

# Eine Einführung in Data Science aus Projektsicht

In einem Data-Science-Projekt wollen wir Daten und Analysen nutzen, um einen Mehrwert für uns, unser Unternehmen oder unsere Kunden zu schaffen. Wichtig ist dabei, dass nicht alles, was mit Daten zu tun hat, automatisch Data Science ist. Die operative Nutzung von Daten, beispielsweise in der Buchhaltung, der Inventarliste oder im CRM-System, muss zunächst einmal nichts mit Data Science zu tun haben, sondern kann einfach nur der Abwicklung operativer Prozesse dienen. Data Science kommt ins Spiel, sobald wir einen zusätzlichen Mehrwert durch die Analyse dieser Daten schaffen wollen. Bei Bedarf können wir darüber hinaus zusätzliche Daten erheben, um komplexere Fragestellungen zu beantworten. Dabei stellt sich die Frage, welche Arten von Mehrwert wir mit Daten und Analysen erzeugen können. Wir gehen davon aus, dass wir Data Science in einem Unternehmen einsetzen möchten. Dann können wir grundsätzlich drei Einsatzarten unterscheiden:

**Prozessoptimierung:** Wir nutzen Data Science, um die Prozesse und Abläufe in unserem Unternehmen zu verbessern. Dabei kann jeder Funktionsbereich (Buchhaltung, Personalwesen, Marketing usw.) davon profitieren, wenn bessere Informationen zur Verfügung stehen. Dies kann je nach Anwendungsfall zu Kosteneinsparungen, besseren Entscheidungen oder schnelleren Prozessabläufen führen.

**Datenbasierte Produkte und Geschäftsmodelle:** Daneben können wir Data Science einsetzen, um unsere Produkte zu verbessern oder neue Produkte zu entwickeln. Entscheidend ist hierbei, dass die Verwendung von Data Science ein Teil des Mehrwerts wird, den wir unserer Kundschaft bieten. Manche Unternehmen entwickeln Daten und Analyseergebnisse selbst zu Produkten, andere ergänzen bestehende Produkte und machen beispielsweise eine Glühbirne »smart«.

Letztlich können auch Daten selbst ein Produkt sein, wenn die Daten einen Mehrwert für andere haben, beispielsweise die Immobilienpreise einer Region. Dies funktioniert allerdings in der Praxis nur für relativ wenige Anbieter. Die meisten setzen auf datenbasierte Produkte und Geschäftsmodelle.

**Strategische Entscheidungen:** Bei strategischen Entscheidungen geht es um einmalige Entscheidungen mit wichtigen Konsequenzen. Die Entscheidungen sind so schwerwiegend, dass es sich lohnt, ein Datenanalyseprojekt hierfür aufzusetzen.

Folglich ergibt sich der Mehrwert von Data Science bei der Prozessoptimierung eher durch eine Vielzahl vergleichbarer Entscheidungsprobleme, auf die entsprechend optimiert werden kann. In der Strategie hingegen geht es mehr um Einzelfallentscheidungen, bei denen die Analysen stärker in die Tiefe gehen. In der Praxis kann es dabei aber auch zu einem fließenden Übergang kommen, wie wir weiter unten im Zusammenhang mit dem Analytics Continuum sehen werden.

In der Literatur (Beispiel: Valliappa Lakshmanan. *Data Science on the Google Cloud Plattform*, O'Reilly 2022) sehen wir manchmal die Unterscheidung, dass einmalige strategische Entscheidungen als »Datenanalysen« bezeichnet werden und die Optimierung von Prozessen (mit potenziell automatisierten Analysen und Entscheidungen) als »Data Science«. Für unsere Einführung zu Data Science wollen wir den Begriff »Data Science« jedoch bewusst weiter fassen und auch einmalige Analyseprojekte einbeziehen, vor allem weil es sich hierbei eher um eine theoretische Abgrenzung handelt, die unserer Erfahrung nach nicht zur Praxis von Data-Science-Projekten und deren Management passt.

## Verlauf eines Data-Science-Projekts (Prozessmodell)

In Data-Science-Projekten lassen sich gewisse wiederkehrende Abläufe identifizieren, die eigentlich immer vorkommen, sinnvollerweise in einer gewissen Reihenfolge ablaufen sollten und entsprechend als *Prozessmodell* dargestellt werden können. Das Prozessmodell, das den folgenden Darstellungen zugrunde liegt, besteht aus fünf Prozessschritten, die einerseits ein existenzieller Teil jedes Data-Science-Projekts sind, andererseits aber auch spezifische Anforderungen an das Team und dessen Kompetenzen stellen (siehe Abbildung 1-1). Das Modul wurde als Teil von Beratungsprojekten der Impact Distillery<sup>1</sup> entwickelt und basiert insbesondere auf dem *Generic Longitudinal Business Process Model*<sup>2</sup> (GLBPM) sowie dem Prozessmodell von Mischa Seiter<sup>3</sup>.




