FH Vorarlberg
University of Applied Sciences

Behavioral Economics und Business Analytics

Einfluss von kognitionspsychologischen Phänomenen des Verhaltens in der Business Analytics

Masterarbeit
zur Erlangung des akademischen Grades

Master of Arts

Fachhochschule Vorarlberg
Business Process Management

Betreut von
Prof. (FH) Gunther Rothfuss, MSc

Vorgelegt von
Alejandra Zapata Patiño

Dornbirn, 28.07.2021

Kurzreferat

Behavioral Economics und Business Analytics – Einfluss von kognitionspsychologischen Phänomenen des Verhaltens in der Business Analytics.

Die schnelllebige und sich verändernde Welt, in der die Menschen gegenwärtig leben, stellt Unternehmen ständig vor neue Herausforderungen. Der Wettbewerb wird immer anspruchsvoller und das Hervorstechen in jeder Branche ist von zahlreichen Faktoren abhängig. Einer davon, der zweifellos einen der grundlegenden Schlüssel zum Erfolg darstellt, ist die Entscheidungsfindung. Um letztere zu unterstützen, werden verschiedene Systeme geschaffen. Unter diesen Systemen lassen sich Business-Analytics-Systeme finden, deren Aufgabe sich auf die Umwandlung von Daten in Informationen konzentriert, um Evidenzen zu schaffen, die es den Managern ermöglicht, Entscheidungen auf der Grundlage von Daten – und nicht auf derjenigen von Intuition – zu treffen. Es ist jedoch Folgendes festzustellen: Obwohl diese Systeme immer besser werden, ist die Mehrheit der Manager in vielen Unternehmen nicht in der Lage, effektive Entscheidungen zu treffen.

Daher ist es das Ziel dieser Arbeit, den Personen in der Wirtschaftswelt eine Untersuchung und Analyse der kognitiven verhaltenspsychologischen Phänomene zur Verfügung zu stellen, um festzulegen, welche dieser Phänomene beim Treffen von Entscheidungen im Rahmen von Business Analytics auftreten und ein Problem verursachen können. Dazu wird die folgende Forschungsfrage gestellt: **Welchen Einfluss haben die kognitionspsychologischen Phänomene des Verhaltens in der Business Analytics?**

Um diese zu beantworten, ist eine systematische Literaturrecherche durchgeführt worden. Die Analyse der Phänomene anhand eines Data-Mining-Vorgehensmodells (CRISP-DM) zeigte, dass der Einfluss der Phänomene auf Business Analytics signifikant ist und sich auf mehrere Aspekte der Analytik bezieht.

Schlagwörter: Business Analytics, Business Intelligence, Decision Support Systems, Data Mining, Data-driven, Evidenzen, Verhaltensökonomik, Management-Entscheidungen, Heuristik, Verzerrungen, Kognition, Intuition.

Abstract

Behavioral Economics and Business Analytics – Influence of Cognitive Psychological Phenomena of Behavior on Business Analytics.

The dynamic and ever-changing world we live in today confronts companies with ever-new challenges. Competition is becoming increasingly demanding, and the ability to compete in an industry depends on numerous factors. One of them, which is certainly one of the fundamental keys to success, is decision-making. Various systems are being created to support this decision-making. Among these systems are business analytic systems, whose purpose is to turn data into information to provide insight that enable managers to make decisions based on data rather than intuition. However, it is noted that while these systems are getting increasingly better, most managers in many companies are not capable of making good decisions.

For this reason, the objective of this thesis is to provide business professionals with a study and analysis of cognitive behavioral psychological phenomena in order to determine which of these phenomena occur in business analytics decision-making and may cause a problem. To this end, the following research question is posed: **What is the influence of the cognitive psychological phenomena of behavior on business analytics?**

To answer the research question, a systematic literature review was conducted. The analysis of the phenomena based on a data-mining methodology (CRISP-DM) has shown that the impact of the phenomena on business analytics is significant and relates to various analytical aspects.

Keywords: Business Analytics, Business Intelligence, Decision Support Systems, Data mining, Data-driven, Evidence, Behavioral Economics, Management Decisions, Heuristics, Biases, Cognition, Intuition.

Inhaltsverzeichnis

Tabellenverzeichnis ..... **VIII**

Abbildungsverzeichnis ..... **IX**

Abkürzungsverzeichnis ..... **X**

1. Einleitung **1**

1.1 Ausgangslage und Relevanz der Themenwahl 1

1.2 Ziel der Masterarbeit 3

1.3 Forschungsfrage 3

1.4 Adressaten 3

1.5 Methodik 3

2. Business Analytics **5**

2.1 Business Analytics – Definition 5

2.1.1 Business Intelligence (BI) 5

2.1.2 Business Analytics (BA) 7

2.1.3 Unterschiede und Gemeinsamkeiten zwischen BI und BA 9

2.2 Data Mining (DM), Künstliche Intelligenz (KI) und Maschinelles Lernen (ML) 11

2.3 Netflix: ein Unternehmen, welches auf Datenanalytik basiert 13

2.4 Risiken von BA 14

2.5 BA und Entscheidungsfindung in Unternehmen 15

3. Kognitionspsychologische Phänomene **17**

3.1 Kognitionspsychologische Phänomene – Begriffserklärung 17

3.1.1 Kognitionspsychologische Phänomene – Entstehung 17

3.1.2 Kritik an der Verhaltensökonomie 18

3.1.3 Wiederbelebung der Verhaltensökonomie und Entdeckung der wichtigsten kognitionspsychologischen Phänomene 19

3.2 Problematik von kognitionspsychologischen Phänomenen 22

3.3 Kognitionspsychologische Phänomene und Entscheidungen 23

3.4 Kognitionspsychologische Phänomene, die den Entscheidungsprozess beeinflussen 26

3.5 Einfluss der kognitionspsychologischen Phänomene bei der BA 28

4. Analyse des Einflusses von kognitionspsychologischen Phänomenen anhand des Cross-Industry-Standard-Process-for-Data-Mining (CRISP-DM)-Vorgehensmodells **29**

4.1 Business Understanding Phase 30
4.1.1 Determine Business Objectives 31
4.1.2 Assess Situation 33
4.1.3 Determine Data Mining Goals 35
4.1.4 Produce Project Plan 36
4.1.5 Darstellung der Phänomene bei der Business Understanding Phase 37
4.2 Data Understanding Phase 39
4.2.1 Collect Initial Data 40
4.2.2 Describe Data 41
4.2.3 Explore Data 42
4.2.4 Verify Data Quality 43
4.2.5 Darstellung der Phänomene bei der Data Understanding Phase 44
4.3 Data Preparation Phase 45
4.3.1 Select Data 46
4.3.2 Clean Data 47
4.3.3 Construct Data 48
4.3.4 Integrate Data 48
4.3.5 Format Data 49
4.3.6 Darstellung der Phänomene bei der Data Preparation Phase 49
4.4 Modeling Phase 50
4.4.1 Select modeling technique 51
4.4.2 Generate test design 52
4.4.3 Build Analysis Model 53
4.4.4 Asses Analysis Model 54
4.4.5 Darstellung der Phänomene bei der Modeling Phase 55
4.5 Evaluation Phase 55
4.5.1 Evaluate results 56
4.5.2 Review process 58
4.5.3 Determine next steps 58
4.5.4 Darstellung der Phänomene bei der Evaluation Phase 59
4.6 Deployment Phase 60
4.6.1 Plan deployment 60
4.6.2 Plan monitoring and maintenance 61
4.6.3 Produce final report 62
4.6.4 Review project 63
4.6.5 Darstellung der Phänomene bei der Deployment Phase 64

4.7 Ergebnisse der Analyse 65

5. Reflexion und Diskurs 71

5.1 Beantwortung der Forschungsfragen 71

5.2 Wichtige Argumente 72

5.3 Forschungserkenntnisse und kritische Reflexion der Arbeit 73

5.4 Ausblick und offene Punkte 73

Literaturverzeichnis 75

Anhang 83

Eidesstattliche Erklärung 84

Tabellenverzeichnis

Tabelle 1: Phänomene bei der Aufgabe Determine Business Objectives. 32
Tabelle 2: Phänomene bei der Aufgabe Assess Situation. 34
Tabelle 3: Phänomene bei der Aufgabe Determine Data Mining Goals. 35
Tabelle 4: Phänomene bei der Aufgabe Produce Project Plan. 36
Tabelle 5: Phänomene bei der Erstellung von Berichten. 40
Tabelle 6: Phänomene bei der Aufgabe Collect Initial Data. 41
Tabelle 7: Phänomene bei der Aufgabe Describe Data. 42
Tabelle 8: Phänomene bei der Aufgabe Explore Data. 42
Tabelle 9: Phänomene bei der Aufgabe Verify Data Quality. 43
Tabelle 10: Phänomene bei der Aufgabe Select Data. 47
Tabelle 11: Phänomene bei der Aufgabe Clean Data. 47
Tabelle 12: Phänomene bei der Aufgabe Construct Data. 48
Tabelle 13: Phänomene bei der Aufgabe Integrate Data. 49
Tabelle 14: Phänomene bei der Aufgabe Format Data. 49
Tabelle 15: Phänomene bei der Aufgabe Select modeling technique. 52
Tabelle 16: Phänomene bei der Aufgabe Generate test design. 53
Tabelle 17: Phänomene bei der Aufgabe Build Analysis Model. 53
Tabelle 18: Phänomene bei der Aufgabe Asses Analysis Model. 54
Tabelle 19: Phänomene bei der Aufgabe Evaluate results. 57
Tabelle 20: Phänomene bei der Aufgabe Review process. 58
Tabelle 21: Phänomene bei der Aufgabe Determine next steps. 59
Tabelle 22: Phänomene bei der Aufgabe Plan deployment. 61
Tabelle 23: Phänomene bei der Aufgabe Plan monitoring and maintenance. 61
Tabelle 24: Phänomene bei der Aufgabe Produce final report. 62
Tabelle 25: Phänomene bei der Aufgabe Review project. 63

Abbildungsverzeichnis

Abbildung 1: Technologische BIA-Landschaft. In Anlehnung an Baars & Kemper (2015) ... 10

Abbildung 2: Schema menschlichen Erlebens ... 25

Abbildung 3: The Cognitive Bias Codex. ... 27

Abbildung 4: Traditionelle Datenanalyse und Data-Mining-Konzepte. ... 28

Abbildung 5: CRISP-DM Prozess. In Anlehnung an Chapman et al. (2000) ... 30

Abbildung 6: CRISP-DM Business Understanding Phase. ... 31

Abbildung 7: Kognitionspsychologische Phänomene bei der Business Understanding Phase. ... 38

Abbildung 8: CRISP-DM Data Understanding Phase. ... 39

Abbildung 9: Kognitionspsychologische Phänomene bei der Data Understanding Phase. ... 44

Abbildung 10: CRISP-DM Data Preparation Phase. ... 46

Abbildung 11: Kognitionspsychologische Phänomene bei der Data Preparation Phase. . 50

Abbildung 12: CRISP-DM Modeling Phase. ... 51

Abbildung 13: Kognitionspsychologische Phänomene bei der Modelling Phase. ... 55

Abbildung 14: CRISP-DM Evaluation Phase. ... 56

Abbildung 15: Kognitionspsychologische Phänomene bei der Evaluation Phase. ... 59

Abbildung 16: CRISP-DM Deployment Phase. ... 60

Abbildung 17: Kognitionspsychologische Phänomene bei der Deployment Phase. ... 64

Abbildung 18: Kognitionspsychologische Phänomene bei dem CRIPS-DM-Vorgehensmodell ... 65

Abbildung 19: Summe der kognitionspsychologischen Phänomene bei dem CRIPS-DM ... 67

Abbildung 20: Zusammenfassung der Kategorie „Too Much Information“. ... 68

Abbildung 21: Zusammenfassung der Kategorie „Not Enough Meaning“. ... 69

Abbildung 22: Zusammenfassung der Kategorie „Need To Act Fast“. ... 70

Abbildung 23: Zusammenfassung der Kategorie „What Should We Remember?“. ... 71

Abkürzungsverzeichnis

BIA.....Business Intelligence & Analytics

BI.....Business Intelligence

BA.....Business Analytics

CRISP.....Cross-Industry Standard Process for Data Mining

CBR.....Case-based Reasoning

CIO.....Chief Information Officer

CEO.....Chief Executive Officer

DW.....Data Warehouse

DM.....Data Mining

DSS.....Decision Support System

ETL.....Extract, Transform, Load

ERP.....Enterprise Resource Planning

EIS.....Executive Information System

GDSS.....Group Decision Support System

KI.....Künstliche Intelligenz

MSS.....Management Support System

ML.....Maschinelles Lernen

ODSS.....Organizational Decision Support System

OLAP..... Online Analytical Processing

1. Einleitung

1.1 Ausgangslage und Relevanz der Themenwahl

Das menschliche Verhalten in der Wirtschaft wurde in der Vergangenheit durch das neoklassische Modell des Homo oeconomicus geprägt, welches die Idee verteidigt, dass der Wirtschaftsmensch ein rationales Wesen ist, das nutzenmaximierende Entscheidungen trifft.[1]

Dieses Modell geht davon aus, dass die Informationen, auf deren Grundlage Entscheidungen getroffen werden, perfekt und jederzeit zugänglich sind, was zu unbegrenzter Rationalität führt. Dementsprechend basieren diese Entscheidungen auf einer Kosten-Nutzen-Analyse, durch die der individuelle Nutzen maximiert wird. Dieses Modell, zusammen mit der Theorie der rationalen Entscheidung, entsprach lange Zeit der gängigen Meinung, wird aber inzwischen stark kritisiert.[2]

Mehrere bekannte Wissenschaftler haben sich zunächst darauf konzentriert, die Grenzen sowie die Widersprüche der bestehenden Theorien aufzuzeigen und dann alternative Modelle auf der Grundlage der kognitiven Psychologie zu entwerfen.[3] Herbert Simon schlug vor, die realen Informationsverarbeitungs- und Rechenfähigkeiten des Menschen zu analysieren, um diese als objektiven Ausgangspunkt für die Untersuchung des menschlichen Verhaltens in ökonomischen Modellen betrachten zu können. Die Erkenntnis von kognitiven Grenzen, die jedem Individuum bei Entscheidungen im täglichen Leben gesetzt sind, führte zur Entstehung des Begriffs der begrenzten Rationalität. Diesem Begriff liegt die Auffassung zugrunde, dass Rationalität nicht nur durch die kognitiven Grenzen des Menschen, sondern auch durch die für jede Entscheidung zur Verfügung stehende Zeit begrenzt ist. Aus diesem Grund strebt der Mensch nicht nach einer optimalen Entscheidung, sondern nach einer befriedigenden Lösung, die seine Kriterien der Adäquanz erfüllt.[4]

Diese und viele andere Untersuchungen in Bereichen wie Verhaltensökonomie, Psychologie und Neurowissenschaften bereiteten den Weg für Autoren wie Amos Tversky und Daniel Kahneman. Diese Wissenschaftler haben sich folglich intensiv mit den Problemen und Hürden der Entscheidungsfindung auseinandergesetzt. Als Ergebnis konnten sie durch die Prospect-Theory nachweisen, dass der Mensch nicht nach Gewinnmaximierung, sondern nach Verlustvermeidung strebt. Darüber hinaus gelang es ihnen ebenfalls, durch diese Theorie eine Reihe von Anomalien zu erklären, die den Menschen bei der Entscheidungsfindung widerfahren. Somit wurden Heuristiken und kognitive Verzerrungen zu den bedeutendsten Themen für die zukünftigen Forschungen dieser beiden Autoren.[5]

---

[1] Vgl. Masao; Tanaka 2017, S. 4–5.
[2] Vgl. Pompian 2012, S. 25–26.
[3] Vgl. DellaVigna 2009, S. 315–316.
[4] Vgl. Simon 1993, S. 156–160.
[5] Vgl. Kahneman; Tversky 1979, S. 274.

Heuristiken sind Vereinfachungsstrategien, die u. a. bei Entscheidungsprozessen unbewusst angewendet werden. Sie führen somit zu zufriedenstellenden und ressourcenschonenden Lösungen. Im Fall, dass Heuristik fehlerhafte Entscheidungen hervorruft, wird dieses Phänomen in der Literatur als kognitive Verzerrungen bezeichnet. Letztere sind psychologische Effekte, die eine fehlerhafte Interpretation oder Wahrnehmung der Realität erzeugen. Sie führen dazu, dass Entscheidungen getroffen werden, die nicht auf entsprechenden Evidenzen basieren.[6]

Gegenwärtig werden Entscheidungen mit der Unterstützung von Business Analytics und Business Intelligence getroffen. Diese sind auf Daten und/oder Algorithmen basierende Prozesse, die sich auf die Extrahierung von Evidenzen konzentrieren, mit dem Ziel, Geschäftsprobleme zu lösen und Geschäftsentscheidungen zu verbessern.[7]

Obwohl die Datenanalysen maschinell erzeugt sind, können diese dennoch von kognitiven Verzerrungen beeinflusst werden, da Ergebnisse bereits im Voraus mithilfe von Heuristiken antizipiert werden (sog. Bauchgefühl). Diese kognitiven Verzerrungen bei der Durchführung einer Geschäftsanalyse können zu ungewünschten Situationen führen. Ein Beispiel dafür wäre folgendes: Ein Manager will sein Team davon überzeugen, dass ein neues Produkt zu einem größeren Profit führen wird. Um diese Aussage zu unterstützen, sucht er unbewusst nach Beispielen von Unternehmensdaten, die mit der Einführung ähnlicher Produkte großen Erfolg erzielen konnten. Demnach neigt er zu Bestätigungsverzerrung, da der Mensch von Natur aus versucht, Informationen zu beschaffen, die seine bestehenden Überzeugungen bestätigen, und verzichtet darauf, nach Daten zu suchen, welche diesen widerstehen. In diesem Beispiel ignoriert der Manager Informationen über die ähnlichen Produkte, die bei der Einführung gescheitert sind.[8]

Eine weitere sehr verbreitete kognitive Verzerrung im Bereich der Datenanalyse ist die Automatisierungsbias. Damit ist die Tendenz gemeint, sich stark auf automatisierte Systeme zu verlassen. Letztere werden meist von Menschen programmiert und können ungültige oder falsche Informationen abliefern.[9] Dies zeigt sich vor allem bei der künstlichen Intelligenz, welche u. a. zum Ziel hat, bei komplexen Entscheidungsprozessen zu helfen. In diesem Kontext ist die Frage zu stellen, ob es sinnvoll ist, die gesamte Verantwortung an diesen Algorithmen zu übergeben und die Entscheidungen somit auf reiner Computer-Basis zu treffen.[10]

Diese und viele andere Verzerrungen, zu denen die Mitarbeiter von Unternehmen stetig neigen, wirken sich erheblich auf die Entscheidungen aus. Aus diesem Grund ist es für die Unternehmenseffizienz wichtig, diese Verzerrungen zu kennen sowie zu überwinden, um sicherzustellen, dass die getroffenen Entscheidungen vollständig auf Evidenz und gültigen Informationen basieren.[11]

---

[6] Vgl. Nermend 2017, S. 37.
[7] Vgl. Ereth; Kemper 2016, S. 459.
[8] Vgl. Costa u. a. 2017, S. 1776–1777.
[9] Vgl. Skitka; Mosier; Burdick 1999, S. 991–992.
[10] Vgl. Seiter 2017, S. 21–22.
[11] Vgl. Niebler; Lindner 2019, S. 8.

