. Schumann; D. Beverungen; G. Gudergan; P. Jussen (2019, Hrsg.): *Digitale Dienstleistungsinnovationen: Smart Services agil und kundenorientiert entwickeln*. Berlin: Springer.

Tao, F., Qi, Q. Liu, A., Kusiak, A. (2018). Data-driven smart manufacturing, *Journal of Manufacturing Systems*, Vol. 48, Part C, 157-169.

Uлага, W.; W.J. Reinartz (2011). Hybrid offerings: How manufacturing firms combine goods and services successfully. *Journal of Marketing*, Vol. 75(6), 5-23.

Vargo, S.L.; R.F. Lusch (2008). From goods to service(s): Divergences and convergences of logics. *Industrial Marketing Management* Vol. 37, 254 – 259.

AP5 – Data Science und Prozesse

Heyde (2019). Process Mining: Goldgräberstimmung im Prozessmanagement – Mit datenbasierter Prozessoptimierung zum Unternehmenserfolg. <https://www.heyde.ch/process-mining-mit-datenbasierter-prozessoptimierung-zum-unternehmenserfolg>. Zugegriffen am 10.12.2019.

Hilbert, A.; P. Zschech (2016). *Process analytics*, Vol. 45, 942-948.

Peters, R.; M. Nauroth (2019). *Process-Mining: Geschäftsprozesse: Smart, schnell und einfach*. Wiesbaden: Springer Gabler.

Rouse, M. (2015). What is robotic process automation? <https://internetofthingsagenda.techtarget.com/definition/robotic-process-automation>. Zugegriffen am 13.10.2019.

Schmiedel, D., O. Jessensky (2015). *Process Mining in der Praxis*. https://www.opitz-consulting.com/fileadmin/user_upload/Collaterals/Artikel/business-technology-2015-02_process-mining_schmiedel-jessensky_sicher.pdf . Zugegriffen am 13.10.2019.

van der Aalst, W.M.P. (2016). *Process Mining: Data Science in Action*. 2. Auflage, Berlin, Heidelberg.

AP6 – Datenkompetenz in Organisationen/KMU

Adlon (2019a). *ADLON Intelligent Solutions GmbH – Strategie und Vision*. Unveröffentlichtes Manuskript, Ravensburg: Autor.

Adlon (2019b). Digital Maturity: Ihr digitaler Reifegrad als Basis für eine erfolgreiche Digitalisierung. https://adlon.de/innovation-intelligence/digital-maturity-level/?pk_campaign=GA_Innovation&pk_kwd=Digital%20Maturity&keyword=%2Bdigital%20%2Bmaturity&device=c&network=g&gclid=Cj0KCQiAjfwBRcKARIsAlqSWIMZdwH0sbzwytXorHdv1jv-0ENRkWqdtvgJdUxjh-6ZDJS5NNer-6kaAguJEALw_wcB. Zugegriffen am 01.06.2019.

Ala-Mutka, K. (2011). Mapping Digital Competence: Towards a Conceptual Understanding. Luxembourg: Publications Office of the European Union. Abgerufen von <https://www.semanticscholar.org/paper/Mapping-Digital-Competence%3A-Towards-a-Conceptual-Ala-Mutka/dd8bb2ae8ae95b9b91c3d623581f3b4a08c5bbb5>. Zugegriffen am 01.06.2019.

Dämon, K. (2017, 28. September). Wie die Digitalisierung Jobs verändert. In Zukunft wird es nur noch Spezialisten geben. WirtschaftWoche Online. Abgerufen von <https://www.wiwo.de/erfolg/beruf/wie-die-digitalisierung-jobs-veraendert-in-zukunft-wird-es-nur-noch-spezialisten-geben/20389848.html>. Zugegriffen am 01.06.2019.

IFLA International Federation of Library Associations and Institutions. (2017). Erklärung der IFLA zu digitaler Kompetenz. https://www.ifla.org/files/assets/faife/statements/ifla_digital_literacy_statement-de.pdf. Zugegriffen am 02.06.2019.

Joblift. (2018). Data Science - mehr als Datenbanken: Jede zweite Stellenanzeige nennt Kommunikationsstärke als unverzichtbare Fähigkeit. <https://joblift.de/Presse/data-scientist>. Zugegriffen am 01.06.2019.

Kugelmeier, D. (2019). Zertifizierungshandbuch und Prüfungsordnung – Personenzertifizierungen im Bereich Data Science. St. Augustin.

Olbert-Bock, S. & Redzeqi, A. (2018). Personalpolitische Rahmenbedingungen in der Bodenseeregion. In: Grünbuch Digitale Agenda Bodensee – Eine Bestandsaufnahme zum Potential der Digitalisierung innerhalb KMU in der Bodenseeregion, 22-33.