Abbildung 1-1: Prozessmodell der Impact Distillery (<https://www.impactdistillery.com/de/digitale-transformation/datengetriebene-organisationskultur/>)

Die fünf Schritte unseres Modells umfassen die konzeptionelle Planung (Design) des Projekts, die Arbeitsschritte, um eine belastbare Datengrundlage zu schaffen, die eigentliche Analyse der Daten, die Dokumentation der Ergebnisse und deren Umset-

1 <https://www.impactdistillery.com/>

2 I. Barkow, W. Block, J. Greenfield, A. Gregory, M. Hebing, L. Hoyle, W. Zenk-Möltgen. »Generic Longitudinal Business Process Model«. *DDI Working Paper Series – Longitudinal Best Practices*, No. 5, 2013, <https://ddialliance.org/sites/default/files/GenericLongitudinalBusinessProcessModel.pdf>

3 M. Seiter (2019). *Business Analytics: Wie Sie Daten für die Steuerung von Unternehmen nutzen*. Vahlen.

zung in praktische Maßnahmen (Impact). Außerdem setzt das Modell ein iteratives Vorgehen voraus – sobald ein solches Projekt abgeschlossen ist, stehen für gewöhnlich neue Fragestellungen im Raum, die den Ausgangspunkt für ein neues Data-Science-Projekt bilden. Die fünf Schritte wollen wir uns im Folgenden einzeln anschauen:

- **Design:** Die Designphase legt den Grundstein für das Projekt. Idealerweise starten Projekte, weil es einen praktischen Bedarf (ein Businessproblem) gibt, der aber noch zu unspezifisch ist. Ein erster Arbeitsschritt ist nun, diesen Bedarf bzw. diese Problemstellung in eine Forschungsfrage zu übersetzen, die dann im Fokus aller folgenden Arbeitsschritte stehen wird. Basierend auf der Forschungsfrage kann jetzt auch ein Zeitplan für das Projekt entwickelt und können die notwendigen Ressourcen kalkuliert werden, die insbesondere die Beschaffung von Daten, eine technische Infrastruktur und personelle Ressourcen umfasst.
- **Daten:** In der zweiten Phase (siehe Kapitel 3, *Datenbeschaffung und -aufbereitung*) geht es um den Aufbau einer entsprechenden Datenbasis für die Bearbeitung der Forschungsfrage. Wenn nicht schon entsprechende Daten verfügbar sind, müssen gegebenenfalls neue Daten erhoben werden. In jedem Fall müssen diese Daten aufbereitet, qualitätsgesichert und für die weitere Nutzung bereitgestellt werden.
- **Analyse:** Die Auswahl der entsprechenden Analysemethoden orientiert sich dann sowohl an der Forschungsfrage als auch an der Struktur der Daten und gegebenenfalls auch an bereits durchgeführten Vorstudien. Im Abschnitt »Von einfachen Analysen zur Automatisierung (Analytics Continuum)« auf Seite 32 werden Sie das Analytics Continuum kennenlernen, das uns eine Entscheidungshilfe für die Auswahl von Analysemethoden in den aufeinander aufbauenden Phasen eines Data-Science-Projekts bietet. Dabei werden wir uns sowohl Methoden der klassischen Statistik als auch neuerer Machine-Learning-Algorithmen bis hin zu neuronalen Netzen ansehen.
- **Dokumentation:** Damit die Ergebnisse der Analysen dann praktisch genutzt werden können, müssen sie dokumentiert und kommuniziert werden. Dabei geht es zum einen um eine technische Dokumentation, um Daten und Methoden später nachnutzen zu können. Und zum anderen sollen die Ergebnisse ansprechend und leicht nachvollziehbar für ein nicht technisches Publikum aufbereitet werden, beispielsweise als Report oder interaktives Dashboard (siehe den Abschnitt »Reporting« auf Seite 83). Inhaltlich sind dabei nicht nur die vorteilhaften Ergebnisse zu berichten, sondern es sollte auch explizit auf mögliche Limitationen der jeweiligen Arbeit eingegangen werden. Gleichzeitig sollten die Inhalte aber für die jeweiligen Leserinnen und Leser verständlich präsentiert und erzählt werden (siehe dazu auch den Abschnitt »Storytelling und visuelle Kommunikation mit Daten« auf Seite 85).
- **Impact:** Mit Impact meinen wir alle praktischen Maßnahmen, die einen Mehrwert für den jeweiligen Auftraggeber bringen und damit die Kosten für ein Data-Science-Projekt rechtfertigen. Dieser Mehrwert kann monetär leicht messbar (z.B. wenn eine Steigerung der Verkaufszahlen gelingt) oder auch schwerer zu