1.2 Ziel der Masterarbeit

Die Ziele dieser Masterarbeit sind die Untersuchung und die Analyse von kognitionspsychologischen Phänomenen des Verhaltens, um herauszufinden, welche dieser Phänomene Probleme beim Treffen von Entscheidungen im Rahmen der Business Analytics verursachen und warum dies der Fall ist. Diese Masterarbeit stellt einen Mehrwert für die Literatur dar, weil es bisher keine Abhandlung zum Thema gibt, die einzelne kognitionspsychologische Verhaltensphänomene im Kontext der Business Analytics betrachtet sowie die damit verbundenen Problematiken und Einflüsse in diesem Bereich identifiziert. Der Schwerpunkt dieser Arbeit liegt auf der Verhaltensökonomie, jedoch bietet die Gegenüberstellung dieser Informationen mit der Business Analytics dem Leser eine interessante und informationsreiche Abhandlung, die es ihm ermöglicht, Kenntnisse in diesen beiden Bereichen zu erwerben.

1.3 Forschungsfrage

Diese Masterarbeit beschäftigt sich mit der folgenden Fragestellung: Welchen Einfluss haben die kognitionspsychologischen Phänomene des Verhaltens in der Business Analytics?

1.4 Adressaten

Diese Masterarbeit richtet sich an Studenten und Personen aus der betriebswirtschaftlichen Welt, die Vorkenntnisse oder Erfahrungen im Bereich Data Analytics vorweisen können und sich für den Zusammenhang zwischen Business Analytics und kognitiven Phänomenen zum Zeitpunkt der Entscheidungsfindung interessieren. Um diese Arbeit vollständig zu verstehen, ist das Beherrschen der englischen Sprache erforderlich, da viele Begriffe und Abbildungen auf Englisch dargestellt werden. Nach der Lektüre dieser Arbeit werden die Leser in der Lage sein, einige der wichtigsten kognitionspsychologischen Phänomene zu verstehen und die damit verbundenen Auswirkungen zu erkennen sowie zu überwinden. Darüber hinaus werden die Leser auch realisieren können, welchen Einfluss diese Phänomene auf die Business Analytics haben.

1.5 Methodik

Im Kapitel 2 wird „Business Analytics (BA)“ vollständig definiert. Ebenfalls werden darin mehrere Begriffe und Ansätze von Business Intelligenz und Business Analytics erläutert. Dieses Kapitel zielt darauf ab, die Leser auf den aktuellen Forschungsstand hinsichtlich des Konzepts Business Analytics und der Entscheidungsfindung zu bringen.

Im Kapitel 3 werden die „kognitionspsychologischen Phänomene“ definiert und analysiert, indem deren Entstehung dargestellt wird. Außerdem wird jenes Kapitel auf die Problematik bezüglich dieses Phänomens eingehen.

Anschließend werden die Informationen aus diesen Kapiteln (2 und 3) analysiert sowie gegenübergestellt, um abschließend zu bewerten, ob die Phänomene ein Problem in dem Bereich Business Analytics darstellten können. Danach folgen zum Abschluss eine Zusammenfassung der Antwort auf die Fragestellung sowie eine kritische Reflexion über diese Masterarbeit.

Die vorliegende Abhandlung basiert auf einer systematischen Literaturrecherche, die in diversen Bibliotheken wie der Bibliothek der Fachhochschule Vorarlberg, der Bibliothek der Universität Liechtenstein und anderen Onlinebibliotheken durchgeführt wurde. Es wird auch in Datenbanken wie WISO, Research Gate, Web of Science, ScienceDirect und Pro Quest recherchiert. Um einen Überblick über das Thema zu verschaffen, wird als Erstes Google Scholar verwendet. Damit werden die wesentlichen Autoren der Thematik gesucht. Die verwendeten Schlagworte für diesen Zweck sind folgende: Data Analytics, Business Intelligence, Data Science, Evidence Base Decisions, Business Analytics, Intuition, Kognition, Data driven, Rationality Decisions, Cognitive Bias, Herbert Simon, Behavioral Economics usw. Nach einer qualitativen Auswertung der Quellen werden die relevantesten Hauptquellen für die Beantwortung der Fragestellung aus Monografien, Büchern und Artikeln ausgewählt und analysiert.

2. Business Analytics

2.1 Business Analytics – Definition

Die Definition von Business Analytics ist eine komplexe Aufgabe, denn dafür ist es notwendig, Kenntnisse aus verschiedenen zusammenhängenden Bereichen (IT, Management, Psychologie etc.) zu besitzen.[12] Hinzu kommt, dass die Definitionen, die in der Literatur zu finden sind, keine absoluten Wahrheiten darstellen, denn der Begriff befindet sich in ständigem Wandel.[13] Aufgrund der kontinuierlichen Entwicklung des Begriffes im Laufe der Zeit kommt es immer wieder vor, dass die Begriffe Business Intelligence und Business Analytics als Synonyme verwendet werden.[14] Deshalb werden in diesem Kapitel beide Konzepte definiert und der Zusammenhang, der zwischen den Begriffen besteht, wird erläutert.

2.1.1 Business Intelligence (BI)

Die Mehrheit von Autoren, welche über Data Science schreiben, darunter Bentley (2017) und Abbasi (2021), ist sich einig, dass der Begriff Business Intelligence (BI) im Jahr 1865 erstmals von Richard Millar Devens in der „Cyclopaedia of Commercial and Business Anecdotes“ erwähnt wurde.[15] [16] Denves (1865) verwendete den Begriff, um die Vorteile zu beschreiben, die der Bankier Sir Henry Furnese durch die Fähigkeit erreichte, die Informationen seiner Umgebung (Verständnis für politische Fragen, Instabilitäten und den Markt) zu nutzen – im Sinne einer Gewinnsteigerung gegenüber seinen Mitbewerbern.[17]

Seitdem wurde erkannt, dass die Fähigkeit, Informationen zu sammeln und dementsprechend zu handeln, eine Eigenschaft darstellt, die hervorgehoben werden muss, um auf dem Markt einen Wettbewerbsvorteil zu erzielen.[18] Diese Erkenntnis gilt noch heute und ist eine der wichtigsten Grundlagen von BI und BA.[19]

Im 20. Jahrhundert erreichte der technologische Fortschritt den Punkt, an dem die Technologie als ein Mittel der Business Intelligence betrachtet werden konnte.[20] Hans Peter Luhn, bekannt als der „Vater der Business Intelligence“, war ein IBM-Informatiker, der 1958 einen Artikel mit dem Titel „A Business Intelligence System“ veröffentlichte. In diesem beschrieb der Autor BI als ein automatisches System, das entwickelt wurde, um Informationen an die verschiedenen Abteilungen einer Organisation zu verteilen. Darüber hinaus erkannte Luhn das Potenzial von BI für Unternehmen und schaffte es, die Einsatzmöglichkeiten des Konzepts zu erweitern, indem er Methoden etablierte, auf deren

[12] Vgl. Niebler; Lindner 2019, S. 8.
[13] Vgl. Seiter 2017, S. 20.
[14] Vgl. Seiter 2017, S. 17.
[15] Vgl. Bentley 2017, S. 2.
[16] Vgl. Abbasi 2021, S. 2.
[17] Vgl. Devens 1865, S. 210.
[18] Vgl. H. Davenport 2014, S. 45–46.
[19] Vgl. Seiter 2017, S. 1.
[20] Vgl. Seiter 2017, S. 4–5.

Basis das Unternehmen IBM einige seiner wichtigsten analytischen Systeme entwickelte.[21] [22]

Das Aufkommen von Computern sowie die Möglichkeit, Daten auf Disketten und anderen Speichertechnologien zu lagern, ermöglichten von den späten 1950er bis zu den späten 1980er Jahren die Schaffung verschiedener Systeme wie Decision Support System (DSS), Management Support Systems (MSS) Executive Information Systems (EIS), Group Decision Support Systems (GDSS) und Organizational Decision Support Systems (ODSS).[23] Der Fokus lag bei allen auf der Generierung wertvoller Informationen zur Unterstützung von Managemententscheidungen. Aus der Kombination von diesen technologischen Fortschritten, Verfahren und diversen Tools konnten Unternehmen Daten in nützliche Informationen umwandeln, die eine fundierte Entscheidungsfindung ermöglichten.[24] Gartner Howard Dresner brachte im Jahr 1989 den Begriff Business Intelligence wieder in den Vordergrund und verwendete diesen als Oberbegriff für alle oben genannten Support-, Datenspeicher- und Analysesysteme.[25] [26]

Mit der Entwicklung von Data Warehouses (DW) gelang es, den Zeitaufwand für den Datenzugriff deutlich zu reduzieren. Parallel zu diesem Schritt entstanden weitere Aspekte des Data Warehousing, welche heute zu den wichtigsten Bestandteilen von BI gehören. Darunter fallen beispielweise ETL-Tools (Extract, Transform, Load) und OLAP-Software (Online Analytical Processing).[27] Die BI orientiert sich an der Vergangenheit und untersucht die Berichte der Entwicklungsgeschichte des Unternehmens, um Informationen über den Werdegang des Unternehmens zu erhalten und nachvollziehen zu können, wie dieser verlief.[28]

Im Hinblick auf eine konkrete Definition des Begriffs beschreibt Bentley (2017) BI als eine Reihe von Techniken und Werkzeugen, die es dem Unternehmen ermöglichen, wertvolle und relevante Informationen durch die Sammlung und Transformation von Rohdaten zu gewinnen.[29] All dies ermöglicht es den Unternehmen, Wettbewerbsvorteile gegenüber ihren Konkurrenten zu erlangen. Darüber hinaus argumentiert Bentley, dass BI zur Unterstützung von Geschäftsentscheidungen sowohl operativ (Preisgestaltung/Positionierung eines Produkts) als auch strategisch (Prioritäten/Ziele) eingesetzt werden kann.[30]

Durch BI-Technologien gelingt es, eine große Menge an Daten zu verarbeiten, sowohl strukturierte als auch unstrukturierte.[31] Der Zweck von BI besteht darin, eine einfache und angemessene Interpretation dieser Daten zu ermöglichen, so dass Unternehmen aus dieser Interpretation heraus neue Chancen erkennen sowie gleichzeitig effektive Strategien auf der Grundlage von Daten umsetzen können.[32] [33]

---

[21] Vgl. Gluchowski; Chamoni 2016, S. 16–18.
[22] Vgl. Luhn 1958, S. 314–315.
[23] Vgl. Weber 2020, S. 2–4.
[24] Vgl. Baars; Kemper 2021, S. 2.
[25] Vgl. Elena; University 2011, S. 2.
[26] Vgl. Gluchowski; Chamoni 2016, S. 20–21.
[27] Vgl. Schön 2016, S. 235–237.
[28] Vgl. Humm; Wietek 2005, S. 3–5.
[29] Bentley 2017, S. 1.
[30] Vgl. Bentley 2017, S. 1–2.
[31] Vgl. Weber 2020, S. 3–4.
[32] Vgl. Brijs 2016, S. 253–254.
[33] Vgl. Weber 2020, S. 74.

Daher gibt es einen wachsenden Bedarf für Unternehmen, sich ein BI-Tool anzuschaffen, da dieses Werkzeug das Mittel ist, das Unternehmen die Möglichkeit gibt, Informationen zu sammeln, zu analysieren sowie zu verbreiten.[34] Auf diese Weise haben die Manager Zugang zu handlungsrelevanten Daten (Kundenverhalten, erwartete Markttrends, Leistungskennzahlen) und können dementsprechend Entscheidungen treffen.[35] Darüber hinaus ist es mit Hilfe von BI-Anwendungen möglich, zahlreiche Aktivitäten in Unternehmen zu unterstützen, wie Data Mining, Data Warehousing, Scorecarding, Dashboarding-Finanzanalyse etc. Zu den vielfältigen Einsatzmöglichkeiten von BI gehören Bedarfsermittlung, Erkennung neuer Märkte, Messung der Wirkung von Marketingkampagnen usw.[36]

Um die Effektivität von BI zu erhöhen und tatsächlich „Intelligenz“ zu gewinnen, ist es notwendig, Daten aus internen Quellen, wie die Finanzdaten des Unternehmens, und Daten aus externen Quellen, z. B. Daten aus verschiedenen Anwendungen oder sozialen Netzwerken, zu kombinieren.[37]

Moderne BI-Lösungen ermöglichen vielfältige Zugriffsmöglichkeiten auf Daten, beginnend mit interaktiven Dashboards sowie verschiedenen Visualisierungs- und Browsing-Möglichkeiten bis zu einheitlichen zeitspezifischen und ereignisbasierten Reports.[38]

Die Aufmerksamkeit für die IT-Gesamtarchitektur wurde in den letzten Jahren durch die wachsende Bedeutung des mobilen Zugriffs auf Daten innerhalb von BI-Systemen intensiviert. Dies liegt hauptsächlich daran, dass mobile Geräte wie Tablets und Smartphones heute nicht mehr für die Führungsetage bestimmt sind, sondern überall Einzug in bestehende Geschäftsprozesse gefunden haben.[39] [40]

2.1.2 Business Analytics (BA)

Nach der Erkenntnis, dass die Analyse wesentlich zutreffender sein sollte und bis zu einem gewissen Grad Informationen über die zukünftigen Entscheidungen des Managements liefern sollte, wurde der Begriff Business Analytics (BA) in diesem Zusammenhang eingeführt.[41]

Kemper und Ereth (2016) definieren Business-Analytik als „die Anwendung mathematischer und statistischer Methoden zur Gewinnung neuer Erkenntnisse über das Geschäft“.[42] Sie argumentieren, dass BA durch die Fokussierung auf die quantitative, methodenorientierte Auswertung von Daten das Spektrum der klassischen Business-Intelligence-Analyse erweitert sowie diagnostische und prädiktive Fragestellungen schärft.[43]

[34] Vgl. Naidoo 2019, S. 4.
[35] Vgl. Hedgebeth 2007, S. 414.
[36] Vgl. Bentley 2017, S. 229.
[37] Vgl. Schön 2016, S. 341.
[38] Vgl. Dietrich u. a. 2015, S. 378.
[39] Vgl. Schön 2018, S. 448–451.
[40] Vgl. Bentley 2017, S. 12–13.
[41] Vgl. Chamoni; Gluchowski 2017, S. 9.
[42] Ereth; Kemper 2016, S. 458.
[43] Vgl. Ereth; Kemper 2016, S. 458–460.

Auf der anderen Seite verteidigt Kimbrough (2016) die Idee, dass es bei BA darum geht, Daten und Modelle zu nutzen, um die Entscheidungsprobleme von Menschen und Organisationen aller Art zu lösen oder zumindest dabei zu unterstützen.[44]

So erfolgt die „Geburt“ dieses neuen Begriffs mit einem Erfolgsversprechen für Organisationen. Die Prämisse, dass durch den Einsatz quantitativer BA-Methoden (Datenanalyse, Optimierung, Simulation, Vorhersage und andere) die Unternehmensleistung wesentlich verbessert werden könnte, führte dazu, dass BA im Laufe der Jahre sehr populär wurde.[45]

Der Schwerpunkt von BA liegt auf der Zukunft, was bedeutet, dass es die Erstellung einer Zukunftsvision auf der Grundlage von prädiktiven Entscheidungsmodellen anstrebt.[46] Deshalb ist diese Analyse viel stärker darauf ausgerichtet, verschiedene Trends zu erkennen und in der Lage zu sein, Situationen (Bedrohungen) für Unternehmen vorherzusagen – z. B. die Anwendung statistischer Algorithmen auf historische Daten, um eine Prognose für die Zukunft zu erstellen, und zwar im Hinblick auf die Leistungsfähigkeit von zukünftigen Produkten, Dienstleistungen, Logoänderungen usw.[47]

Die BA untersucht größtenteils nicht die internen Quellen, sondern sucht nach Informationen aus anderen Quellen, Trends oder makroökonomischen Informanten.[48] Dabei werden umfangreiche Daten analysiert, um Verhaltensmuster über die Gewohnheiten und Bräuche der Menschen zu extrahieren. Außerdem bietet BA die Möglichkeit, Geschäftssituationen effizient zu interpretieren und intelligente Entscheidungen zu begründen. [49]

Alle Analytics-Methoden des Unternehmens haben die Eigenschaft, dass sie durch Algorithmen in Computersystemen abgebildet werden. Dabei geht es darum, aus bestehenden Daten neue Erkenntnisse zu erhalten sowie neue Datensätze zu erzeugen.[50]

Algorithmen verdanken einen großen Teil ihrer Bedeutung der Diskussion um das Thema Big Data.[51] Bedingt durch die zunehmenden Datenmengen, welche Unternehmen zu Verfügung stehen, ist eine manuelle Auswertung dieser Datenbestände nicht mehr vorstellbar. Zudem verspricht die Auswertung dieser Daten, neue Erkenntnisse zu liefern und somit einen Mehrwert für das Unternehmen zu generieren.[52] [53] Die automatische Bereitstellung dieser Erkenntnisse durch die Verwendung von Algorithmen ist dabei eine der großen Chancen. Dazu werden neuartige Technologien und Methoden benötigt, um in der riesigen Datenmasse relevante Erkenntnisse zu gewinnen sowie zukunftsfähige Entscheidungen zu treffen.[54] Häufig genügen die Visualisierungsmethoden der Daten nicht, um entscheidungsrelevante Handlungen allein aus der Visualisierung heraus abzuleiten. Für Mustererkennungen sowie für die Ableitung von zukunftsweisenden Handlungen in

[44] Vgl. Kimbrough; Lau 2016, S. 3.
[45] Vgl. Albright; Winston 2017, S. 32.
[46] Vgl. Chamoni; Gluchowski 2017, S. 9.
[47] Vgl. Chamoni; Gluchowski 2017, S. 11–12.
[48] Vgl. Gluchowski 2016, S. 277–278.
[49] Vgl. Zhang 2017, S. 86.
[50] Vgl. Zhang 2017, S. 95.
[51] Vgl. Liang; Liu 2018, S. 9.
[52] Vgl. Weber 2020, S. 73.
[53] Vgl. Hormigo; Caralt 2014, S. 83–84.
[54] Vgl. Gluchowski 2016, S. 278.

einer vorhandenen und ständig wachsenden Datenmenge wird daher der Einsatz von Algorithmen in Zukunft immer mehr an Bedeutung gewinnen.[55]

Die Verwendung von Business-Analytics-Algorithmen kommt Unternehmen in mehrfacher Weise zugute. Diese sind in der Lage, Korrelationen und Muster in Daten zu identifizieren, Prozesse zu optimieren sowie Fehler zu reduzieren. Dadurch können manche Ereignisse in der Vergangenheit deutlicher interpretiert werden, so dass sich daraus verlässliche Zukunftsstrategien ergeben.[56] Die Szenariosimulation gewährleistet zudem die Absicherung anstehender Managemententscheidungen. Darüber hinaus ist es möglich, genaue Prognosen über zukünftige Entwicklungen zu erstellen, sowohl unternehmensweit als auch in einzelnen Unternehmensbereichen.[57]

2.1.3 Unterschiede und Gemeinsamkeiten zwischen BI und BA

An dieser Stelle drängt sich eine Reihe von Fragen auf, wie die folgenden: Geht es nicht in beiden Fällen um BI? Was macht den Begriff BA so populär? Gibt es einen relevanten Unterschied zwischen BI und BA? Hat die BA plötzlich neue quantitative Methoden erfunden, um die traditionellen Methoden der Managementwissenschaft in den Schatten zu stellen? Hier bestehen somit einige der subtilen Unterschiede, welche zwischen den beiden Begriffen zu finden sind.