Olbert-Bock, S.; A. Redzepi (2019). Skills für die digitale Zukunft. Kompetenzentwicklung zur erfolgreichen Bewältigung der Transformation. *personalSCHWEIZ*, Vol. 8(19), 25-27.

Pankow, G. (2017). Wer ist hier der Boss? *Produktion*, Heft 18/2017, 12-13

Seufert, A. (2017). Information als strategische Ressource nutzbar machen. *Controller Magazin*, Heft 5/2017, 79-83.

AP7 – Data Science braucht Organisationskultur und Ganzheitlichkeit

Brown, B.; D. Court; P. Willmott (2013). Mobilizing your C-suite for big-data analytics. *McKinsey Quarterly*, November.

Chin, J.K., Hagstroem, M.; A. Libarikian; K. Rifai (2017). Advanced analytics: Nine insights from the C-suite, *McKinsey Analytics*, July.

Henke, N. et al. (2016). The age of analytics: Competing in a data-driven world. *Research Report Executive Summary*. London et al.: McKinsey Global Institute in Collaboration with McKinsey Analytics.

KPMG (2017). Mit Daten Werte schaffen. *Report 2017*, in Kooperation mit Bitkom Research.

New Vantage Partners LLC (2019). *Data and innovation: How big data and AI are accelerating business transformation. Big data and AI executive survey 2019, Executive Summary of Findings*, Boston et al.

Schein, E. (1985). *Organizational culture and leadership*, San Francisco: Jossey-Bass.

Vargo, S.L.; R.F. Lusch (2004). Evolving to a new dominant logic for marketing. *Journal of Marketing*, Vol. 68(1), 1-17.

Westerman, G.; D.L. Soule; A. Eswaran (2019). Building digital-ready culture in traditional organizations. *Sloan Management Review*, Summer 2019.

Impressum

An diesem Projekt beteiligte Hochschulen:

- ZHAW Zürcher Hochschule für Angewandte Wissenschaften, School of Engineering
- FHS St. Gallen Hochschule für Angewandte Wissenschaften
(ab 09.2020 neue Bezeichnung: OST - Ostschweizer Fachhochschule)
- Fachhochschule Vorarlberg
- Hochschule Konstanz Technik, Wirtschaft und Gestaltung

Herausgeber:

ZHAW Zürcher Hochschule für Angewandte Wissenschaften, School of Engineering

Redaktion:

Martin Dobler, Roman Etschmann, Prof. Dr. Petra Kugler, Dr. Jürg Meierhofer,
Prof. Dr. Sibylle Olbert-Bock, Abdullah Redzepi, Prof. Dr.-Ing. Jens Schumacher,
Prof. Dr. Christian Thiel, Prof. Dr. Rigo Tietz

Gestaltung:

Bodenseezentrum Innovation 4.0 | HTWG Konstanz

Bildnachweise:

Seite 30: © Kir Smyslov – stock.adobe.com

Seite 89: © red150770 – stock.adobe.com

Seite 98: © Funtap – stock.adobe.com

Seite 125: © deepagopi2011 – stock.adobe.com

Aktualisierte Auflage August 2020

Das Projekt IBH-Lab KMUdigital ABH 69 «Data4KMU» wird aus Mitteln des Interreg-Programms «Alpen-rhein-Bodensee-Hochrhein», dessen Mittel vom Europäischen Fonds für regionale Entwicklung (EFRE) und vom Schweizer Bund zur Verfügung gestellt werden, gefördert.

IBH-Lab KMUdigital
Data Science für KMU leicht gemacht (Data4KMU)

ZHAW School of Engineering (ZHAW)

Institut für Datenanalyse und Prozessdesign (IDP)
Rosenstrasse 3
8400 Winterthur, Schweiz
www.zhaw.ch

FHS St. Gallen (FHSG)

Hochschule für Angewandte Wissenschaften
(Ab 09.2020 neue Bezeichnung: OST – Ostschweizer Fachhochschule)
Institut für Informations- und Prozessmanagement IPM-FHS
Institut für Unternehmensführung IFU-FHS
Institut für Qualitätsmanagement und angewandte Betriebswirtschaft IQB-FHS
Rosenbergstrasse 59, Postfach
9001 St.Gallen, Schweiz
www.fhsg.ch

Fachhochschule Vorarlberg (FHV)

PPE – Prozess- und Produkt-Engineering
Hochschulstrasse 1
6850 Dornbirn, Österreich
www.fhv.at

Hochschule Konstanz (HTWG)

Technik, Wirtschaft und Gestaltung
Bodenseezentrum Innovation 4.0
Alfred-Wachtel-Str. 8
78462 Konstanz, Deutschland
www.htwg-konstanz.de

www.kmu-digital.eu

www.bodenseehochschule.org