greifen sein (z.B. wenn es um eine Steigerung der Kundenzufriedenheit geht). In jedem Fall ist es sinnvoll, die entsprechenden Maßnahmen zu evaluieren, um zu überprüfen, ob sie auch die gewünschte Wirkung haben, oder um gegebenenfalls nachzusteuern.

### Literaturempfehlung

M. Seiter (2019). *Business Analytics: Wie Sie Daten für die Steuerung von Unternehmen nutzen*. Vahlen.

## Von einfachen Analysen zur Automatisierung (Analytics Continuum)

Während die vorgestellten fünf Phasen unseres Prozessmodells gut geeignet sind, um einzelne Projekte zu strukturieren, werden wir in der Praxis selten nach einem einzelnen Projekt wieder aufhören, mit Daten zu arbeiten. Vielmehr werden die fünf Phasen in aufeinander aufbauenden Iterationen immer wieder neu durchlaufen, weswegen man auch von einem *Data-Science-Lifecycle* spricht. Aus fast jedem Data-Science-Projekt wird sich eine neue Fragestellung ergeben, die wir in einer neuen Iteration bearbeiten können. Dies können sowohl die Evaluation der Maßnahmen sein als auch eine weiterführende Analyse, beispielsweise wenn wir einen spannenden Zusammenhang in unseren Daten gefunden haben und uns nun fragen, ob wir diesen vielleicht auch für Vorhersagen nutzen können. Schließlich ist es möglich, sich in späteren Iterationen bis zu einer Automatisierung der Maßnahmen vorzuarbeiten (siehe Kapitel 15, *Automatisierung und Operationalisierung im kybernetischen Regelkreis*).

Auf dieser Ebene bietet uns das Analytics Continuum<sup>4</sup> von Gartner eine Struktur, anhand der wir uns im Laufe der Zeit und über verschiedene Iterationen hinweg von einfachen beschreibenden Analysen bis hin zu komplexen Automatisierungsprojekten bewegen können (siehe Abbildung 1-2).

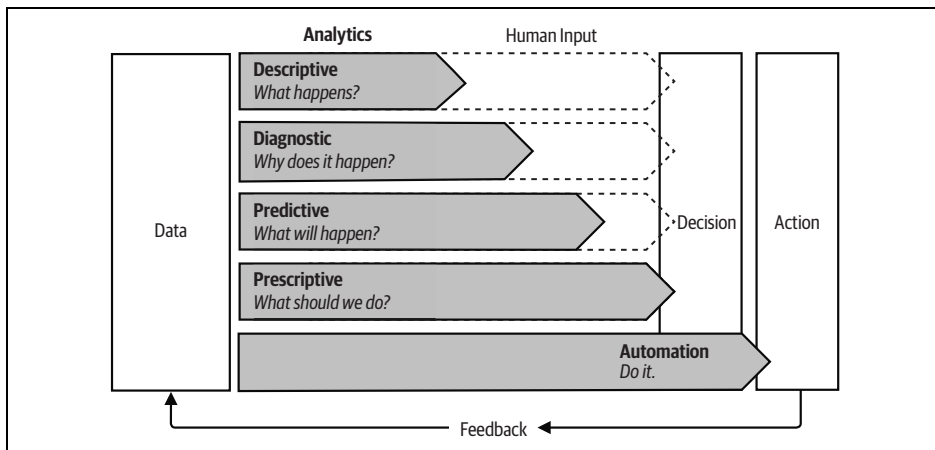


Abbildung 1-2: Analytics Continuum nach Gartner (eigene Darstellung)

<sup>4</sup> <https://www.gartner.com/en/newsroom/press-releases/2014-10-21-gartner-says-advanced-analytics-is-a-top-business-priority>

Schauen wir uns die fünf Ebenen des Analytics Continuum im Detail an:

### **Beschreibende Analysen (Descriptive)**

Am Anfang eines Projekts brauchen wir einen guten Überblick über den Status quo, also das, was gerade passiert. Dabei reichen meist einfache deskriptive Analysen und Visualisierungen aus, um schnell die aktuelle Lage einschätzen zu können, gegebenenfalls auch im Vergleich mit historischen Daten. Ein einfaches Beispiel ist das Inventarverzeichnis in einem Lager. Basierend darauf können wir uns einen Überblick darüber verschaffen, welche Produkte, Produktkategorien, Marken oder Ähnliches wir aktuell vorrätig haben.