Während der Schwerpunkt von BI weiterhin auf klassischen IT-Themen wie Datenintegration und Datenmanagement liegt, orientiert sich BA immer stärker an den tatsächlichen Auswertungen der Fachanwender.[58] Dabei steht die Exploration von Daten im Vordergrund. Fachanwender im Unternehmen werden gezielt bei der täglichen Arbeit unterstützt. Des Weiteren wird gefordert, dass die Anwender in der Lage sind, Probleme mit Hilfe von Werkzeugen selbstständig, ohne IT und Programmierkenntnisse, zu lösen.[59] Das ist im Grunde genommen keine Neuigkeit, denn BI-Lösungen verfügen derzeit bereits über Visualisierungs- und Explorationswerkzeuge, die sich unter dem Begriff Self-Service-BI an Fachanwender richten.[60] Die Abweichung liegt jedoch in dem Fokus auf der Erkenntnis. Während BI vor allem durch eine retrospektive Sicht auf Daten gekennzeichnet ist, ist BA an der Interpretation zukünftiger Entwicklungen interessiert.[61]

Das übergeordnete Ziel beider Ansätze ist es, Entscheidungsprozesse zu unterstützen und zu optimieren. Der wesentliche Unterschied liegt demzufolge nicht im Ziel, sondern in der Methodik bzw. Vorgehensweise und in dem Zeitraum. Aus diesem Grund ergänzen sich die beiden Disziplinen und stehen nicht im Gegensatz zueinander.[62] Damit die entwickelten Analyseansätze sinnvoll angewendet werden können, ist es notwendig, eine valide Datengrundlage sicherzustellen. Hervorzuheben ist, dass nicht die Größe der Datenmenge das entscheidende Erfolgskriterium für die Gewinnung von Erkenntnissen ist, sondern das

[55] Vgl. Chamoni; Gluchowski 2017, S. 10–12.
[56] Vgl. LaValle u. a. 2011, S. 26–27.
[57] Vgl. Dietrich u. a. 2015, S. 12–13.
[58] Vgl. Dietrich u. a. 2015, S. 10.
[59] Vgl. Weber 2020, S. 19.
[60] Vgl. Albright; Winston 2017, S. 904.
[61] Vgl. Weber 2020, S. 8–11.
[62] Vgl. Brijs 2016, S. 14.

Nutzen geeigneter Daten sowie die Auswahl der richtigen Fragen.[63] In der Abbildung 1 „Technologische BIA-Landschaft“ ist es möglich, die Integration zwischen BI und BA zu erkennen.

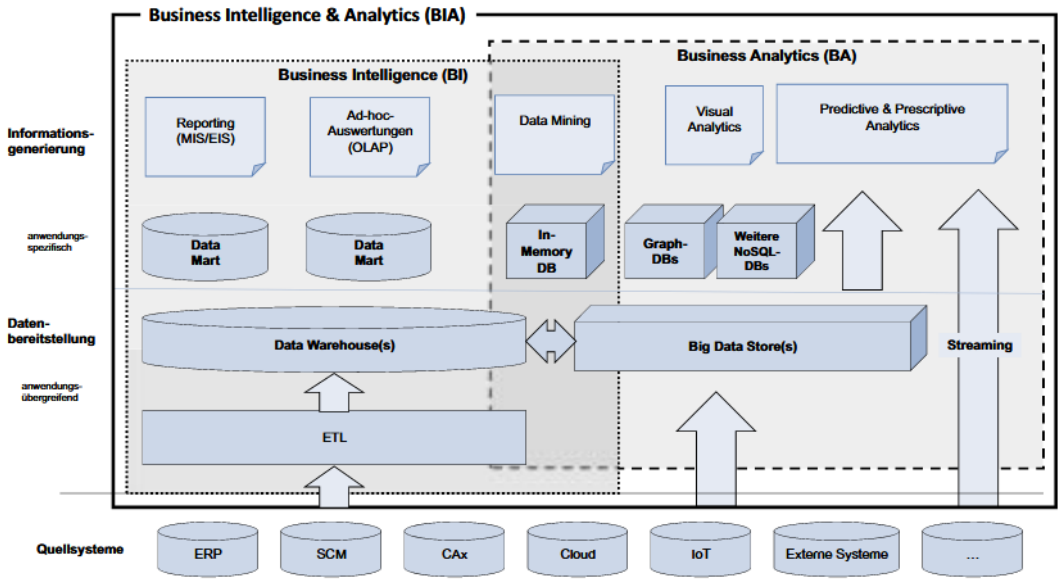

Abbildung 1: Technologische BIA-Landschaft.[64] In Anlehnung an Baars & Kemper (2015)[65]

Es ist zu erkennen, dass alles miteinander verbunden ist, allerdings handelt es sich nicht um einen einheitlichen Zusammenhang, denn aufgrund der Ausprägung der Werbung ist es nicht mehr so einfach, zwischen beiden Begriffen zu unterscheiden. Deshalb sind BI- und BA-Software zwar verbunden, jedoch nicht identisch. Das ist ungefähr so, als ob der Anwender die Antwort auf eine Frage wüsste oder als ob er wüsste, wo diese Antwort zu finden ist. Somit behebt ein Bereich das derzeitige Problem und der andere sorgt für die Lösung zukünftiger vergleichbarer Probleme.[66]

Beide Begriffe, d. h. sowohl BA als auch BI, zielen auf die Optimierung von Managemententscheidungen ab. Weiterhin ist zu beachten, dass eine Aussage über die Zukunft nicht möglich sein kann, wenn keine Kenntnis darüber besteht, was im Augenblick vor sich geht. Unabhängig davon, dass häufig gesagt wird, dass BI deskriptiv und diagnostisch ist, während BA prädiktiv und präskriptiv ist, ist eine vollständige Analyse erforderlich, damit Entscheidungen umgesetzt werden können und eine Verbesserung im Unternehmen bewirken kann.[67]

Zusammenfassend lässt sich sagen, dass sich BA- und BI-Lösungen tendenziell ergänzen. Im optimalen Fall werden beide Ansätze kombiniert, um weiterhin die klassischen Kennzahlenberichte abzubilden sowie genaue Prognosen zu treffen. Viele traditionelle Systemanbieter sind dabei, ihre neuen BI/BA-Systeme um entsprechende Algorithmen zu

[63] Vgl. Weber 2020, S. 6–8.
[64] Ereth; Kemper 2016, S. 461.
[65] Baars; Kemper 2015, S. 226.
[66] Vgl. Schniederjans; Schniederjans; Starkey 2014, S. 6.
[67] Vgl. Ereth; Kemper 2016, S. 459.

erweitern. Oft sind BI und BA inzwischen auch Bestandteil einer ERP-Lösung. Damit verschwimmen die Grenzen zwischen ERP, BI, BA und anderen Begriffen zunehmend.[68]

2.2 Data Mining (DM), Künstliche Intelligenz (KI) und Maschinelles Lernen (ML)

Data Mining (DM), Künstliche Intelligenz (KI) und Maschinelles Lernen (ML) – diese drei Begriffe stehen im Zusammenhang mit BA und gewinnen immer mehr an Aufmerksamkeit bei BA-Software-Erstellern und -Anwendern, da diese aktuell stark mit Daten und Entscheidungsfindung verbunden sind. Im Kern ist die Zielsetzung bei diesen Begriffen dieselbe – es geht darum, Wissen aus Daten zu extrahieren und dieses für den Menschen nützlich zu machen.[69]

Müller (2013) definiert DM als „das semi-automatische Aufdecken von Mustern mittels Datenanalyse-Verfahren in meist sehr großen und hochdimensionalen Datenbeständen“.[70] Um diese Muster zu entdecken, sind Methoden aus verschiedenen Wissenschaftsbereichen wie Statistik, KI (ML) und Informatik notwendig.[71]

In diesem Sinne wird unter ML der Einsatz von intelligenten Algorithmen verstanden, die solche Muster automatisch erkennen können, verbunden mit dem Ziel, dieses Wissen zur selbstständigen Lösung von Aufgaben einzusetzen.[72] Für den erfolgreichen Einsatz dieser Art von Algorithmen ist es allerdings in vielen Fällen notwendig, die Daten vorher mit statistischen Methoden zu analysieren und diese für den Algorithmus vorzubereiten.[73]

KI bezeichnet die Fähigkeit von Algorithmen, Aufgaben zu übernehmen, die bisher nur mit menschlichen Fähigkeiten gelöst werden konnten.[74] Zunehmend wird erwartet, dass die Weiterentwicklung von KI und ML zu einer Revolution der Entscheidungsfindung sowie der Wahrnehmung der Welt führen kann. Es besteht jedoch noch kein Grund zur Sorge, denn derzeit befindet sich die Entwicklung von KI noch in der Anfangsphase. Tatsächlich hat KI aufgrund der deutlich gestiegenen Rechenleistung in großen Datenzentren und den Fortschritten in der Forschung zum menschlichen Gehirn und verwandten Bereichen ein starkes Comeback erlebt. Dennoch bleibt die Herausforderung für Forscher, menschliches Verhalten vollkommen zu verstehen, existent. Dementsprechend sind zahlreiche Forschungen in den verschiedenen verwandten Disziplinen erforderlich, bis die Technik, die in Hollywood-Filmen gezeigt tatsächlich Realität wird.[75]

Durch ML verfügen Maschinen über die Fähigkeit, Daten und Informationen aus Experimenten, Interaktionen und Beobachtungen der Realität zu analysieren. Anders formuliert, ist eine Maschine in der Lage, wie ein Mensch zu lernen und zu handeln, ohne dass sie mit einer Reihe spezifischer Regeln programmiert ist, die das Verhalten vorgeben.

---

[68] Vgl. Haber u. a. 2021, S. VII–IX.
[69] Vgl. Seiter 2017, S. 21–22.
[70] Müller; Lenz 2013, S. 75.
[71] Vgl. Skilton; Hovsepian 2018, S. 121–122.
[72] Vgl. Weber 2020, S. 39.
[73] Vgl. Zhang 2017, S. 91.
[74] Vgl. Weber 2020, S. 37.
[75] Vgl. Shrestha; Ben-Menahem; von Krogh 2019, S. 66–67.

Dies wird erreicht, indem die Maschine gemäß dem verwendeten Lernparadigma agiert. Es ist möglich, im Bereich ML drei Gruppen von Paradigmen zu identifizieren.[76]

1) Überwachtes Lernen: Die Maschine hat viele Trainingsdaten, welche die zu erzielenden Ergebnisse zeigen – das sind die sogenannten gelabelte Daten. Somit kann die Maschine aus den Trainingsdaten den Ausgabewert vorhersagen.[77]

2) Unüberwachtes Lernen: In diesem Fall sind Eingabedaten vorhanden, allerdings keine Ausgabedaten. Es existiert kein Ergebnis, das zugeordnet werden kann (gelabelte Daten). Dadurch ist es möglich, in Datengruppen, die auf Ähnlichkeiten beruhen, eine Art Datenstruktur zu finden, die die Analyse synthetisiert, um Ergebnisse zu finden.[78]

3) Bestärkendes Lernen: Dieses wird mit Agenten eingesetzt, welche sich in einer Trainingsumgebung befinden und Feedback erhalten. Das Ziel ist, dass die Maschine versteht, in einer Situation autonom zu handeln, indem die Reaktion durch das Auftreten von Reizen beeinflusst wird, die eine Reaktion auslösen, die zuvor durch eine positive oder negative Verstärkung konditioniert wurde.[79]

ML ist eine sehr wertvolle Anwendung von KI. Damit lässt sich die Zeit für die Softwareprogrammierung minimieren. Zudem lassen sich die Angebote sowie das Kundenerlebnis je nach Segment personalisieren und die Probleme lösen, welche die unsichere und agile Realität, in der sich die Menschen gegenwärtig befinden, mit sich bringt.[80]

DM, ML und KI sind in allen Branchen anwendbar. Die Modeindustrie ist ein Beispiel dafür, wie die Anwendung dieser drei Konzepte eine Branche komplett revolutionieren kann. *„Von der Produktionsmaschine über das Schnittmuster-Programm bis zur Marketing-Optimierungs-Software beim Händler oder Social-Media-Kanälen für VIP-Shopping: Maschinen und künstliche Intelligenz helfen dabei, Mode zu machen und sie an den Kunden zu bringen.“*[81] So lässt sich mit Hilfe von DM herausfinden, wie Kunden über neue Produkte oder Trends denken.[82] ML und KI können wiederum anhand von Visual Search, die durch den Einsatz von Computer Vision die Möglichkeit bietet, ohne sich auf Text zu beschränken, Unmengen von visuellen Daten zu durchsuchen, sowie Neuronal Networks, welches ebenfalls mittels Computer Vision die Möglichkeit bietet, Objekten zu identifizieren. Dadurch lassen sich beispielweise die Farben der Kleidung, die Passanten tragen, erkennen, sodass sich Muster im Hinblick auf die Vorhersage der nächsten saisonalen Farbe und Desings, die Unternehmen auf den Markt bringen sollten, identifizieren lassen.[83]

Es ist Folgendes anzumerken: Obwohl diese Informationssysteme die Fähigkeit besitzen, Muster zu finden, die für den Menschen nur sehr schwer zu erkennen sind, ist es wichtig,

[76] Vgl. Davenport 2018, S. 101–103.
[77] Vgl. Cleve; Lämmel 2020, S. 59.
[78] Vgl. Cleve; Lämmel 2020, S. 59.
[79] Vgl. Weber 2020, S. 43.
[80] Vgl. Baars; Kemper 2021, S. 124.
[81] Albers Ben Chamo 2017, S. 1.
[82] Vgl. Luce 2018, S. 14.
[83] Vgl. Luce 2018, S. 58–59.

immer im Hinterkopf zu behalten, dass Entscheidungen und Analyse stets von einem Menschen kontrolliert, genehmigt und umgesetzt werden müssen.[84]

Zu betonen ist die Wichtigkeit, Muster zu erhalten, die Sinn ergeben. Schließlich ist es wahr, dass Systeme Muster erkennen können, die für den Menschen nicht sichtbar sind. Allerdings ist es auch zutreffend, dass diese Muster in vielen Fällen bedeutungslos sind. Das heißt, es handelt sich manchmal um bloße Koinzidenzen in Form von Korrelationen, die bei der Ergreifung von Maßnahmen oder der Umsetzung von Verbesserungen in Unternehmen nicht berücksichtigt werden können.[85]

Ausgehend von der Idee, dass die Menschen diejenigen sind, die die Entscheidungen treffen sollten, ist es an dieser Stelle notwendig, zu betonen, dass ein Mensch sowohl Sozialkompetenz (Soft Skills) als auch Fachkompetenz (Hard Skills) besitzen sollte, um gute Auswertungsergebnisse zu erzielen. Außerdem benötigt er eine Unternehmensvision, die es ihm gestattet, innovativ zu sein und in einer Weise zu denken, die über die Analyse hinausgeht.[86] Diejenige Berufsgruppe, die über die oben genannten Capabilities verfügen soll, ist die des Data Scientist. Es ist jedoch zu beachten, dass diese Berufsgruppe äußerst schwierig zu finden ist. Außerdem sind Data Scientists in den meisten Fällen nicht geeignet, ihr Potenzial auszuschöpfen, wenn die Personen in ihrer Umgebung über keine Kenntnisse hinsichtlich Data Science verfügen. Aus diesem Grund ist es wichtig, Führungskräfte und Mitarbeiter aus anderen Bereichen in der Datenanalytik zu schulen, denn diese Fähigkeiten sind nahezu unverzichtbar, um den Informationen, die durch Daten generiert werden, einen Wert zu verschaffen.[87]

2.3 Netflix: ein Unternehmen, welches auf Datenanalytik basiert

Mit dem Aufkommen von Informationssystemen, welche die Unterstützung des Managements durch die Analyse ermöglichen, gewann der Aufstieg der Analytik deutlich an Bedeutung. In diesem Bereich sind anerkannte Autoren wie Kemper (2010) und Davenport (2007) tätig. Sie vertreten die Idee, dass der Einsatz von Computern und Informationstechnologien eine essenzielle Rolle bei der Unterstützung des Managements spielt. Seitdem ist in Unternehmen ein Paradigmenwechsel zu beobachten, bei dem Daten und Technologie eine wesentliche Rolle für den Erfolg spielen.[88][89]

Den Erfolg von Netflix verdankt das Unternehmen der Tatsache, ein Analytik-Unternehmen zu sein, d. h. es ist ein hervorragendes Beispiel für ein Unternehmen, das auf der Grundlage seiner mathematischen und statistischen Fähigkeit sowie seiner Datenmanagement-Fähigkeiten konkurriert. In der Vergangenheit hatte Netflix seinen fast 6 Millionen Kunden einen kostenlosen Versand von DVDs angeboten und eine ebenfalls kostenlose Rücksendung bereitgestellt.[90]

[84] Vgl. Lyell; Coiera 2017, S. 423–424.
[85] Vgl. Seiter 2017, S. 190–191.
[86] Vgl. Zhang 2017, S. 167–168.
[87] Vgl. Euchner 2017, S. 14–15.
[88] Vgl. Davenport; Harris 2007, S. 16–19.
[89] Vgl. Ereth; Kemper 2016, S. 458.
[90] Vgl. Davenport; Harris 2007, S. 16–17.

Die Kunden sahen sich ihre ausgewählten Filme nach Belieben an; es gab keine Verspätungsgebühren. Bei der Rückgabe von DVDs wählten die Kunden ihre nächsten Filme aus. Zusätzlich zu den logistischen Erkenntnissen, die Netflix benötigte, um dieses Projekt profitabel zu gestalten, setzte das Unternehmen die Analytik auf diverse wichtige Arten ein, alle angetrieben durch das Kundenverhalten und die Kaufmuster.[91]

Das erste Programm war eine Filmempfehlungs-Maschine mit dem Namen Cinematch, die auf einer proprietären, Algorithmus-gesteuerten Software basiert. Es wurden Mathematiker mit Programmierkenntnissen engagiert, um die Algorithmen und den Code zu schreiben, die Gruppen von Filmen zu definieren, die Filmbewertungen der Kunden mit den Gruppen zu verbinden, Tausende von Bewertungen pro Sekunde auszuwerten sowie das aktuelle Website-Verhalten in Betracht zu ziehen, um eine personalisierte Webseite für jeden Kunden zu garantieren.[92]

Darüber hinaus hat Netflix einen Preis in Höhe von 1 Million US-Dollar für externe quantitative Analysten ausgelobt, die es mit ihren Ergebnissen schaffen, den Cinematch-Algorithmus um mindestens 10 Prozent zu verbessern.[93] [94]

Aufgrund der Datenanalyse war Netflix in der Lage, Entscheidungen zu treffen, beispielweise

- welche Filme empfehlenswert waren, so dass sowohl der Kundengeschmack als auch die Bestandsbedingungen optimiert wurden,
- wie bestimmt werden sollte, wie die Verteilung der Lieferanforderungen zwischen häufig benutzenden und selten benutzenden Kunden ausbalanciert wurde, und
- was für die DVD-Vertriebsrechte zu zahlen war.