### **Diagnostische Analysen (Diagnostic)**

Als Nächstes werden wir uns fragen, wie es zum aktuellen Zustand gekommen ist. Wenn beispielsweise ein Produkt im Lager nicht mehr vorhanden ist, liegt das daran, dass dieses Produkt nicht mehr verfügbar ist? Oder daran, dass die Nachfrage so groß ist, dass wir in der Lieferung kaum hinterherkommen? Im Bereich der diagnostischen Analysen interessieren wir uns besonders für kausale Beziehungen. Was ist die Ursache für bestimmte Phänomene?

### **Vorhersagende Analysen (Predictive)**

Wenn wir die Ursachen verstanden haben, können wir versuchen, darauf aufbauend Vorhersagen zu treffen. Wenn wir merken, dass die Nachfrage nach einem bestimmten Produkt gerade sehr hoch ist, wollen wir beispielsweise wissen, wie groß die Nachfrage voraussichtlich im nächsten Monat sein wird, um entsprechende Vorkehrungen treffen zu können.

### **Vorschreibende Analysen (Prescriptive)**

Nachdem wir nun eine Vorstellung davon haben, wie viele Produkte im kommenden Monat nachgefragt werden könnten, stellt sich als Nächstes die Frage, wie viele wir davon nachbestellen sollten. Dies ist etwas anderes als die reine Menge der Nachfrage, denn nun müssen wir zusätzliche Faktoren miteinbeziehen: Wie lange ist die zu erwartende Lieferdauer? Wie viel Platz haben wir im Lager zur Verfügung? Wie haltbar ist das Produkt? Wir wollen nun eine Handlungsempfehlung formulieren, haben es dabei aber schnell mit einem Optimierungsproblem zu tun, wenn wir die angedeuteten Fragen miteinbeziehen. Ist beispielsweise nur begrenzt Platz im Lager, müssen wir vielleicht zwischen mehreren Produkten abwägen, die aktuell stark nachgefragt sind.

### **Automatisierung (Automation)**

Wenn sich unsere Vorhersagen und Handlungsempfehlungen über längere Zeit bewährt haben, werden wir in Erwägung ziehen, diese zu automatisieren. Wir können also beispielsweise in der Software der Lagerhaltung ein Programm einbauen, das automatisch nachbestellt, sobald ein Produkt knapp wird, und dabei die Ergebnisse der vorherigen Phase nutzen, um die richtigen Mengen zu kalkulieren.

Ein häufig anzutreffender konzeptioneller Fehler, den wir immer wieder in Diskussionen um den Einsatz von Data Science sehen, ist ein vorschneller Fokus auf die letzten Phasen, insbesondere auf die Automatisierung von Prozessen. Eine wesentli-

che Erkenntnis aus der langjährigen Arbeit mit dem Analytics Continuum ist, dass wir die ersten Phasen nie überspringen können. Wir werden uns immer erst mal einen Überblick über den Status quo verschaffen müssen, verstehen, wie dieser zustande gekommen ist, und erste Vorhersagen testen. Erst dann können wir uns an die Entwicklung von Empfehlungssystemen oder die Automatisierung von Prozessen machen.

Im dritten Teil des Buchs werden wir dann sehen, dass insbesondere mit zunehmender Automatisierung der Prozessabläufe (egal ob bei der Auswertung der Daten oder auch bei der Umsetzung in Maßnahmen) eine Anpassung des Prozessmodells Sinn ergeben wird. Sie werden dazu in Kapitel 15, *Automatisierung und Operationalisierung im kybernetischen Regelkreis*, den kybernetischen Regelkreis als Modell und Werkzeug zur Strukturierung von automatisierten Prozessen kennenlernen.

## Welche Kompetenzen brauchen wir in einem Data-Science-Projekt?

Data Science wird gern als inter- oder transdisziplinäre Wissenschaft bezeichnet. Das bedeutet, dass Data Science ganz wesentlich auf einer Reihe anderer Disziplinen aufbaut. Conway (2010<sup>5</sup>) nennt dabei Programmierkenntnisse (Softwareentwicklung), Mathematik und Statistik sowie fundiertes Wissen um das jeweilige Anwendungsfeld (im Folgenden als Domain Knowledge bezeichnet) als die drei wesentlichen Fundamente für den Bereich Data Science. Wir möchten diese drei Bereiche noch um einen vierten Bereich ergänzen, der sich auf soziale Normen und Kommunikationsfähigkeit bezieht (die soziale Dimension).

### Statistik und Mathematik

Aus der Statistik übernimmt Data Science sowohl Methoden, um ein initiales Verständnis für die jeweiligen Daten zu gewinnen (deskriptive Statistik), als auch vielfältige Methoden zur Berechnung von abstrakten Modellen. Während bei der klassischen Statistik der Fokus der Modellbildung mehr auf dem Erklären von Zusammenhängen liegt, konzentriert sich die Modellbildung bei Data Science vorrangig auf die Vorhersage von Ereignissen. Beispiele für Vorhersagen können von der Wettervorhersage über die Erzeugung von Kaufempfehlungen in Onlineshops bis zur Automatisierung des Nachkaufs in einem Warenlager reichen. Ein fundiertes statistisches Grundwissen bleibt auch in Zeiten zunehmend automatisierter Analysetools unerlässlich, denn wir müssen weiterhin hinterfragen, ob die Ergebnisse verlässlich und anwendbar für unsere jeweiligen Fragestellungen sind.

### Softwareentwicklung

Neben dem Fokus auf Vorhersagen ist die Bereitstellung und Analyse der Daten im Bereich Data Science deutlich rechenintensiver als in der klassischen Statistik, was die Softwareentwicklung ins Spiel bringt. Der Begriff *Big Data* bezieht

---

5 <http://drewconway.com/zia/2013/3/26/the-data-science-venn-diagram>

sich nicht nur auf das reine Speichervolumen der Daten, sondern schließt insbesondere auch Vielfältigkeit, teilweise Korrektheit und letztlich die Geschwindigkeit der Entstehung neuer Daten mit ein – alles Faktoren, die neben der eigentlichen Analyse der Daten wachsende Anforderungen an die (automatisierte) Aufbereitung der Daten stellen. Gleichzeitig müssen viele der Methoden aus der Statistik an die neuen Gegebenheiten angepasst werden, beispielsweise weil deren Berechnung über verschiedene Teilsysteme verteilt werden muss.

### **Fachexpertise**

Es wird gern als Faustregel genommen, dass in einem Data-Science-Projekt nur ca. 20 % der Arbeitszeit auf die eigentliche Arbeit an den Modellen entfällt und ca. 80 % auf die Aufbereitung der Daten. Diese 80 % erfordern neben dem bereits dargestellten technischen Wissen auch ein gutes Verständnis des jeweiligen Anwendungsfalls. Von Data Scientists wird daher erwartet, dass sie entsprechendes Vorwissen im jeweiligen Fachgebiet bzw. der jeweiligen Domäne mitbringen.

### **Soziale Dimension**

Die Zusammenarbeit und Kommunikation mit Stakeholdern ist ein wesentlicher Teil der Arbeit in Data-Science-Teams. Es geht nicht nur darum, ein möglichst gutes Modell zu entwickeln, die Ergebnisse müssen auch angemessen präsentiert und kommuniziert werden. Darüber hinaus sehen wir in den letzten Jahren, dass sich Data Scientists zunehmend mit sozialen Aspekten der Verwendung ihrer Arbeit auseinandersetzen müssen. Insbesondere wenn es sich um personenbezogene Daten handelt, hat die Einführung der Datenschutzgrundverordnung (DSGVO) neue Maßstäbe gesetzt. Aber auch bei anderen Datenquellen sind rechtliche Aspekte nicht zu vernachlässigen, beispielsweise das Urheberrecht oder Firmengeheimnisse (siehe Kapitel 22, *Sicherheit und Datenschutz*).

Abbildung 1-3 gibt einen Überblick über die vier Bereiche und zeigt auch noch einmal zusätzliche Schnittstellen zwischen diesen auf. So können wir beispielsweise die klassische (empirische) Forschung an der Schnittstelle von Statistik und Fachwissen verorten. Klassische Unternehmensberatung findet häufig an der Schnittstelle von sozialer Dimension und fachlicher Expertise statt, insbesondere in Hinblick auf betriebliche Abläufe. Fragen der Nutzerfreundlichkeit (*Usability*), aber auch des Datenschutzes lassen sich insbesondere zwischen Programmierung und sozialer Dimension verorten. Und die Entwicklung von Machine-Learning-Algorithmen erfordert sowohl fundiertes mathematisches Wissen als auch Programmiererfahrung. Entsprechend werden wir bei einer genaueren Betrachtung dessen, was Data Science eigentlich ist, auch immer wieder Aspekte dieser verschiedenen Schnittstellen finden. Wie schon gesagt, Data Science ist eine interdisziplinäre Wissenschaft, und entsprechend gibt es viele angrenzende Bereiche, von denen wir gute Theorien und bewährte Tools übernehmen können.