Die Analytik, die Netflix in der Vergangenheit eingesetzt hat, sowie die ständigen Investitionen und Weiterentwicklungen des Unternehmens in diesem Bereich machten Netflix schließlich zu dem erfolgreichen Unternehmen, das es gegenwärtig ist. Hieran zeigt sich, dass die Netflix-Manager früher als ihre Konkurrenten erkannt haben, dass die Gewinnung, Einstellung und Bindung von Analysetalenten sowie der Aufbau von Analysefähigkeiten im Unternehmen eine entscheidende Quelle für Wettbewerbsvorteile sind.[95]

2.4 Risiken von BA

Die Risiken der Analytik sind vielfältig. Im Folgenden werden einige der wichtigsten vorgestellt und es wird erklärt, warum es notwendig ist, jedes einzelne davon bei einer Entscheidung zu berücksichtigen.

- **Erkennung von Mustern, die nicht existieren**: Die Menge der Sensoren, die heute verkauft werden, ist beeindruckend und die Daten, die erzeugt werden, sind

[91] Vgl. Davenport; Harris 2007, S. 16–19.
[92] Vgl. Davenport; Harris 2007, S. 17.
[93] Vgl. Bell; Koren; Volinsky 2010, S. 24.
[94] Vgl. Hallinan; Striphas 2016, S. 118.
[95] Vgl. Harris; Craig; Egan 2010, S. 15.

dementsprechend enorm. Die Fähigkeit, diese Daten zu analysieren und umzuwandeln, führt zu besseren Entscheidungen und damit zu einem Wettbewerbsvorteil.[96] Allerdings kann es dem Unternehmen zum Verhängnis werden, wenn es keine Muster identifiziert und keine strategische Analyse durchführt. Dafür ist es wichtig, die korrekte IT-Infrastruktur zu besitzen. Somit benötigen die Daten die 5V(Volume, Velocity, Variety, Veracity, Value)-Eigenschaften und der Transformationsprozess (ETL, Extact, Transform, Load) soll außerdem der korrekte sein, um Erkenntnisse an diese Menge von Daten zu bekommen.[97]

- **Kompletter Ersatz der menschlichen Intelligenz durch Informationen aus BA-Systemen:** Es ist sehr wichtig, klarzustellen, dass die Gewinnung von Intelligenz aus Daten nicht dazu gedacht ist, die menschliche Intelligenz zu ersetzen. Es handelt sich lediglich um Systeme und Informationen, die als Referenz dienen und dem Menschen helfen, sich nicht auf seine Intuition zu verlassen und die kognitionspsychologischen Probleme zu überwinden (diese werden in den nächsten Kapiteln der Masterarbeit ausführlich erklärt).[98]

- **Falsche Programmierung eines Algorithmus**, d. h. Erstellung von verzerrten Verfahren wie HR-Algorithmen bei der Suche nach Personal, die von Personen programmiert wurden, die Frauen benachteiligen. Dies verursacht nicht nur, dass eine Abteilung, in diesem Fall die HR-Abteilung, verzerrte Informationen bekommt, sondern kann auch weitere Folgen haben, wie die Diskriminierung von ein paar Bewerbern.[99] [100]

- **Mangel an qualifizierten Mitarbeitern:** Es ist essenziell, geeignetes Personal im Unternehmen zu haben, d. h., einen Data Scientist, der alle Kompetenzen besitzt, um eine gute Analyse vornehmen zu können. Demzufolge sollten diese auch genügend Ressourcen besitzen, um das Projekt oder Problem datenbasiert lösen zu können.[101]

2.5 BA und Entscheidungsfindung in Unternehmen

In Anbetracht der Bedeutung von BA für Unternehmen ist zu beobachten, wie Organisationen immer mehr Data-Science-Initiativen zur Unterstützung der Entscheidungsfindung implementieren. Trotz der richtigen Intuition bei der Umsetzung dieser Initiativen stellt sich oft heraus, dass die Ergebnisse nicht die erwarteten sind. Dafür gibt es viele Gründe. Einer davon ist, dass das Unternehmen auf diesen Wandel nicht vorbereitet war, sowohl auf der infrastrukturellen als auch auf der kulturellen Ebene, und deshalb keine guten Ergebnisse erreichen konnte.[102]

In diesem Zusammenhang soll abschließend noch einmal darauf hingewiesen werden, dass Entscheidungen, die auf der Grundlage von BA und BI getroffen werden, wesentlich

[96] Vgl. Zhang 2017, S. 30.
[97] Vgl. Weber 2020, S. 2–3, 15–16.
[98] Vgl. Varona; Lizama-Mue; Suárez 2021, S. 197–198.
[99] Vgl. Zhang 2017, S. 18–20.
[100] Vgl. Bonnefon; Rahwan 2020, S. 1019–1021.
[101] Vgl. Zhang 2017, S. 171–173.
[102] Vgl. Zhang 2017, S. 148–149.

genauer sind. Dennoch liegt die endgültige Entscheidung immer im Kompetenzbereich einer Person (Manager, CIO, CEO etc.). Hier kommt das menschliche Verhalten zum Tragen, welches in der Datenanalyse eine sehr wichtige Rolle hat. Somit liegt in diesem Bereich eine der größten Herausforderungen für die Analytik. Dabei geht es nicht nur um Systeme, die Muster liefern oder bei der Entscheidungsfindung helfen, sondern vielmehr ist es maßgeblich, zu verstehen, wie sich Menschen verhalten und Entscheidungen auf der Grundlage der vom System bereitgestellten Informationen treffen.[103]

[103] Vgl. Niebler; Lindner 2019, S. 8.

3. Kognitionspsychologische Phänomene

3.1 Kognitionspsychologische Phänomene – Begriffserklärung

Für den Begriff des kognitionspsychologischen Phänomens gibt es in der Literatur keine konkrete Definition. Daher wird in dieser Masterarbeit das kognitionspsychologische Phänomen als Oberbegriff verstanden, der alle Phänomene umfasst, die bei der Entscheidungsfindung auftreten können. Darunter fallen Heuristiken, Trugschlüsse, Verzerrungen, Gesetzesmechanismen usw.

3.1.1 Kognitionspsychologische Phänomene – Entstehung

Die kognitionspsychologischen Phänomene gehören zur Verhaltensökonomie. Dieses Fachgebiet, das Disziplinen wie Ökonomie, Psychologie, Mathematik und Soziologie miteinander verbindet, entstand in den 1970er Jahren und versucht seitdem, das Verhalten der Menschen durch verschiedene Theorien und Forschungen zu erklären, wobei die oben genannten Disziplinen kombiniert werden, um eine vollkommen revolutionäre und andersartige Vorstellung als die der neoklassischen Ökonomen dieser Zeit hervorzubringen.[104]

Dieser Forschungszweig wurde als Kritik an den damals vorherrschenden ökonomischen Modellen initiiert.[105] Durch verschiedene Untersuchungen von mehreren Autoren wie Simon, Tversky, Edwards, Kahneman, Thaler usw. zeigte sich aufgrund der von ihnen durchgeführten Experimente, dass das Bild des rationalen Menschen, besser bekannt als Homo oeconomicus, welches mit der klassischen Ökonomie geprägt wurde, nicht der Realität entsprach.[106]

Die Annahme, dass der Mensch rational ist, wurde durch die Beiträge dieser Autoren widerlegt, indem sie als grundlegende Prämisse aufstellten, dass der Mensch nicht als berechnende Maschine gesehen werden kann, die über unbegrenztes Eigeninteresse, unlimitierte Willenskraft und uneingeschränkte Rationalität verfügt, da eine solche Aussage nicht der Wirklichkeit entspricht.[107]

Beck (2014) definiert Verhaltensökonomie als „Versuch, das Menschenbild der Ökonomie mit dem Menschenbild der Psychologie wieder zu versöhnen“.[108] Auf diese Weise sucht die Verhaltensökonomie nach psychologischen Mustern des menschlichen Verhaltens und erhebt die Relevanz dieser Muster in einem ökonomischen Kontext.[109] Es ist jedoch anzumerken, dass dieser Gedanke nicht neu ist. Schon in seiner ersten Schrift „Theory of moral sentiments“ schrieb Adam Smith über verschiedene Phänomene wie Selbstüberschätzung, Verlustaversion und den Konflikt zwischen den kurzfristigen

[104] Vgl. Masao; Tanaka 2017, S. 4–5.
[105] Vgl. Pompian 2012, S. 26–27.
[106] Vgl. DellaVigna 2009, S. 315–316.
[107] Vgl. Beck 2014, S. 1–2.
[108] Beck 2014, S. 9.
[109] Vgl. Rabin 2002, S. 11–13.

Leidenschaften der Menschen und ihren langfristigen rationalen Absichten.[110] [111] Auch wenn diese Phänomene heute unter anderen Namen bekannt sind und von anderen Autoren genauer beschrieben werden, basieren sie auf der gleichen Grundlage.

3.1.2 Kritik an der Verhaltensökonomie

Weiterhin wurde und wird die Verhaltensökonomik von mehreren Ökonomen kritisiert, wie, um nur zwei zu nennen, Mikhail Myagkov und Charles Plott (1997).[112] Eines der aussagekräftigen Argumente der Kritiker liegt darin, dass Marktsituationen nicht durch Verhaltensbeobachtung erklärt werden können, da aufgrund von Lernmöglichkeiten und Wettbewerb ein vernünftiges Verhalten zu erwarten sei.[113] Hinzu kamen die mathematischen Theorien, welche die Idee des Homo oeconomicus unterstützten, beispielsweise die Spieltheorie. Diese wurde als eine mathematische Theorie zur Modellierung von Entscheidungssituationen vorgestellt. Der Ausgangspunkt dieser Theorie war die Analyse des Homo oeconomicus. Hierbei sind u. a. die Beiträge von Bernoulli, Bertrand, Cournot und Borel zu würdigen. Die Grundlagen der modernen Spieltheorie wurden im Jahr 1928 von John von Neumann durch eine formale Analyse von Gesellschaftsspielen und den Beweis des MinMax-Theorems gelegt.[114]

Diese Theorie sowie eine Reihe von Beiträgen anderer Autoren, wie die Nutzentheorie, die Erwartungsnutzentheorie und die Wahrscheinlichkeitstheorie, basieren auf der Grundlage der Mathematik, um rationales menschliches Verhalten bei der Entscheidungsfindung zu definieren sowie zu unterstützen.[115]

Die Kritiker wiederum argumentieren, dass es sich bei der Verhaltensökonomie nicht um eine einheitliche Theorie handelt, sondern eher um eine Sammlung verschiedener Ideen und Werkzeuge. Darüber hinaus weisen sie darauf hin, dass die Verhaltensökonomik auf der selektiven Behandlung der Annahmen der neoklassischen Ökonomie durch die Verhaltensökonomen aufbaut. Anders formuliert, basiert die Verhaltensökonomie auf der Eliminierung bestimmter Elemente der allgemeinen ökonomischen Struktur. Dies kann zu Inkonsistenzen in Bezug auf andere Prinzipien führen – und als Konsequenz zum Zusammenbruch der gesamten Struktur einer vorliegenden Theorie. Zu den stärksten Hauptkritikpunkten gehört auch, dass viele dieser Ökonomen darauf hinweisen, dass es der verhaltensökonomischen Forschung sowohl am Realismus als auch in vielen Fällen am Verständnis der Befragten für das Experiment mangelt. Dementsprechend ist die Gültigkeit der Ergebnisse anzuzweifeln.[116]

Somit lässt sich erkennen, dass sich die Kritiker der Verhaltensökonomie ausschließlich auf die mathematische Seite von Entscheidungen konzentrieren und ihre Beiträge und Theorien auf die Grundlage der Mathematik stützen. Unbestreitbar waren die Beiträge der genannten Autoren elementar für die Entwicklung der Ökonomie sowie anderer Disziplinen

[110] Vgl. Smith 1795, S. 15–18.
[111] Vgl. Ashraf; Camerer; Loewenstein 2005, S. 131.
[112] Vgl. Myagkov; Plott 1997, S. 801–802.
[113] Vgl. Callebaut 2007, S. 77.
[114] Vgl. Myerson 1991, S. 1–2.
[115] Vgl. Beck 2014, S. 1.
[116] Vgl. Nermend 2017, S. 14–16.

wie der Technologie. Jedoch gehen ihre Forschungen, indem sie sich ausschließlich auf den mathematischen Teil der Entscheidungsfindung konzentrieren, nicht vollständig auf die Entscheidungsrealität ein, d. h. es können diese nicht als endgültige Wahrheit angesehen werden.[117] [118]

3.1.3 Wiederbelebung der Verhaltensökonomie und Entdeckung der wichtigsten kognitionspsychologischen Phänomene

In Anlehnung an die Verknüpfung von Psychologie und Ökonomie entstanden Teilgebiete der Psychologie wie die ökonomische Marktpsychologie und die Verhaltensorganisationspsychologie. In Studien, die auf der kognitiven Psychologie basieren, wurde 1960 die Erstellung von kognitiven Modellen erreicht.[119] Auf diesem Gebiet befindet sich das Vermächtnis einer der wichtigsten Personen in der Disziplin der Entscheidungsfindung, nämlich Herbert Simon.[120] [121] Er war ein vielseitiger Wissenschaftler mit Kenntnissen und Erfahrungen in verschiedenen Disziplinen wie Wirtschaftswissenschaft, Politikwissenschaft, Betriebsanalyse, Mathematik, Statistik, Science, Psychologie und Computerwissenschaft. Er widmete sein Leben der Forschung in den oben genannten Bereichen.[122]

Eine der bedeutendsten Grundlagen der Verhaltensökonomie, die sogenannte begrenzte Rationalität, geht auf Simon zurück. Er verteidigte mit diesem Konzept die These, dass die Rationalität des Menschen nicht unbegrenzt ist, wie es die Theorie des Homo oeconomicus vorschlug, denn es können nicht sämtliche Faktoren, mit denen eine Entscheidung verbunden ist, bekannt sein und berücksichtigt werden.[123] Der Grund dafür liegt in der Tatsache, dass die Welt zu komplex ist, Unsicherheit immer präsent ist und schließlich der Einfluss, den Institutionen auf die Entscheidungen von Menschen ausüben, sehr stark ist.[124] Somit verfügt der Mensch nicht über ausreichende Ressourcen, um optimale Entscheidungen zu treffen, sondern eher über befriedigende Entscheidungen, die wiederum an die Umstände und Erfahrungen des Entscheidungsträgers angepasst sind.[125] Dementsprechend beschäftigte sich Simon mit der Gewinnung und Auswertung von Informationen mit Hilfe der Informatik, um Informationslösungen zu entwickeln, welche die oben beschriebenen Faktoren bei der Entscheidungsfindung in Organisationen minimieren würden.[126] Auf diese Weise lässt sich nachvollziehen, wie Simons Forschungen auch die Anfänge der KI und der Entscheidungsunterstützungssysteme (DSS, ODSS, GDSS) begründeten.[127]

Die umfangreichen Studien von Simon beeinflussten die Arbeit anderer Forscher auf diesem Gebiet. So schufen Daniel Kahneman und Amos Tversky im Jahr 1979 unter dem

[117] Vgl. Quesnel 2018, S. 35–36.
[118] Vgl. Nermend 2017, S. 12–14.
[119] Vgl. Pompian 2012, S. 31.
[120] Vgl. McCredie; Simon 2001, S. 27.
[121] Vgl. Velupillai; Venkatachalam 2018, S. 2.
[122] Vgl. Brown 2002, S. 237.
[123] Vgl. Simon 1993, S. 156, 160.
[124] Vgl. Morin 2001, S. 22–24.
[125] Vgl. Brown 2004, S. 1240.
[126] Vgl. Simon 1971, S. 10–13.
[127] Vgl. Simon 1995, S. 123.

Einfluss von Simons Werk eine wesentliche Theorie für die Verhaltensökonomie.[128] [129] Dabei handelt es sich um die Prospect Theory, welche eine realistische Alternative zur Theorie des Erwartungsnutzens bietet.[130]

Die Erwartungsnutzentheorie erklärt die Entscheidungsfindung in risikoreichen Situationen, in denen die Wahrscheinlichkeit des Auftretens eines Ereignisses oder mehrerer Ereignisse bekannt ist. Demnach entscheiden sich Menschen für die Option mit dem höchsten Erwartungswert, der sich aus der Multiplikation des zu gewinnenden oder zu verlierenden Betrags mit der Eintrittswahrscheinlichkeit ergibt. Weiterhin geht die Theorie davon aus, dass Menschen jede Option in Bezug auf deren Beitrag zum finanziellen Endergebnis bewerten.[131]

Hingegen argumentiert die Prospect Theory, dass die Motivation der Menschen nicht darin besteht, die Option mit dem höchsten Erwartungswert zu wählen, sondern Verluste zu vermeiden.[132] Gemäß dieser Theorie wird „prospect“ als die Kombination eines Ereignisses mit seiner Wahrscheinlichkeit definiert. Zwar wird in dieser Theorie die Vorstellung aufrechterhalten, dass Menschen eine Art von Erwartung maximieren, jedoch wird auch festgestellt, dass Menschen die Wahrscheinlichkeiten, mit denen ein Ereignis eintritt, unterschiedlich bewerten. Dies liegt daran, dass „Prospects“ zwei Prozesse durchlaufen: die Bearbeitung, bei der „Prospects“ organisiert und neu formuliert werden, sowie die Bewertung, bei der Wahrscheinlichkeiten gewichtet werden und der Wert eines jeden „Prospects“ für die Person berechnet wird.[133] [134]

Die Theorie hat sich im Laufe der Zeit weiterentwickelt. Im Jahr 1992 wurde eine überarbeitete Version von Kahneman und Tversky veröffentlicht, die „Cumulative Prospect Theory“ genannt wurde. Diese Version gibt eine Erklärung für die Entscheidungsfindung nicht nur unter Risiko, sondern auch unter Unsicherheit und Ambiguität.[135]

Anhand dieser Theorie lässt sich erkennen, wie deskriptive und normative Verhaltenstheorien aufgeteilt wurden.[136] Des Weiteren ist zu erkennen, dass der Anwendungsbereich dieser Theorie sehr vielfältig ist: Zu nennen sind Investitionen, Versicherungsverträge, Marketing usw.[137] Darüber hinaus erklärt diese Theorie eine Reihe von dokumentierten Anomalien (in dieser Arbeit als kognitionspsychologische Phänomene bezeichnet) beim Treffen fundierter wirtschaftlicher Entscheidungen.[138]

In diesem Zusammenhang lässt sich feststellen, dass Menschen beim Denken nicht immer logischen und normativen Verfahren folgen und auch nicht in der Lage sind, statistische Daten so zu abstrahieren sowie zu analysieren, dass daraus gültige Schlussfolgerungen