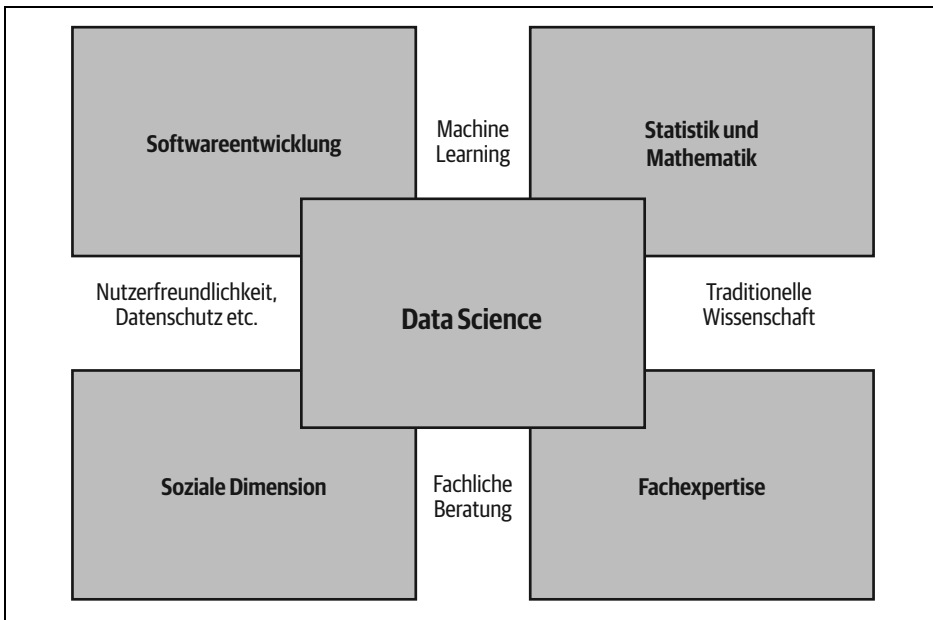


Abbildung 1-3: Data Science als interdisziplinäre Wissenschaft



<b>Einleitung: Ein Handbuch zum Management von Data Science</b> . . . . .	<b>13</b>
<hr/>	
<b>Teil I: Data-Science-Grundlagen</b> . . . . .	<b>27</b>
<b>1 Eine Einführung in Data Science aus Projektsicht</b> . . . . .	<b>29</b>
Verlauf eines Data-Science-Projekts (Prozessmodell) . . . . .	30
Von einfachen Analysen zur Automatisierung (Analytics Continuum) . .	32
Welche Kompetenzen brauchen wir in einem Data-Science-Projekt? . . .	34
<b>2 Wie wir über Daten sprechen</b> . . . . .	<b>37</b>
Strukturierte Daten . . . . .	37
Semistrukturierte Daten . . . . .	38
Unstrukturierte Daten . . . . .	40
Skalenniveaus und besondere Datenformate . . . . .	40
Verschiedene Aspekte der Qualität von Daten . . . . .	42
Big Data und Smart Data . . . . .	43
<b>3 Datenbeschaffung und -aufbereitung</b> . . . . .	<b>45</b>
Datenquellen und Datenerhebung . . . . .	45
Datenzugriff ist nicht nur eine technische Angelegenheit . . . . .	46
Integration und Aufbereitung verschiedener Datenquellen . . . . .	47
Trainings- und Testdaten für das Training von Machine-Learning- Algorithmen . . . . .	48
Feature Engineering . . . . .	48
<b>4 Deskriptive Analysen</b> . . . . .	<b>51</b>
Univariate Basisstatistiken und Kennzahlen . . . . .	51
Bivariate Darstellungen und Korrelationen . . . . .	53
Visualisierung von Daten . . . . .	55
Explorative Datenanalyse (EDA) . . . . .	58