[128] Vgl. Takemura 2014, S. V.
[129] Vgl. Kahneman 2003, S. 1449.
[130] Vgl. Masao; Tanaka 2017, S. 33.
[131] Vgl. Beck 2014, S. 11.
[132] Vgl. Beck 2014, S. 11–12.
[133] Vgl. Takemura 2014, S. 84–87.
[134] Vgl. Kahneman; Tversky 1979, S. 274.
[135] Vgl. Takemura 2014, S. 89, 95–97.
[136] Beck 2014, S. 9, 101–102, 319.
[137] Vgl. Takemura 2014, S. 91, 94, 123.
[138] Vgl. Kahneman; Tversky 1979, S. 288–289.

abgeleitet werden können. Vielmehr folgen Menschen einfachen Regeln, mentalen Abkürzungen oder Heuristiken, um zu sinnvollen Schlussfolgerungen zu gelangen.[139]

Heuristiken werden als Verfahren betrachtet, die zur Problemlösung beitragen, obwohl diese Vorgehensweise nicht unbedingt rational ist, d. h., es handelt sich um intuitive Urteile, die auf Teilwissen, auf Erfahrung oder auf Annahmen beruhen, die richtig oder falsch sein können.[140] Außerdem gibt es keine absolute und logische Gewissheit über diese Heuristiken. Anders formuliert, können Heuristiken als normale intuitive Antworten definiert werden, die nicht nur auf Probleme hoher Komplexität, sondern auch auf einfache Fragen der Plausibilität, Häufigkeit und Vorhersage angewendet werden können.[141]

Es ist anzumerken, dass Heuristiken nützlich sind, da sich mit ihrer Hilfe akzeptable Synthesen einer Problemlösung erreichen lassen.[142] Allerdings ist zu berücksichtigen, dass die Verwendung von Heuristiken zu systematischen Fehlern führen kann, welche als kognitive Verzerrungen bezeichnet werden.[143]

Kognitive Verzerrungen werden als Veranlagung zum Irrtum, als Fehlinterpretation verfügbarer Informationen oder als Fehleinschätzung betrachtet. Sie sind Effekte, die eine Veränderung der Informationsverarbeitung von Menschen verursachen. Dadurch entsteht eine Verzerrung, ein abweichendes Urteil oder eine fehlerhafte, inkohärente und unlogische Interpretation der ihnen zur Verfügung stehenden Informationen.[144] [145]

So unterteilt Kahneman (2012) in seinem Buch „Thinking fast and slow“ kognitive Prozesse in zwei Systeme – System 1 und System 2. Er weist Heuristiken und kognitive Verzerrungen dem System 1 zu. Dieses zeichnet sich dadurch aus, dass es schnell und intuitiv, d. h. fast automatisch, arbeitet. Er argumentiert auch, dass System 2 ein System ist, das Informationen kontrolliert und logisch auswerten kann, aber sowohl Konzentration als auch Zeit benötigt.[146] Hervorzuheben ist, dass die Idee, den Geist in zwei verschiedene Systeme zu unterteilen, nicht neu ist, denn in der Erforschung des Geistes in der Psychologie wurde von Anfang an eine Unterteilung zwischen den Begriffen bewusst (kontrolliert, explizit, aufmerksame oder mit Anstrengungen) und unbewusst (automatische, implizite, mühelose oder nicht aufmerksame Verarbeitung) vorgeschlagen.[147]

Kahneman weist anhand mehrerer einfacher Experimente, die er in seinem Buch beschreibt, darauf hin, dass Entscheidungen hauptsächlich im System 1 getroffen werden. Dieses System ist, wie oben erwähnt, emotional, geprägt von Stereotypen und unbewusst. Somit lässt sich erkennen, dass aus Kahnemans Sicht die Entscheidungsprozesse von Menschen steuerbar sind.[148]

Dieser Gedanke ist sehr kontrovers, was an einer Kritik von Gerd Gigerenzer zu erkennen ist. Letzterer ist ein konsequenter Verteidiger der Intuition. Dementsprechend weist er

---

[139] Vgl. Gilovich; Griffin; Kahneman 2002, S. 19–20.
[140] Vgl. Beck 2014, S. 25–27.
[141] Vgl. Łatuszyńska; Nermend 2018, S. 13–14, 48, 156.
[142] Vgl. Beck 2014, S. 81–83.
[143] Vgl. Nermend 2017, S. 37.
[144] Vgl. Nermend 2017, S. 43–44, 66, 114–116.
[145] Vgl. Beck 2014, S. 26.
[146] Vgl. Kahneman 2012, S. 22–23.
[147] Vgl. Núñez Partido 2006, S. 1–2.
[148] Vgl. Kahneman 2012, S. 23–24.

darauf hin, dass Intuition effektiver sein kann als rationale Entscheidungsmodelle.[149] Laut Gigerenzer treffen Menschen bessere Entscheidungen, wenn sie einen guten Grund in Betracht ziehen, als wenn sie zehn in Betracht ziehen.[150] Die Ursache dafür ist, wie bei fast allem anderen kognitiven Prozessen, evolutionär bedingt. Der Prozess der Auswahl basiert auf einer Reihe von allgemeinen Regeln, die das Gehirn über Tausende von Jahren gelernt hat. Diese Regeln sind Teil einer Art Lehrbuch, das Menschen in jeder Situation zu Rate ziehen können, um schnelle und präzise Antworten zu finden. Es ist das, was als „Faustregel“ oder „Heuristik“ bezeichnet wird. Der Autor beschreibt auch, dass die wichtigsten Entscheidungen im Leben intuitiv getroffen werden.[151] Denn Menschen, die nicht alle Informationen kennen, wählen aus, was ihnen bekannt ist (Erkennungsheuristik), und treffen somit systematisch bessere Entscheidungen.[152] Wenn jedoch ein bekanntes Unternehmen sein ganzes Geld für Werbung ausgibt, anstatt in die Verbesserung eines Produkts zu investieren, ist es sehr wahrscheinlich, dass die Intuition des Kunden getäuscht wird und er keine vorteilhafte Entscheidung trifft.

Es sollte klargestellt werden, dass weder Heuristiken noch Verzerrungen als pathologische Phänomene betrachtet werden sollten, denn diese hatten einen adaptiven Wert bei der menschlichen Spezies. Auf diese Weise mussten die Vorfahren der heutigen Menschen in einer feindlichen, unsicheren und unter Druck stehenden Umgebung schnelle Entscheidungen treffen, ohne über vollständige Informationen zu verfügen. Daran lässt sich erkennen, dass solche Verzerrungen bzw. Heuristiken in diesen Fällen ein schnelles Handeln mit wenig verfügbaren Informationen ermöglichten. Wenn es jedoch um die Entscheidungsfindung in Organisationen geht, ist es wichtig, dass die Entscheidungen auf Evidenz und nicht rein auf Intuition basieren.[153]

3.2 Problematik von kognitionspsychologischen Phänomenen

Eines der größten Probleme bei diesen psychologischen Phänomenen ist, dass sich viele der Autoren und Theorien gegenseitig widersprechen.

Daran lässt sich beispielweise erkennen, dass Gigerenzer und Kahneman Gegner sind. Beide Autoren wurden von Simons Ideen und Erbe beeinflusst und gehören zur Strömung der Verhaltensökonomie, außerdem wurden die Forschungen beider Autoren durch zahlreiche Experimente und Beobachtungen validiert. Jedoch vertreten diese komplett unterschiedlichen Ansichten. Wie bereits im Kapitel 3.1 dargestellt wurde, verteidigt Gigerenzer die These, dass es möglich ist, mit Hilfe von Intuition und Heuristiken die optimalen Entscheidungen zu treffen, während Kahneman argumentiert, dass die Intuition versagen kann. Demzufolge ist dies nicht die richtige Methode, um die bestmögliche Entscheidung zu treffen.

Es ist daher sehr wichtig, zu betonen, dass es nicht immer sinnvoll ist, der Intuition zu folgen, da mehrere Beispiele in der Literatur zeigen, wie die Intuition zu einer Verirrung

[149] Vgl. Gigerenzer 2015, S. 38, 44–45, 146.
[150] Vgl. Gigerenzer 2015, S. 45–46.
[151] Vgl. Gigerenzer 2008, S. 20–21.
[152] Vgl. Gigerenzer 2015, S. 64, 71, 293.
[153] Vgl. Gilovich; Griffin; Kahneman 2002, S. 10–13.

führen kann.[154] Es ist somit notwendig, zu identifizieren, wann Heuristiken für eine Person nützlich sind – und wann sie gegen diese wirken können. Andernfalls wird es nicht möglich sein, diese Phänomene zu vermeiden, und die Entscheidungen, zu denen ein Mensch kommt, werden nicht korrekt sein.[155]

In Anlehnung an Kahnemans Ansatz ergibt sich ein weiteres Problem bzw. eine weitere Konsequenz, die „Nudge Theory", je nachdem, aus welchem Standpunkt das Thema betrachtet wird. Diese Theorie wurde von Richard Thaler und Cass Sunstein im Jahr 2008 entwickelt und gehört zur Verhaltensökonomie.[156] Dabei handelt es sich um eine neue Methode, die zu einer Veränderung der Gesellschaft führt. Ziel ist es, durch kleine Veränderungen unbewusste Verhaltensmuster in den Menschen zu verankern. So können Probleme mit Hilfe von Verhaltensänderungen gelöst werden.[157]

Es ist zu erkennen, dass diese Methode sehr beliebt ist, sowohl im Bereich der Politik als auch im Marketing. Allerdings ist festzustellen, dass die Autoren, welche diese Methode kritisieren, es als problematisch betrachten, wenn diese dazu verwendet wird, Entscheidungen von Menschen zu manipulieren. Somit ist festzustellen, dass der Mensch mit dieser Methode nicht unbedingt eine für ihn günstigere Entscheidung finden wird.[158]

Um eine Strategie zu ermitteln, mit deren Hilfe herausgefunden werden kann, welche Veränderungen im Unterbewusstsein induziert werden sollen, werden Daten benötigt. Dieser Datenbestand wird heutzutage hauptsächlich im Internet abgefragt, wodurch laut dem Internet-Philosophen Evgeny Morozov „die Bürger zu Informationsmaschinen degradiert werden, die den techno-bürokratischen Komplex mit ihren Daten bearbeiten".[159]

Daraus lässt sich ableiten, dass die Verarbeitung dieser Daten, entsprechend ihrer Komplexität, durch ein Datenverarbeitungssystem erfolgen soll. Das bedeutet, dass zu diesem Zeitpunkt eine andere Art von Beziehung zwischen Datenverarbeitungssystemen und Entscheidungen bemerkt werden kann. Diese andere Art von Beziehung basiert auf der Tatsache, dass Unternehmen die von einem BI- und BA-System gelieferten Daten auswerten müssen, um daraus Entscheidungen zu treffen, die es gestatten, Änderungen im Kundenverhalten vorzunehmen. Dafür ist ein umfangreiches Wissen über die kognitionspsychologischen Phänomene und deren Einfluss auf den Menschen erforderlich. Außerdem kommen hiermit viele ethische Fragen ins Spiel.

3.3 Kognitionspsychologische Phänomene und Entscheidungen

In den vorherigen Kapiteln war es möglich, festzustellen, wie die psychologischen Phänomene entstanden sind, sowie deren Einfluss auf alle Arten von Entscheidungen zu identifizieren. Allerdings ist darauf hinzuweisen, dass im Rahmen dieser Masterarbeit hauptsächlich betriebswirtschaftliche Entscheidungen das wesentliche Thema sind.

[154] Vgl. Kahneman 2012, S. 446–447.
[155] Vgl. Gigerenzer 2008, S. 27.
[156] Vgl. Thaler 2018, S. 1266, 1283.
[157] Vgl. Bruttel; Stolley 2017, S. 783.
[158] Vgl. Burton; Shah 2013, S. 117.
[159] Rauner 2015, S. 5.

Im Bereich der unternehmerischen Entscheidungen ist erneut Herbert Simon zu erwähnen.[160] Er vertritt die Idee, dass die Hauptaufgabe des Managements darin besteht, Entscheidungen zu treffen, aber nicht so einfache Entscheidungen wie die Wahl zwischen A, B oder C, sondern komplexe Entscheidungen im Unternehmen.[161] Außerdem beschreibt er, dass programmierte (die sich wiederholen, einer Routine entsprechen und Teil des Alltags in der Organisation sind) und nicht programmierte Entscheidungen (die nicht programmierten) ein Problem außerhalb der betrieblichen Normalität des Unternehmens darstellen.[162] [163] [164] Simons Forschungen verdeutlichen auch die grundlegende Rolle des Kontexts bei der Entscheidungsfindung.[165] Denn die Wahrnehmung der Dinge und die damit verbundene Meinungen bestimmen, wie sich ein Manager entscheiden wird.[166] Hierfür sind drei Kernaspekte zu erkennen:

1) Das Untersuchungsobjekt: Was sind die Merkmale dieses Objekts? Hierunter fallen Entscheidungen wie Messung der Leistung einer Person, welche Person die vorgeschlagenen Ziele nicht erreicht, Eröffnung einer neuen Filiale, Implementierung neuer Technologien, Einführung eines neuen Produkts etc.[167]

2) Situationsbezogene Faktoren: Zeit, Wahrnehmung, was wird dringend gebraucht, was die Merkmale der Umgebung sind, soziale Komponenten usw.[168]

3) Individuelle Faktoren des Entscheiders: z. B. Motivationen, Werte, Erfahrungen, Überzeugungen etc.[169]

In der Abbildung 2 es ist möglich, zu erkennen, wie das Schema der menschlichen Erlebnisse im Moment der Entscheidungsfindung ist.

[160] Vgl. Kerr 2011, S. 400.
[161] Vgl. Simon 1960, S. 1–4.
[162] Vgl. Simon 2008, S. 41, 82, 102, 120, 129.
[163] Vgl. Banasiewicz 2019, S. 21–22.
[164] Vgl. Hofinger; Heimann 2016, S. 110–11.
[165] Vgl. Beck 2014, S. 81–82.
[166] Vgl. Nermend 2017, S. 21–23, 26, 40.
[167] Vgl. Bak 2020, S. 139–140.
[168] Vgl. Bak 2020, S. 142–144.
[169] Vgl. Bak 2020, S. 17–18.

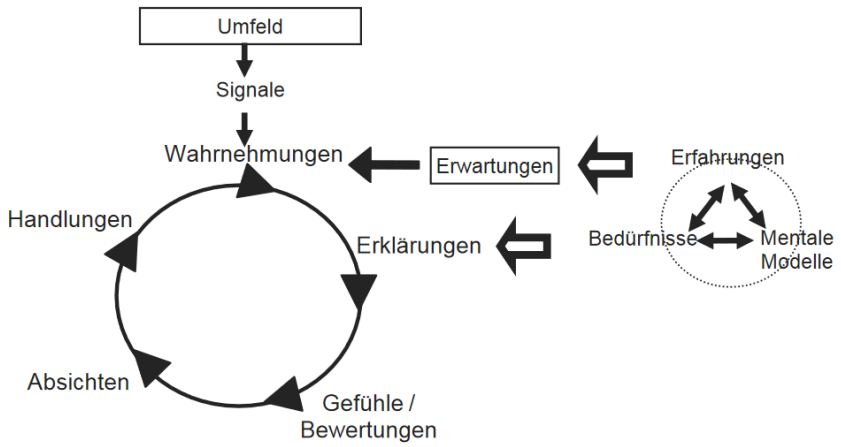

Abbildung 2: Schema menschlichen Erlebens[170]

Es ist wichtig, zu erwähnen, dass individuelle Entscheidungen heutzutage fast nicht mehr nicht mehr existieren, und noch viel weniger im Managementbereich, wo vor allem kollektive Entscheidungen getroffen werden.[171] [172] Das Problem bei kollektiven Entscheidungen ist, dass sie den Entscheidungsprozess wesentlich komplexer machen.[173] Zwar ist es richtig, dass die Diversifikation von Ideen und die oben genannten Faktoren für alle Entscheidungen äußerst wichtig sind.[174] Dadurch steigt aber die Komplexität noch mehr, wenn sich mit den Ideen, Erfahrungen und Gedanken der einzelnen Teilnehmer eines Arbeitsteams auseinandergesetzt wird.[175]

De Bono, der Begründer des lateralen Denkens, erklärt in seiner Sechs-Hüte-Theorie verschiedene mentale Modelle, die helfen, die Art, nach der Menschen denken, zu kategorisieren.[176] Der weiße Hut beschreibt beispielweise eine rationale, kapitalfluss- und makroökonomische Analyse, während der rote Hut sich für eine emotionale zuneigt: „Es gibt da irgendwas, das mir sagt, dass ich dieses Geschäft unbedingt heute eröffnen muss“.[177]

Diese Modelle bekommen einen besonderen Wert, indem diese mit der Theorie der Entscheidungsfindung kombiniert werden, denn es ist möglich, zu erkennen, dass der Mensch in Abhängigkeit vom jeweiligen Kontext ein unterschiedliches Denkmodell anwendet. Je nachdem, welchen Hut dieser Mensch für eine bestimmte Situation angewandt hat, spiegelt sich dies wiederum in seiner Entscheidung wider.[178]

Anschließend lässt sich feststellen, dass Entscheidungsfindung zwar ein Prozess ist, aber der Mensch nicht nur rational, sondern auch emotional ist, so dass der Prozess lediglich als Leitfaden dient, jedoch nicht umfassend bestimmen kann, wie Menschen entscheiden.[179]

---

[170] Hölscher u. a. 2006, S. 52.
[171] Vgl. Schnebel; Homann; Picot 2017, S. 44–46.
[172] Vgl. Hölscher u. a. 2006, S. 50–51.
[173] Vgl. Schnebel; Homann; Picot 2017, S. 52.
[174] Vgl. Bak 2020, S. 156.
[175] Vgl. Wilz 2010, S. 32–34.
[176] Vgl. Geschwill; Nieswandt 2020, S. 151.
[177] Vgl. De Bono 2016, S. 18–21.
[178] Vgl. Pinto u. a. 2015, S. 4–6.
[179] Vgl. Hölscher u. a. 2006, S. 53–55.

Zusätzlich ist es zu berücksichtigen, dass der Realität der Entscheidungsfindung in Unternehmen trotz eines Analyse-Systems eine chaotische Realität (bekannt als Mülleimer-Modell) entspricht.[180]

3.4 Kognitionspsychologische Phänomene, die den Entscheidungsprozess beeinflussen

Es existieren diverse kognitionspsychologische Phänomene, die den Entscheidungsprozess beeinflussen können. In der Abbildung 2 sind über 180 erkennbar, unter welchen sich Effekte, Fehler, Verzerrungen, Heuristiken, Regeln usw. befinden.[181] Des Weiteren ist in der Abbildung zu erkennen, dass diese Phänomene in vier Kategorien fallen:

- What Should We Remember? Hier werden mehrere Phänomene im Zusammenhang mit dem Gedächtnis, der Art, wie sich der Mensch erinnert, und der Wahrnehmung von Ereignissen in Abhängigkeit von den verschiedenen Gefühlen, die während dieses Ereignisses auftraten, beschrieben.
- Too Much Information: Unter dieser Kategorie lassen sich die Phänomene finden, die dann auftreten, wenn die Informationen, die zur Verfügung stehen, zu viele sind und somit verschiedene Eigenschaften in denselben Informationen gefunden werden können.
- Not Enough Meaning: Darunter fallen Phänomene, die auftreten, wenn jemand für die vorhandenen Informationen keine relevante Bedeutung finden kann und als Konsequenz versucht, diese Informationen mit bereits vorhandenen Geschichten und Gedanken zu füllen.
- Need To Act Fast: Zu dieser Kategorie gehören Phänomene, bei denen Zeit und die Wahrnehmung dessen, was andere denken, eine wichtige Rolle bezüglich der Entscheidungsfindung spielen.

Da diese 180 Phänomene im Laufe der Jahre durch eine Reihe von Forschungen nachgewiesen wurden, lässt sich feststellen, dass zum Zeitpunkt der Entscheidungsfindung die Wahrscheinlichkeit, in eines dieser Phänomene zu fallen, sehr hoch ist. Allerdings kann nicht im vornherein gesagt werden, welches Phänomen zum Verhängnis wird, da alles vom Kontext jeder Person und dem Moment, in dem die Entscheidung getroffen werden muss, abhängt.

Aufgrund der Zeit und des Umfangs dieser Masterarbeit ist es nicht möglich, alle 180 Phänomene der Abbildung 3 ausführlich zu beschreiben. Allerdings befindet sich im Anhang des Buches „Evidence-Based Decision-Making: How to Leverage Available Data and Avoid Cognitive Biases“ von Andrew D. Banasiewicz eine Liste mit den

[180] Vgl. Wachter 2016, S. 22, 36-37,44.

[181] Diese Arbeit beschränkt sich auf das, was bekannt ist. Deshalb wird dieses Bild aus Wikimedia (Wikipedia Creative Commons) in seiner englischen Originalsprache übernommen. Auf eine deutsche Übersetzung wird daher verzichtet. Dieses Bild wurde von John Manoogian III erstellt, die Liste der Biases mit ihren Kategorien und Beschreibungen wurde jedoch ursprünglich von Buster Benson entwickelt.

Beschreibungen von 100 dieser Phänomene.[182] Zusätzlich ist es möglich, bei der Erweiterung der Cognitive Bias Codex durch Brian Morrissette die Definitionen der einzelnen Biases nachzulesen.[183]

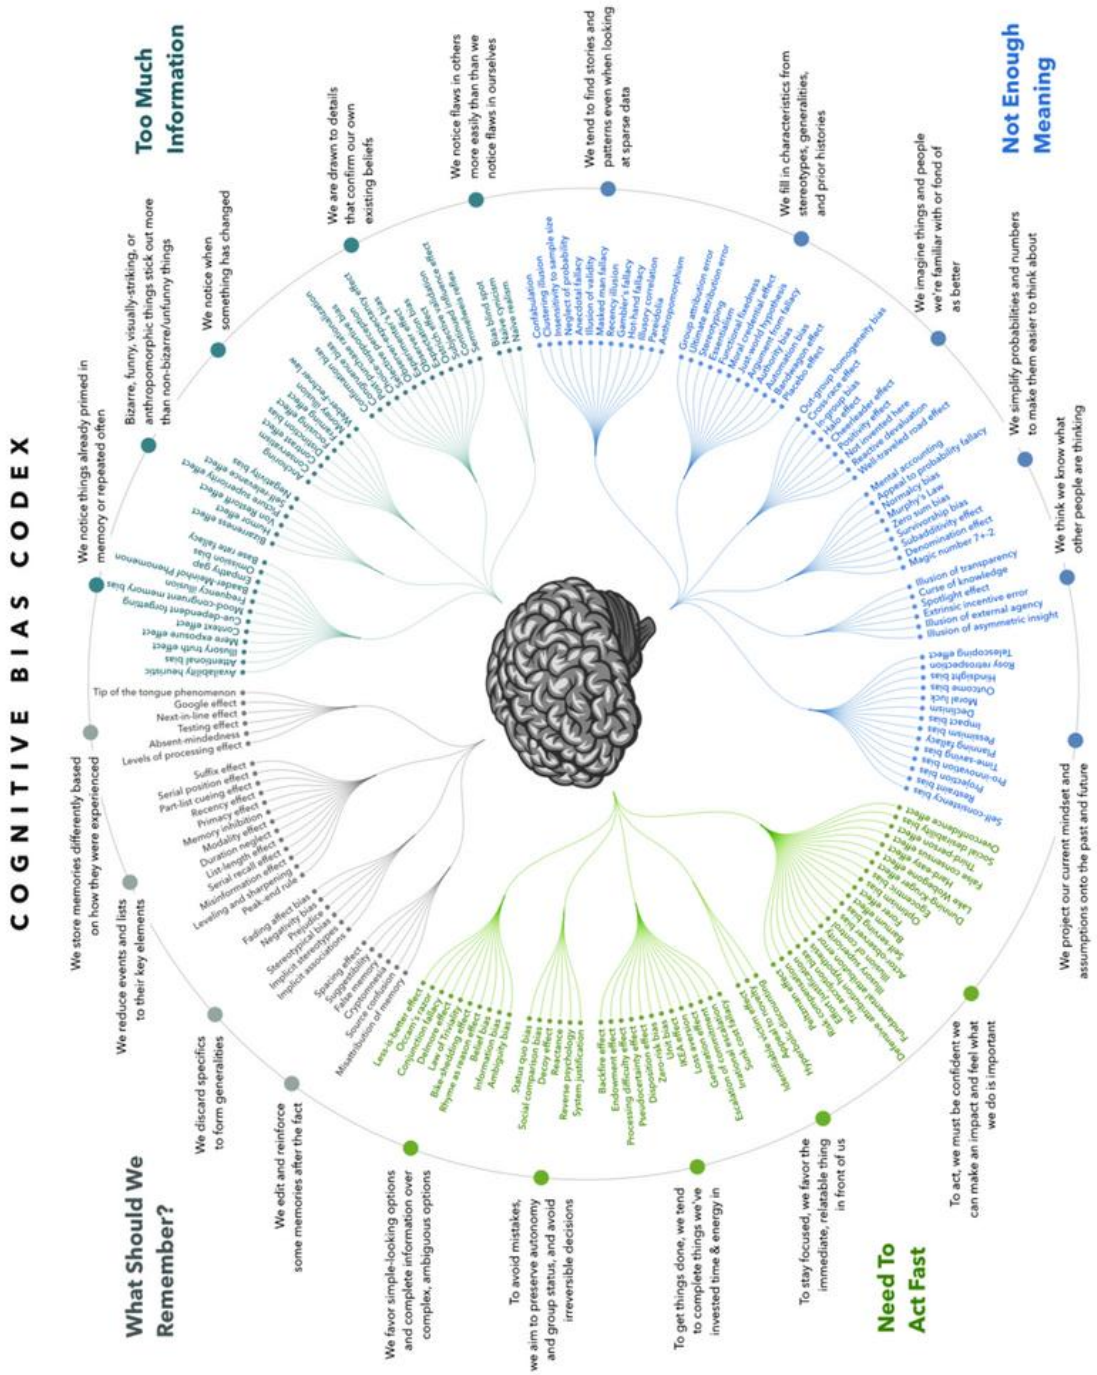

Abbildung 3: The Cognitive Bias Codex.[184]

[182] „Evidence-Based Decision-Making: How to Leverage Available Data and Avoid Cognitive Biases“ von Andrew D. Banasiewicz, ISBN:9781138485198.

[183] Die Beschreibung der Biases ist unter dem folgenden Link abrufbar: https://upload.wikimedia.org/wikipedia/commons/c/ce/Cognitive_Bias_Codex_With_Definitions%2C_an_Extension_of_the_work_of_John_Manoogian_by_Brian_Morrissette.jpg

[184] Manoogian III; Benson 2016.

3.5 Einfluss der kognitionspsychologischen Phänomene bei der BA

Der Einfluss psychologischer Phänomene in der Data Analytics ist aus den bisherigen Erkenntnissen offensichtlich, denn die systematischen Fehler, die der Mensch bei der Entscheidungsfindung macht, wurden und werden durch Experimente sowie jahrelange Forschung von Autoren aus vielen Bereichen und Strömungen nachgewiesen.

Auf diese Weise kann behauptet werden, dass in jedem Teil des Analyseprozesses, wofür ein Mensch zuständig ist, von einigen der kognitiven psychologischen Phänomene, die in der Abbildung 3 „THE COGNITIVE BIAS CODEX“ zu sehen sind, beeinflusst werden kann.

In der Abbildung 4 ist jedoch zu sehen, wie je nach durchgeführter Datenanalyse, entweder traditionell oder Data Mining, der Einfluss dieser Phänomene stark abweichen kann, da bei der traditionellen Datenanalyse der Mensch in alle Teile des Prozesses involviert ist, beim Data Mining hingegen nur in einige Teile des Prozesses.

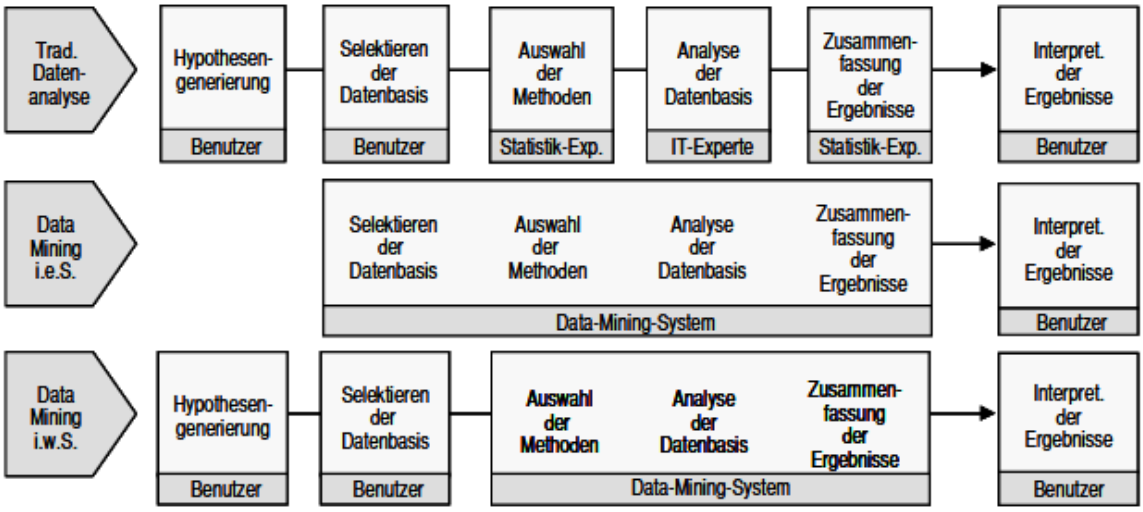

Abbildung 4: Traditionelle Datenanalyse und Data-Mining-Konzepte.[185]

[185] Kemper; Baars; Mehanna 2010, S. 114.

4. Analyse des Einflusses von kognitionspsychologischen Phänomenen anhand des Cross-Industry-Standard-Process-for-Data-Mining (CRISP-DM)-Vorgehensmodells

Aus Abbildung 4 ist ersichtlich, dass die meisten Phänomene im Moment der Interpretation der durch die Analyse generierten Ergebnisse auftreten. Diese Aussage reicht jedoch nicht aus, um den Einfluss kognitionspsychologischer Phänomene in dieser Hinsicht eindeutig nachzuweisen. Um den Einfluss kognitionspsychologischer Phänomene auf Business Analytics beweiskräftig darzustellen, wird im Folgenden jedes einzelne der 180 Phänomene anhand des in Abbildung 5 dargestellten Vorgehensmodells des Cross Industry Standard Process for Data Mining (CRISP-DM) analysiert. Dieser Schritt erfolgt, indem zuerst die Phasen des Vorgehensmodells und die dazugehörigen Aufgaben beschrieben werden. Als Nächstes werden die 180 Phänomene entsprechend der Beschreibung der einzelnen Aufgaben des Referenzmodells analysiert. Abschließend werden die Phänomene, die in jeder Aufgabe auftreten können, tabellarisch beschrieben und die Gründe oder die Folgen des Auftretens des Phänomens in dieser Aufgabe genannt.

CRISP-DM ist eine Methodologie, die ein Vorgehensmodell enthält, welches alle Schritte (sechs Phasen) beschreibt, die Experten bei der Durchführung eines Data-Mining-Projekts befolgen sollten.[186] Dieses Verfahren bietet wiederum ein Framework zur Strukturierung des Denkens über Datenanalyseprobleme, indem verschiedene Aspekte der Analytik hervorgehoben werden, die häufig bei der Entscheidungsfindung überschätzt werden. Darüber hinaus kontrastiert dieses Framework zum einen die Punkte, an denen menschliche Kreativität gefragt ist, und zum anderen die Punkte, an denen leistungsstarke analytische Werkzeuge eingesetzt werden können, um die beste Lösung für das jeweilige Problem oder Projekt zu erreichen.[187]

Es ist wichtig, klarzustellen, dass bei der Analyse dieser Phänomene davon ausgegangen wird, dass eine Arbeitsgruppe mit mehreren Mitgliedern eines Unternehmens gebildet wird, wobei diese nicht nur Data-Mining-Experten oder Datenanalysten sind, sondern auch aus anderen Abteilungen stammen können (Cross-Functional Teams). Die Begründung für die Entscheidung, eine Gruppe von Fachleuten aus verschiedenen Bereichen zu nehmen, ist, dass Data Mining zwar ausreichende Computerkenntnisse voraussetzt, zugleich aber auch Fähigkeiten erfordert, die unter Experten in diesem Bereich nicht üblich sind. Damit ein erfolgreiches Data-Mining-Projekt durchgeführt werden kann, werden Personen benötigt, welche die Fähigkeiten besitzen, Probleme präzise zu formulieren, Lösungen schnell zu prototypisieren, vernünftige Annahmen über Probleme zu treffen usw.[188] [189]

Es ist auch wichtig, zu erwähnen, dass es sich um eine allgemeine Analyse handelt, d. h., dass kein spezifisches Problem oder Projekt vorgestellt wird. Die Abbildungen, die in

[186] Vgl. European Simulation and Modelling Conference 2011, S. 4–5.
[187] Vgl. Provost; Fawcett 2013, S. 14–15.
[188] Vgl. Provost; Fawcett 2013, S. 35.
[189] Vgl. Euchner 2017, S. 15.

diesem Kapitel verwendet werden, wurden in englischer Sprache verfasst, da dies der Sprache der Originalquelle entspricht, aus der sie stammen.

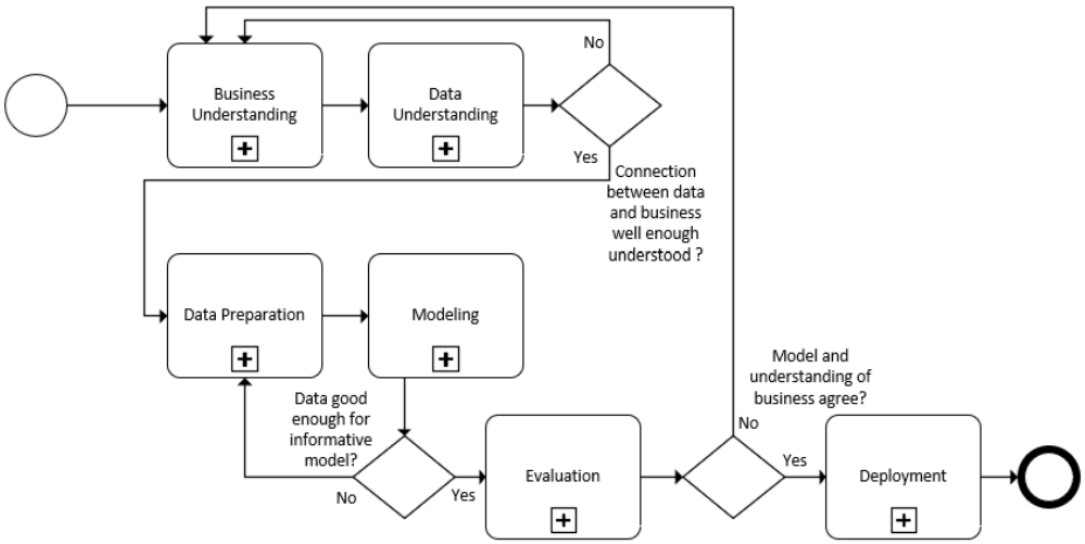

Abbildung 5: CRISP-DM Prozess.[190] In Anlehnung an Chapman et al. (2000)[191]

4.1 Business Understanding Phase

In dieser Phase des Prozesses geht es darum, das Problem bzw. den Bedarf des Unternehmens für ein Data-Mining-Projekt vollständig zu verstehen. Das Hauptziel ist, dass die Ziele des Data-Mining-Projekts und die Geschäftsziele in Übereinstimmung gebracht werden. In Abbildung 6 wird diese Phase mit den einzelnen Aufgaben dargestellt.[192] [193]

[190] Rothfuss 2021, S. 44.
[191] Chapman u. a. 2000, S. 10.
[192] Vgl. Chapman u. a. 2000, S. 10, 57–58.
[193] Vgl. Provost; Fawcett 2017, S. 53–54.

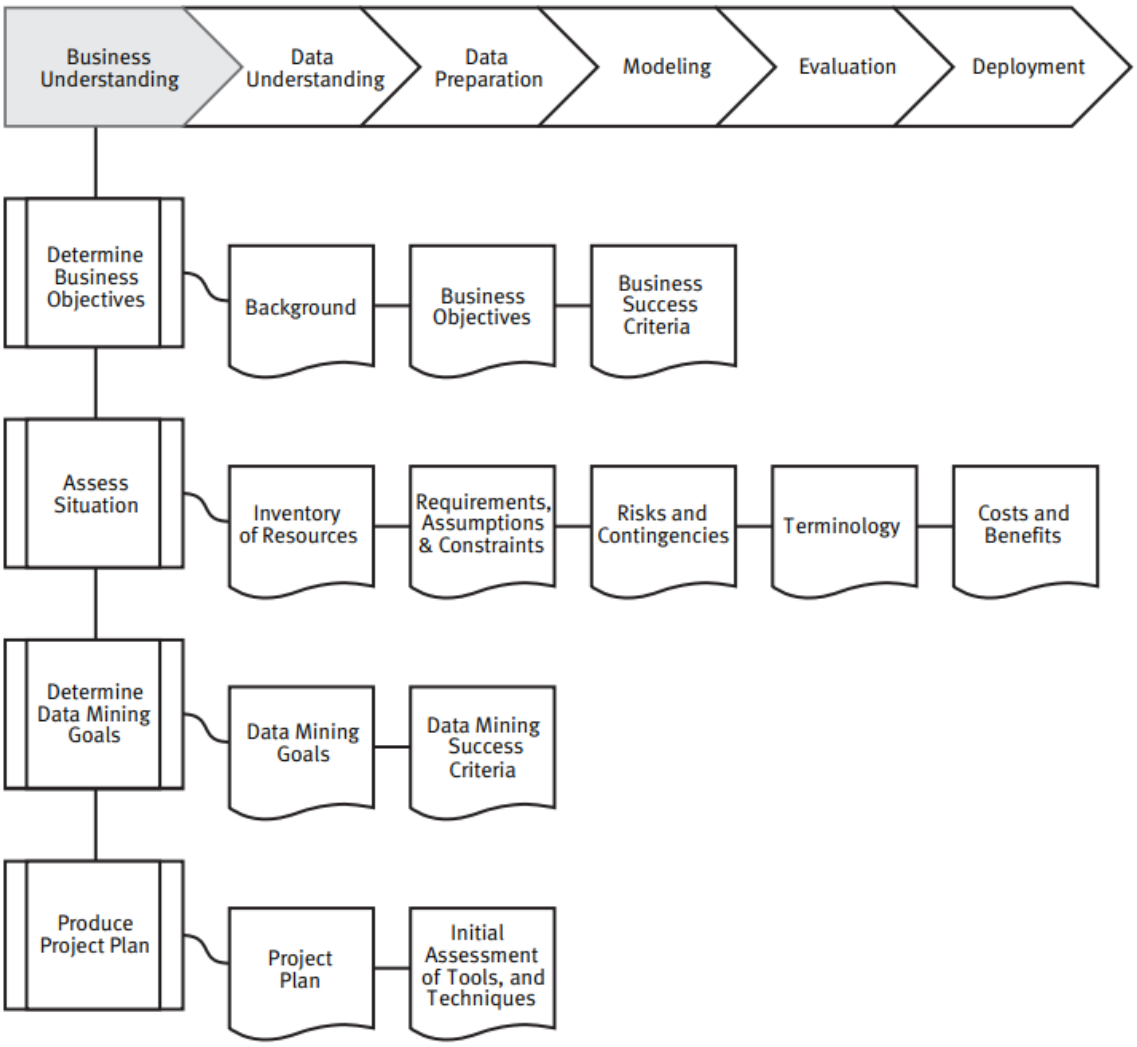

Abbildung 6: CRISP-DM Business Understanding Phase.[194]

4.1.1 Determine Business Objectives

Entscheidend ist das Verständnis dessen, das erreicht werden soll.[195] Dafür ist es notwendig, genügend Kenntnisse über das Unternehmen und die Branche zu besitzen, sowie jemanden zu haben, der sich mit den Methoden der Datenanalyse ausreichend auskennt.[196] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 1 dargestellt sind.