<b>5</b>	<b>Modellbildung in der klassischen Statistik</b>	<b>61</b>
	Grundgesamtheiten und Stichproben	61
	Die Regressionsanalyse als Beispiel für ein erklärendes Modell	63
	Wie funktioniert eine Regressionsanalyse aus mathematischer Sicht? ...	64
	Die Flexibilität der Regressionsanalyse	65
	Spezielle Anwendungsfälle: Zeitreihenanalyse und Vorhersagen	67
<b>6</b>	<b>Vorhersagen im Machine Learning</b>	<b>71</b>
	Supervised Learning	73
	Regressionsanalyse	73
	Entscheidungsbäume	74
	K-Nearest-Neighbors	74
	Datenqualität und verwandte Herausforderungen	75
	Unsupervised Learning	77
	Dimensionsreduktion	77
	Clusteranalyse	77
	Deep Learning, Reinforcement Learning und neuronale Netze	78
	Predictive, Prescriptive, Automation	80
<b>7</b>	<b>Aufbereitung der Ergebnisse für die weitere Verwendung</b>	<b>81</b>
	Dokumentation, Wiederverwendung und Replizierbarkeit	81
	Reporting	83
	Statischer Report	83
	Dashboards	84
	Storytelling und visuelle Kommunikation mit Daten	85
	Mehrwert von Daten im Unternehmen	86
	Impact, Evaluation und Feedback	86
<b>8</b>	<b>Aspekte einer Basisinfrastruktur</b>	<b>89</b>
	Datenformate und Datenbanken	89
	Plain Text	90
	Binary Files	91
	SQL-Datenbanken	91
	NoSQL	91
	Datenverarbeitung und Analyse	91
	Collaboration und Arbeit in der Cloud	92
<b>9</b>	<b>Hands-on: Beispielprojekt</b>	<b>95</b>
	Studiendesign	95
	Datenbeschaffung und -aufbereitung	96
	Analyse der Daten	98
	Dokumentation und Reporting	99
	Handlungsempfehlung (Impact)	100

<b>Teil II: Data-Science-Management</b>	<b>101</b>
<b>10 Fallstricke für Data-Science-Projekte</b>	<b>105</b>
Fallstricke in Technologie und Infrastruktur	105
Data Engineering wird unterschätzt	106
Datensilos	106
Fallstricke in der Modellierung	107
Zu komplexe Modelle	107
Fluch der Dimensionalität	108
Ausreißer	109
Fallstricke im Management	110
Law of Instrument	110
Zu viel, zu früh	111
Unklare Ziele	111
Ein Projekt ist keine produktive Anwendung	112
Fehlende Skills und Data-Science-Kultur	112
<b>11 Grundlagen des Projektmanagements</b>	<b>115</b>
Klassisches Anforderungsmanagement	117
Agiles Management und Lean Mindset	120
Mehrwert und Kundenzentrierung	121
Kollaboration	121
Iteratives und inkrementelles Vorgehen	122
Kontinuierliche Verbesserung	122
Dezentralität und Selbstorganisation	123
PoC und MVP	123
Agiles Mindset	124
Erkenntnisse aus der agilen Praxis	124
Agiles Anforderungsmanagement	125
Zeit- und Ressourcenmanagement	127
Finanzielle Ressourcen	128
Zeitliche Ressourcen	129
Infrastrukturelle Ressourcen	132
Daten	133
Kontextualisierung und Kommunikation	134
Team-Bubble	135
<b>12 Data-Science-Teams</b>	<b>137</b>
Funktionen von Teams	137
Teamstrukturen	140
Team of Teams und New Work	143
Verortung von Data-Science-Teams	145

Rollen und deren Aufgaben in Data-Science-Teams .....	147
Rollenverständnis nach methodischer Tiefe .....	147
Rollenverständnis nach Ausbildung und Interessen .....	148
Rollenverständnis nach Aufgaben .....	149
Rollen von Data Scientists .....	150
Data Scientists .....	151
Data Engineers .....	151
Fachexpertinnen und -experten .....	151
Software Engineers und DevOps Engineers .....	152
Machine Learning Engineers und MLOps Architects .....	152
Model-Risk-Managerinnen und -Managern .....	153
Softwarearchitektinnen und -architekten .....	153
Analystinnen und Analysten .....	154
Herausforderungen und Konflikte in Teams .....	155
Digitales Arbeiten und Remote Work .....	155
Zusammenarbeit und Kommunikation .....	156
<b>13 Data-Science-Managerinnen und -Manager .....</b>	<b>159</b>
Aufgaben und Fähigkeiten .....	161
Modernes Leadership .....	164
Servant Leadership .....	164
Agile Leadership .....	165
Shared Leadership .....	167
Impact durch Leadership .....	168
Coaching und Mentoring von Data Scientists .....	171
<b>14 Hands-on: Empfohlenes Toolkit für das Data-Science-Management .....</b>	<b>175</b>
Scrum .....	175
Kanban .....	177
Scrum oder Kanban nutzen? .....	178
Team Health Checks .....	179
AI Project Canvas .....	181
Checkliste Anforderungsmanagement .....	182
Problemfelder benennen .....	182
Herausforderungen ermitteln .....	183
Mehrwert beschreiben .....	183