[194] Chapman u. a. 2000, S. 13.
[195] Vgl. Nettleton 2014, S. 7–9.
[196] Vgl. Chapman u. a. 2000, S. 14, 30–31.

Tabelle 1: Phänomene bei der Aufgabe Determine Business Objectives.[197]

Phänomen	**Begründung/Folgen**
Misinformation effect, False memory Cryptomnesia, Confabulation	Teammitglieder erinnern sich möglicherweise nur falsch oder verzerrt an ein Ereignis, wenn sie versuchen, eine Erinnerung hervorzurufen, die ihnen bei der Planung von Geschäftszielen helfen soll, wodurch es ihnen nicht möglich ist, Ziele auf der Grundlage der Realität zu setzen.
Law of Triviality & Bike-shedding effect	Fokussierung auf die trivialeren und einfacheren Fakten, anstatt die Ziele zu analysieren und zu adressieren, die mehr mit den Geschäftszielen übereinstimmen.
Information bias	Wichtig ist die Erkenntnis, dass genügend Wissen vorhanden sein muss, um die Ziele richtig zu definieren. Allerdings sollte nicht in die Informations bias verfallen werden, weil dadurch der Fokus verloren geht und keine brauchbaren Ziele formuliert werden können.
Belief bias	Es kann vorkommen, dass z. B. die Führungskraft oder ein Teammitglied wertvolle Informationen für die Definition des Problems ablehnt, weil diese Informationen seinen Überzeugungen widersprechen.
Status quo bias	Diese Verzerrung lässt sich widerspiegeln, wenn ein oder mehrere Teammitglieder die aktuelle Situation des Unternehmens nicht verändern wollen und daher alle Vorschläge als problematisch wahrnehmen. Diese Verzerrung kann wiederum dazu führen, dass bei diesen Teammitgliedern das Phänomen der **Reactance** auftritt, wenn z. B. der Vorgesetzte auf einem spezifischen Problem besteht und diese Mitglieder sich überredet und unter Druck gesetzt fühlen, dieses Projekt zu akzeptieren, obwohl es nicht mit ihren Überzeugungen oder Ideen übereinstimmt.
Backfire effect	Selbst wenn der Manager oder ein anderes Teammitglied konkrete Beweise zur Verteidigung der Problemstellung vorgelegt hat, kann es vorkommen, dass einige Teammitglieder diese Beweise ablehnen und eher der Meinung sind, dass die **Status-quo**-**Situation** viel besser und angenehmer ist und keine Veränderung notwendig ist.
Appeal to novelty & Pro-innovation bias	Hier geht es darum, zu glauben, dass eine der vorgeschlagenen Ideen die beste ist, da diese besonders modern und innovativ ist und aus diesem Grund vollständig funktionieren wird, selbst wenn ihre Verlässlichkeit bisher nicht bewertet wurde, was zur Folge hat, dass weniger innovative, aber für das Unternehmen geeignetere Ansätze beiseitegelassen werden.

[197] Einige Darstellung.

Phänomen	Begründung/Folgen
Not invented here	Obwohl diese Tendenz eher negativ verstanden wird, weil damit die Verweigerung gemeint ist, jede Art von Arbeit, Forschung, Produkt usw. aus einer externen Quelle zu verwenden, kann dies für den konkreten Fall der Bestimmung von Unternehmenszielen positiv betrachtet werden, denn um diese Ziele zu bestimmen, ist ein umfangreiches Wissen über das Unternehmen notwendig – und die meisten externen Akteure verfügen nicht über dieses Wissen und können Ziele bestimmen, die keine gültigen Argumente haben.
Outcome bias & Survivorship bias	Die Tendenz, Zielsetzungen anhand des Ergebnisses früherer Ereignisse zu bewerten, beeinträchtigt die Problemstellung negativ. So kann es z. B. problematisch sein, wenn gedacht wird, dass viele Unternehmen es geschafft haben, ihre Leistung durch soziale Netzwerke zu verbessern, jedoch nicht der Kontext berücksichtigt wird, in dem diese Ergebnisse erzielt wurden, was zu einer falschen Feststellung führt.
Hindsight bias	Dies hat viel mit der vorherigen Verzerrung zu tun, da die Teammitglieder dazu neigen, zu denken, dass sie vergangene Ereignisse richtig vorhergesagt hätten. Damit wird die sogenannte **Overconfidence bias** verstärkt und eine realistische Zielsetzung kann nicht richtig bestimmt werden.
Semmelweis reflex & Continued influence effect	Wenn eines der Teammitglieder dazu neigt, tief verwurzelte Überzeugungen oder Wissen zu haben, selbst dann, nachdem neue Beweise vorliegen, die seinem Wissen widersprechen, kann je nach Einfluss dieses Mitglieds in der Gruppe (Manager, Ingenieur, Datenanalyst) diese Person das Projekt zum Scheitern bringen.
Ambiguity bias	Teammitglieder können dazu neigen, das Projekt zu wählen, bei dem die Erfolgswahrscheinlichkeit bekannt ist, wenn sie sich zwischen mehreren Projekten entscheiden, ohne zu berücksichtigen, dass andere Projekte auf lange Sicht vorteilhafter sein können, auch wenn sie etwas riskanter sind, weil ihre Wahrscheinlichkeit nicht bekannt ist.

4.1.2 Assess Situation

Hierbei ist es notwendig, die Ressourcenverfügbarkeit und die Projektanforderungen zu ermitteln, Risiken und Eventualitäten zu bewerten sowie eine Kosten-Nutzen-Analyse durchzuführen.[198]

[198] Vgl. Chapman u. a. 2000, S. 14–15, 32–35.

Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 2 dargestellt sind.

Tabelle 2: Phänomene bei der Aufgabe Assess Situation.[199]

Phänomen	**Begründung/Folgen**
Serial position effect	Bei einer Kosten-Nutzen-Analyse besteht die Gefahr, dass sich bei der Erstellung einer Liste mit den Vor- und Nachteilen nur an den ersten und letzten Punkt erinnert wird. Daher ist es wichtig, dass sich die Teammitglieder ausreichend Zeit für diese Art der Analyse nehmen, insbesondere dann, wenn sie mit Listen arbeiten.
Peak-end rule	Wenn ein Projektmitglied gemischte Gefühle zu einem der Ansätze hat, wird es dazu neigen, dies auf der Basis seiner Gefühle zu verurteilen, anstatt die Erfahrungen abzuwägen. Wenn es sich z. B. positiv an ein früheres Projekt erinnert, weil es in diesem keine Eventualität gab, wird es dazu neigen, zu beurteilen, dass in diesem Projekt das Gleiche passieren wird, ohne zu berücksichtigen, dass es sich um völlig unterschiedliche Projekte handelt. Hinweis: Das Beispiel wurde mit der Assoziation von positiven Erinnerungen gegeben, da gemäß dem **Fading affect bias** Erinnerungen, die mit negativen Emotionen verbunden sind, schneller vergessen werden.
Social comparison bias	Es kommt vor, dass die Gruppenmitglieder, anstatt sich gegenseitig zu unterstützen, miteinander konkurrieren, was zur Folge hat, dass sie sich in der Bewertung der für diese Aufgabe festgelegten Kriterien (Ressourcen, Anforderungen, Risiken) nicht einig sind.
Zero-risk bias & Risk compensation	Diese Phänomene können bei der Aufgabe der Bewertung der Situation angewendet werden, denn bei der Bewertung der Risiken wird dazu geneigt, eine Option zu wählen, die 0 Prozent Risiko bietet, obwohl sie nicht die günstigste für das Projekt ist.
Loss aversion	Verwerfen eines Projekts, weil es als risikoreicher als die anderen angesehen wird und deshalb Geld verloren werden kann, obwohl die Belohnung viel höher sein könnte als bei den sicheren Projekten.
Hyperbolic discounting	Dies geschieht in dem Moment, in dem die Ziele bewertet werden und diejenigen bevorzugt werden, bei denen der Nutzen in kürzester Zeit erreicht wird, und nicht diejenigen, die mehr Ergebnisse in der Zukunft bringen.
Overconfidence effect	Die Teammitglieder sind möglicherweise so zuversichtlich, dass sie vergessen, die tatsächlichen Erfolgschancen des Projekts angemessen zu bewerten.

[199] Einige Darstellung.

Phänomen	Begründung/Folgen
In-group bias & Halo effect	Eine Bevorzugung in der Gruppe kann sich positiv auf die Zuteilung von Ressourcen an scheinbar sympathischere Mitglieder der Gruppe auswirken, unabhängig davon, ob die Abteilung, der dieses oder diese Mitglieder angehören, weit weniger Ressourcen benötigt als andere.
Conjunction fallacy	Dies kann vorkommen, wenn die Problemstellung nicht ein einzelnes Ziel, sondern mehrere Ziele verfolgt, und die Teammitglieder an die Möglichkeit glauben, dass alle Ziele erreicht werden. Dies ist problematisch, da es sehr schwierig sein wird, die Kosten und den Nutzen dieser Ziele zu bewerten. Außerdem kann es passieren, dass die Mitglieder, weil sie fest an die Möglichkeit glauben, dass die Ziele erreicht werden, keinen Notfallplan erstellen.

4.1.3 Determine Data Mining Goals

Neben der Definition der Geschäftsziele muss auch festgelegt werden, wie der Erfolg aus technischer Data-Mining-Perspektive aussieht.[200] Das Unternehmensziel könnte zum Beispiel lauten: „Steigerung der Katalogverkäufe an bestehende Kunden." Das Data-Mining-Ziel könnte lauten: „Vorhersagen, wie viele Widgets ein Kunde kaufen wird, wenn man seine Einkäufe der letzten drei Jahre, demografische Informationen (Alter, Gehalt, Stadt usw.) und den Preis des Artikels berücksichtigt."[201]

Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in der Aufgabe „Determine Business Objectives" thematisiert wurden, denn in beiden Aufgaben geht es darum, Ziele zu bestimmen. Es ändert sich nur der zu bestimmende Gegenstand dieser Ziele. Neben diesen oben geplanten Phänomenen wurden jedoch weitere Phänomene identifiziert, die in Tabelle 3 dargestellt sind.

Tabelle 3: Phänomene bei der Aufgabe Determine Data Mining Goals.[202]

Phänomen	Begründung/Folgen
Memory inhibition	Die positive Seite dieses Phänomens ist, dass es den Teammitgliedern erlaubt, sich nicht an irrelevante Informationen zu erinnern, wobei das Problem darin besteht, dass es sehr relativ ist, was jeder von ihnen für wichtig hält, um die Data-Mining-Ziele zu bestimmen.
Overconfidence effect	Zu dieser Aufgabe gehört es auch, die erwarteten Ergebnisse zu definieren, die das Erreichen der Ziele ermöglichen. Aus diesem Grund sollten die Teammitglieder nicht in diesen Effekt verfallen und blind darauf vertrauen, dass das Projekt erfolgreich sein wird.

[200] Vgl. Chapman u. a. 2000, S. 16, 35–36.
[201] Chapman u. a. 2000, S. 16.
[202] Einige Darstellung.

4.1.4 Produce Project Plan

An dieser Stelle geht es um die Beschreibung des Plans zum Erreichen der Data-Mining-Ziele und damit der Geschäftsziele. Im Plan sollten die Schritte festgelegt werden, die im weiteren Verlauf des Projekts zu erledigen sind, inklusive der Auswahl der ersten Tools und Methoden.[203] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 4 dargestellt sind.

Tabelle 4: Phänomene bei der Aufgabe Produce Project Plan.[204]

Phänomen	**Begründung/Folgen**
Illusion of control	Die Erstellung eines Planes mit Überschätzung der Ereignisse, die eintreten können, ohne diese sorgfältig bewertet zu haben, führt dazu, dass dieser Plan fehlerhaft ist.
Optimism effect	Wenn die Gruppenmitglieder glauben, dass ein negatives Ereignis während des Projekts weniger wahrscheinlich ist und folglich kein Alternativplan definiert wird, wenn irgendetwas schief geht.
Normalcy bias	Diese Verzerrung hängt stark mit den beiden oben genannten zusammen, da Menschen dazu neigen, Warnungen vor einer Bedrohung wie einem Marktzusammenbruch zu ignorieren, was dazu führt, dass Notfallpläne nicht ausreichend vorbereitet sind und die Planung im Falle eines unerwarteten Ereignisses scheitert.
Dunning-Kruger effect & Lake Wobegone effect	Bei der Erstellung eines Plans werden Aufgaben eingeteilt und möglicherweise überschätzen einige Mitglieder der Gruppe ihre Fähigkeiten, wodurch die Entwicklung des gesamten Projekts gefährdet wird. Diese Verzerrung kann auch als Folge des Hard-easy effect auftreten, da diese Teammitglieder in vielen Fällen unbewusst die Erfolgswahrscheinlichkeit dieses Projekts, das einen hohen Grad an Komplexität aufweist, überschätzen.
Hot hand fallacy	Wenn die Mitglieder der Gruppe denken, dass dieses Projekt auch gut laufen wird, weil die vorherigen Projekte gut gelaufen sind, kann es vorkommen, dass sie die Planung nicht ernst nehmen und keinen guten Plan erstellen können.
Planning fallacy	Dies bezieht sich darauf, dass die Zeit, die zur Erledigung der Aufgaben jeder Phase benötigt wird, nicht korrekt bestimmt werden kann, weil die Teammitglieder in den meisten Fällen eine Neigung zu Optimismus und Zuversicht zeigen.
Pessimism bias	Es kann auch passieren, dass die Teammitglieder die Eintrittswahrscheinlichkeit negativer Ereignisse überschätzen, so dass die Planung, wie im vorherigen Fall, fehlerhaft ausfällt.

[203] Vgl. Chapman u. a. 2000, S. 16–17, 36–37.
[204] Einige Darstellung.

Phänomen	Begründung/Folgen
Recency effect	Überlegungen zur Lösung kürzlich eingetretener Ereignisse, anstatt die Ziele des Unternehmens richtig einzuschätzen und ein Projekt entsprechend zu planen.
Not invented here	Wenn die Mitglieder dazu neigen, nichts Externes zu wollen, kann es sein, dass sie kein geeignetes Werkzeug für dieses Projekt auswählen – infolgedessen wird das Data Mining nicht richtig durchgeführt.
Outcome bias	In diesem Fall besteht die Neigung, die Techniken und die Werkzeuge auf der Grundlage der Ergebnisse früherer Projekte auszuwählen, was zur Folge hat, dass die Werkzeuge in dieser Phase nicht planmäßig ausgewählt werden und es in den späteren Phasen viele Probleme bei der Durchführung von Data Mining gibt.

4.1.5 Darstellung der Phänomene bei der Business Understanding Phase

Um die Analyse zu überschaubar zu gestalten, wurden die Ergebnisse der Phänomene in den einzelnen Aufgaben der Phase „Business Understanding“ in Abbildung 7 zusammengefasst.

Business Understanding			
Determine Business Objectives			
Too Much Information: - Semmelweis reflex - Continued influence effect	**Not Enough Meaning:** - Confabulation - Pro-innovation bias - Appeal to novelty - Not invented here - Outcome bias - Survivorship bias - Hindsight bias	**Need to Act Fast:** - False memory - Law of Triviality - Bike-shedding effect - Information bias - Belief bias - Status quo bias - Backfire effect - Ambiguity bias	**What Should We Remember?** - Misinformation effect - Cryptomnesia
Assess Situation			
	- In-group bias & Halo effect - Conjunction fallacy	- Conjunction fallacy - Serial position effect - Peak-end rule - Social comparison bias - Zero-risk bias & Risk compensation - Loss aversion - Hyperbolic discounting -Overconfidence effect	- Serial position effect - Peak-end rule
Determine Data Mining Goals			
		-Overconfidence effect	-Memory inhibition
Produce Project Plan			
	-Normalcy bias -Hot hand fallacy -Planning fallacy -Pessimism bias -Not invented here -Outcome bias	-Illusion of control -Optimism effect -Dunning-Kruger effect -Lake Wobegone effect	-Recency effect

Abbildung 7: Kognitionspsychologische Phänomene bei der Business Understanding Phase.[205]

[205] Einige Darstellung.

4.2 Data Understanding Phase

Diese Phase bestimmt den Ansatz zur Identifizierung, Sammlung und Analyse der Datensätze, die zur Erreichung der Projektziele benötigt werden. Es geht darum, die Problemdaten zu kennen, indem die Qualität der Daten ermittelt wird und letztere in einen Zusammenhang gebracht werden, sodass einige erste Hypothesen aufgestellt werden können. Es ist wichtig, den ETL-Transformationsprozess zu berücksichtigen, damit das Data Mining die gewünschten Ergebnisse liefern kann.[206] [207]

Die Aufgaben, aus denen diese Phase besteht, sind in Abbildung 8 zu erkennen.