<b>Teil III: Infrastruktur und Architektur</b> .....	<b>185</b>
<b>15 Automatisierung und Operationalisierung im kybernetischen Regelkreis</b> . . . .	<b>187</b>
Das wissenschaftliche Vorgehen: Wissen iterativ weiterentwickeln und vertiefen .....	188
Proof-of-Concept-Projekte und Design Thinking .....	188
Operationalisierung und Evaluation von Zielen in laufenden Projekten .....	189
Der kybernetische Regelkreis .....	190
Cross Industry Standard Process for Data Mining (CRISP-DM) .....	192
<b>16 Grundlagen der IT-Infrastruktur</b> .....	<b>193</b>
Bausteine einer Softwareanwendung .....	193
Hardware: eigene Rechner vs. Cloud .....	196
Container und Microservices .....	199
Platform-as-a-Service (PaaS) und Serverless .....	200
Software- und Data-Science-as-a-Service (SaaS/DSaaS) .....	201
<b>17 Data-Science-Architekturen</b> .....	<b>203</b>
Data Lake .....	204
Data Warehouse (DWH) .....	205
Weitere Optionen wie das Analytics Lab .....	207
Interaktive Visualisierung, EDA und Business Intelligence .....	208
Data Mesh .....	209
<b>18 DevOps und MLOps: Entwicklung und Betrieb</b> .....	<b>211</b>
Versionierung und Versionskontrolle .....	211
Continuous Integration and Delivery .....	213
Microservices und Application Programming Interfaces (APIs) .....	215
Testing und Monitoring .....	217
Betrieb von Machine-Learning-Modellen (DevOps und MLOps) .....	219
<b>19 Hands-on: Modellierung von Software und Infrastruktur</b> .....	<b>221</b>
Bestandsaufnahme im Event-Storming .....	221
Weiterentwicklung in der Business Process Model and Notation (BPMN) .....	223
Modellierung einer technischen Infrastruktur .....	224
Modellierung einer (relationalen) Datenbank .....	225
Regelkonformität .....	226

<b>Teil IV: Data Science Governance und Data-driven Culture</b>	<b>227</b>
<b>20 Digitale Transformation der Unternehmen</b>	<b>231</b>
Strategischer Einsatz von Daten	232
Wettbewerbsvorteile durch Data Science	236
As-a-Service-Modelle	239
<b>21 Implementierung im Unternehmen</b>	<b>241</b>
Schritt 1: Ideenfindung	241
Wie findet man geeignete Anwendungsfälle?	241
Schritt 2: Proof-of-Concept	242
Schritt 3: Technische Implementierung	243
Schritt 4: Implementierung auf Bereichsebene	243
Schritt 5: Skalierung auf Unternehmensebene	244
Schritt 6: Verstetigung	245
Change Management	245
Datenmanagement	249
IT-Management	253
<b>22 Sicherheit und Datenschutz</b>	<b>255</b>
Safety	256
Security	257
Governance, Compliance und rechtliche Aspekte	261
Ethische Aspekte und Corporate Responsibility	263
Digitalpolitik	266
<b>23 Digitale Kompetenzen und Data-Science-Kultur</b>	<b>269</b>
New Work	270
Flexibilisierung der Arbeitsorganisation	273
Diversität und Kreativität	274
Netzwerkorganisationen und Leadership	274
Achtsamkeit und Gesundheit	274
Recruiting	275
Upskilling und Reskilling	278
Entrepreneurship, Intrapreneurship und Innovation	280
Literacy, Enablement und Citizen Data Science	282
Grundpfeiler einer kreativen Umgebung	284
<b>24 Hands-on: Toolkit für Strategie und Governance</b>	<b>287</b>
Business Model Canvas	287
AI Canvas	288
Datenstrategie-Designkit	290

<b>25 Schlüsselfaktoren für erfolgreiches Data-Science-Management</b>	<b>293</b>
Data Scientists als Individuen	293
Wirtschaftlichkeit	294
Governance	294
Kultur	294
Infrastruktur	295
Projekte und Teams	296
Wirtschaftlichkeit	296
Governance	296
Kultur	297
Infrastruktur	298
Unternehmen und Strategie	298
Wirtschaftlichkeit	298
Governance	299
Kultur	299
Infrastruktur	300
<b>Index</b>	<b>301</b>