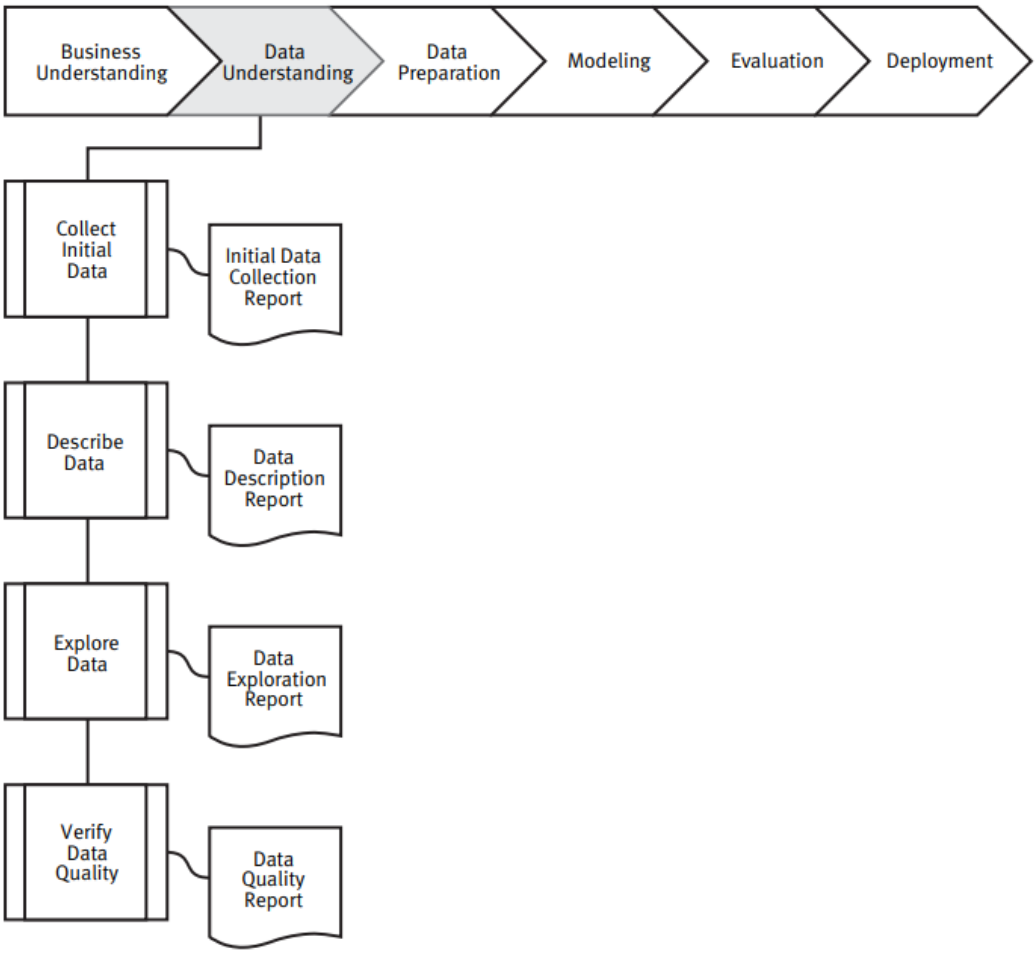

Abbildung 8: CRISP-DM Data Understanding Phase.[208]

Es ist auch zu erkennen, dass die Aufgaben in dieser Phase darauf abzielen, Berichte zu erstellen. Bei dieser Erstellung können Phänomene auftreten, die in Tabelle 5 dargestellt sind. Da diese Phänomene nicht aufgabenspezifisch sind, sondern immer auftreten

[206] Vgl. Chapman u. a. 2000, S. 10, 58–59.
[207] Vgl. Provost; Fawcett 2017, S. 54–55.
[208] Chapman u. a. 2000, S. 17.

können, wenn ein Bericht erstellt wird, werden sie nur in dieser Tabelle 5 gezeigt, jedoch nicht in allen Aufgaben dieser Phase wiederholt.

Tabelle 5: Phänomene bei der Erstellung von Berichten.[209]

Phänomen	**Begründung/Folgen**
Anecdotal fallacy	Dieses Phänomen tritt auf, weil der Bericht möglicherweise keine sachlichen Informationen enthält, sondern nur die persönlichen Meinungen der Mitglieder.
Negativity bias	Möglicherweise neigen Mitglieder dazu, bei der Ausführung einer Aufgabe negative Ereignisse zu beschreiben und positive Ereignisse zu ignorieren.
Selective perception	Es ist möglich, dass Mitglieder dazu neigen, Informationen zu ignorieren, die nicht mit ihren Erwartungen oder Überzeugungen übereinstimmen, so dass diese Berichte unvollständig sind und es sehr schwierig sein wird, nach den ausgelassenen Informationen zu suchen, falls diese in Zukunft benötigt werden.
Self-consistency bias	Bei dieser Verzerrung kann der Inhalt von Erinnerungen verfälscht werden, so dass Berichte möglicherweise nicht wahrheitsgemäß beschrieben werden.
Curse of knowledge	Je nachdem, wer den Bericht schreibt, beschreibt er vielleicht nicht alle Informationen, die für andere zum Verständnis notwendig sind, weil der Verfasser glaubt, dass andere das gleiche Wissen haben und es verstehen werden. Dies führt zu Berichten, die von den anderen Mitgliedern der Gruppe nicht verwendet werden können.
Confirmation bias	Es kann vorkommen, dass Teammitglieder in ihre Berichte nur die Informationen schreiben, die das bestätigen, was sie in jeder Phase zu finden glaubten. Dies führt zu nicht immer objektiven Berichten.
Framing effect	Bei der Darstellung von Informationen in einem Bericht sollte berücksichtigt werden, dass die Art, wie diese Informationen präsentiert werden, die Wahrnehmung der einzelnen geplanten Optionen beeinflusst, sodass die Beurteilung des Lesers davon abhängt, ob die Optionen getrennt voneinander dargestellt werden oder nicht.

4.2.1 Collect Initial Data

Das Ziel lautet, die ersten Daten zu sammeln und diese für eine zukünftige Verarbeitung anzupassen. Wichtig ist es, die notwendigen Daten (aus verschiedenen Quellen) zu beschaffen und diese gegebenenfalls in das jeweilige Analysetool zu laden.[210] [211] Bei der

[209] Einige Darstellung.
[210] Vgl. Chapman u. a. 2000, S. 18, 37–39.
[211] Vgl. Zhang 2017, S. 14–15.

Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 6 dargestellt sind.

Tabelle 6: Phänomene bei der Aufgabe Collect Initial Data.[212]

Phänomen	**Begründung/Folgen**
Overconfidence effect	Es kann vorkommen, dass die Teammitglieder bei der Suche nach Daten oder der Auswahl der Datenquellen, die für die Durchführung des Projekts benötigt werden, darauf vertrauen, dass die verfügbaren internen Daten ausreichen, um das Projekt ausarbeiten zu können, und nicht bewusst prüfen, ob es notwendig ist, externe Quellen zu nutzen.
Not invented here	Es kann vorkommen, dass einige Mitglieder dazu neigen, externe Quellen abzulehnen, ohne vorher zu analysieren, ob sie für den Erfolg des Projekts notwendig sind. Außerdem werden sie möglicherweise Data-Mining-Tools ablehnen, die aus externen Quellen stammen oder die sie nicht sehr gut kennen – und somit eine verzerrte Entscheidung über das beste Tool für das Problem treffen.
Moral credential effect	Es ist möglich, dass die Mitglieder in ihrem Wunsch, die für das Projekt benötigten Daten zu erhalten, Quellen auf dem sogenannten schwarzen Markt wählen, die den Datenschutz von Personen nicht respektieren.
Social desirability bias	Bei der Durchführung von Umfragen zur Datenerfassung gilt es immer zu bedenken, dass die Befragten wahrscheinlich nicht wahrheitsgemäß antworten werden, sondern eher so, dass andere die Antworten als akzeptabel ansehen.
Insensitivity to sample size	Die Missachtung des Stichprobenumfangs kann sich negativ auf die durchgeführten Statistiken auswirken.
Experimenter's bias & Observer effect & Expectation bias	Bei der Durchführung von Experimenten zur Erhebung von Ausgangsdaten sollten diese Verzerrungen berücksichtigt werden, weil sie Einfluss auf die Handlungen haben, die der Forscher von den Untersuchungsteilnehmern erwartet, und daher zu Ergebnissen führen, die einerseits eindeutig mit den Hypothesen übereinstimmen, andererseits aber völlig verzerrt sind.

4.2.2 Describe Data

Hier ist es erforderlich, die Daten zu untersuchen und ihre Roh- bzw. Oberflächeneigenschaften zu dokumentieren. Darüber hinaus ist es wichtig, zu beurteilen, ob die erfassten Daten den jeweiligen Anforderungen entsprechen. In den meisten Fällen werden die Daten in einem Data Warehouse gespeichert, wodurch diese Aufgabe für die Projektmitglieder sehr erleichtert wird, denn in diesem Fall müssten diese nur das Schema

[212] Einige Darstellung.

der Datenbanken identifizieren, wobei jede der Tabellen und ihre Attribute genau beschrieben werden sollten. Das bedeutet, dass die Gruppenmitglieder nur die Informationen beschreiben und analysieren sollen, die das Data Warehouse liefert.[213] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomenen zu verfallen, die in Tabelle 7 dargestellt sind.

Tabelle 7: Phänomene bei der Aufgabe Describe Data.[214]

Phänomen	**Begründung/Folgen**
Automation bias	Großes Vertrauen in die vom Data Warehouse bereitgestellten Daten und keine Überprüfung, ob diese für das Projekt ausreichend sind.
Law of Triviality	Es kann vorkommen, dass sich die Analysten bei der Beschreibung der Informationen des Data Warehouse nur auf die Informationen konzentrieren, die das System ausliefert. Dabei lassen sie jedoch die Analyse beiseite, die an diesen Daten vorgenommen werden muss, um zu überprüfen, ob sie die Anforderungen des Projekts erfüllen oder nicht.

4.2.3 Explore Data

An diesem Punkt ist es notwendig, tiefer in die Daten einzudringen. Dazu ist es erforderlich, das Thema Data Mining mit Hilfe von Abfrage-, Visualisierungs- und Berichtstechniken anzugehen. Dazu gehören die Verteilung von Schlüsselattributen, die Beziehungen zwischen Paaren oder kleinen Mengen von Attributen, die Ergebnisse einfacher Aggregationen, die Eigenschaften signifikanter Teilmengen sowie einfache statistische Analysen. Dadurch ist es möglich, bereits erste Schlussfolgerungen oder Hypothesen und deren Auswirkungen auf den weiteren Projektverlauf zu ziehen.[215] [216]

Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 8 dargestellt sind.

Tabelle 8: Phänomene bei der Aufgabe Explore Data.[217]

Phänomen	**Begründung/Folgen**
Pseudocertainty effect	Bei der Bestimmung einiger Schlussfolgerungen oder Hypothesen kann das Ergebnis im Voraus als sicher angesehen werden, obwohl es in Wirklichkeit nicht geprüft wurde und daher unsicher ist.
Clustering illusion	Bei einer sehr eingeschränkten Stichprobe wird dazu geneigt, Muster zu sehen, die nicht existieren. Aus diesem Grund ist es notwendig, umfangreiche Stichproben von Daten zu nehmen und

[213] Vgl. Chapman u. a. 2000, S. 18, 39–40.
[214] Einige Darstellung.
[215] Vgl. Chapman u. a. 2000, S. 18–19.
[216] Vgl. Chapman u. a. 2000, S. 18–19, 40.
[217] Einige Darstellung.

Phänomen	Begründung/Folgen
	dabei sehr gut zu analysieren, ob eine Gruppierung angemessen ist oder nicht.
Frequency illusion & Baader-Meinhof Phenomenon	Manche Teammitglieder können in diese Phänomene verfallen, indem sie glauben, etwas Relevantes in den Daten bemerkt zu haben, und annehmen, dass sich dies mit hoher Häufigkeit wiederholt.
Picture superiority effect	Es ist wichtig, Visualisierungsmethoden zu verwenden, weil das menschliche Gedächtnis sehr empfindlich auf die Darstellung von Informationen in einer grafischen Form reagiert und sich die Gruppenmitglieder daher tendenziell besser an die dargestellten Informationen erinnern werden.
Congruence bias	Der Wunsch, anfängliche Hypothesen zu beweisen, kann dazu führen, dass die Daten nicht ausreichend untersucht werden, so dass diese die anfängliche Überzeugung nicht widerlegen können.

4.2.4 Verify Data Quality

Es ist notwendig, die Datenqualität zu bestimmen und möglicherweise aufgetretene Qualitätsprobleme zu dokumentieren. Hierbei ist es auch wichtig, die Kosten für die Beschaffung und Bereinigung dieser Daten zu berücksichtigen.[218]

Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 9 dargestellt sind.

Tabelle 9: Phänomene bei der Aufgabe Verify Data Quality.[219]

Phänomen	Begründung/Folgen
Mental accounting	Dieses Phänomen kann die Entscheidungen der Gruppe bei der Abrechnung der Ausgaben beeinflussen, und zwar sowohl bei der Beschaffung als auch bei der Bereinigung der Daten.
Automation bias	Teammitglieder neigen dazu, sich zu sehr auf Daten zu verlassen, die automatisch generiert wurden, z. B. durch ein Programm, das Skripte zum Einfügen von Daten erstellt, ohne deren Gültigkeit zu überprüfen.
Overconfidence effect	Die Teammitglieder neigen dazu, sich ganz darauf zu verlassen, dass nach der Explorations-Aufgabe die Daten vollständig sind, ohne sie noch einmal zu überprüfen. Das heißt, dass sie sich auf die Arbeit der vorherigen Phasen blind verlassen und sich nicht fragen, ob bei der Durchführung der vorherigen Aufgaben nicht doch Fehler entstanden sind.
Attentional bias	Es kann vorkommen, dass Teammitglieder Daten mit Nullwerten nicht ernst nehmen, weil sie darauf fokussiert sind, die Daten so

[218] Vgl. Chapman u. a. 2000, S. 19, 41–42.
[219] Einige Darstellung.

Phänomen	Begründung/Folgen
	schnell wie möglich zu beschreiben, sodass diese Daten ein Problem für zukünftige Phasen des Projekts darstellen können.

4.2.5 Darstellung der Phänomene bei der Data Understanding Phase

Um die Analyse zu überschaubar zu gestalten, wurden die Ergebnisse der Phänomene in den einzelnen Aufgaben der Phase „Data Understanding“ in Abbildung 9 zusammengefasst.

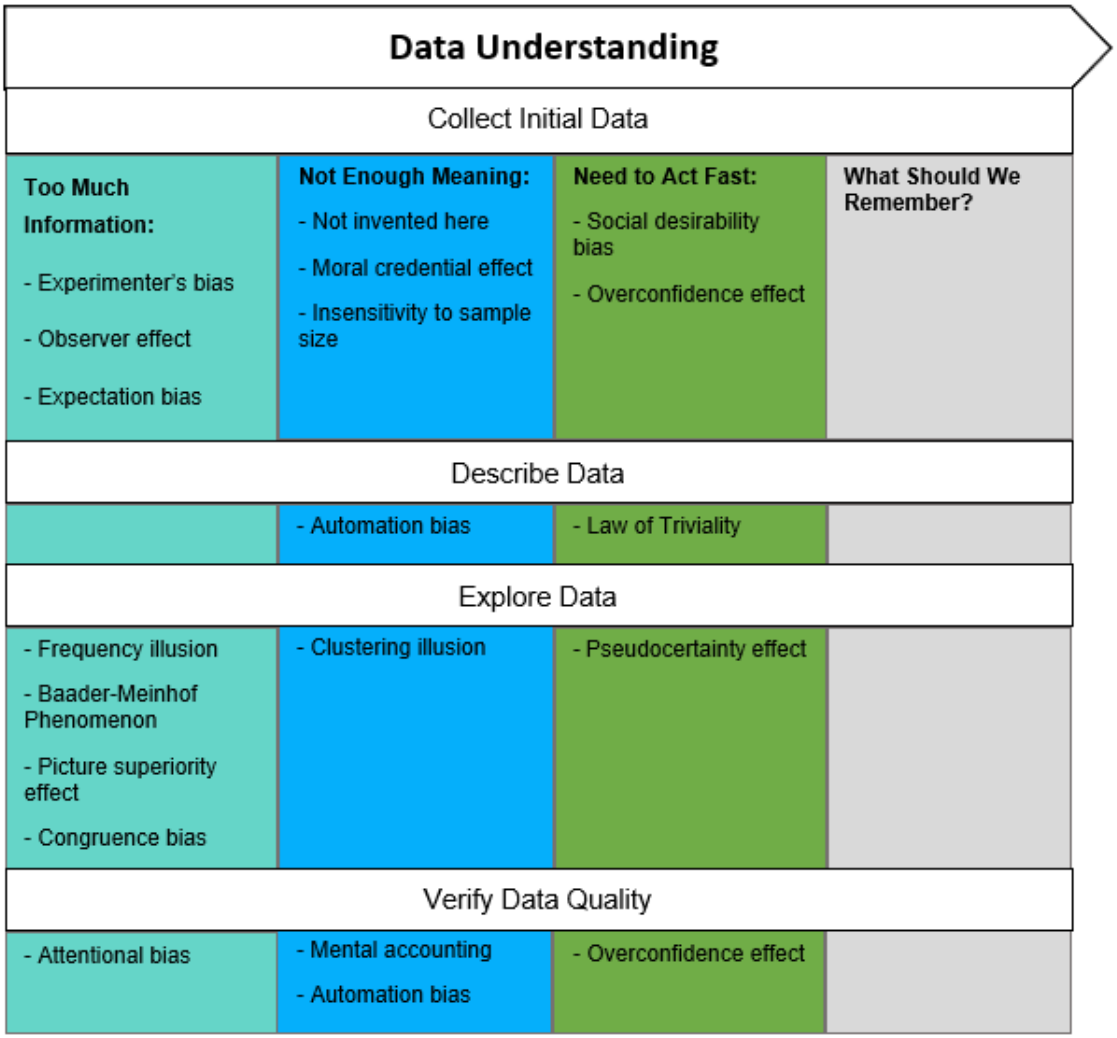

Abbildung 9: Kognitionspsychologische Phänomene bei der Data Understanding Phase.[220]

[220] Einige Darstellung.

4.3 Data Preparation Phase

In dieser Phase werden die endgültigen Datensätze für die Modellierung vorbereitet. Da je nach gewählter Modellierungstechnik die Daten auf die eine oder andere Weise bearbeitet werden müssen, stehen diese Phase und die Modellierungsphase in ständiger Interaktion.[221] [222]

Es ist wichtig, zu erwähnen, dass je nach verwendetem Data-Mining-System alle Aufgaben dieser Phase und der Modellierungsphase automatisch durchgeführt werden können. Das bedeutet, dass die Beteiligung der Teammitglieder in diesen Phasen minimal ist. Daher ist das psychologische Phänomen die „Automation bias“, welche in dieser Phase überwiegen würde, denn Teammitglieder neigen dazu, sich zu sehr auf die Ergebnisse der einzelnen Aufgaben zu verlassen, ohne diese Informationen zu hinterfragen.[223] [224] Die Aufgaben dieser Phase sind in Abbildung 10 zu erkennen.

[221] Vgl. Chapman u. a. 2000, S. 11, 60.
[222] Vgl. Dietrich u. a. 2015, S. 36.
[223] Vgl. Lyell; Coiera 2017, S. 425–426.
[224] Vgl. Wickens u. a. 2015, S. 728–729.

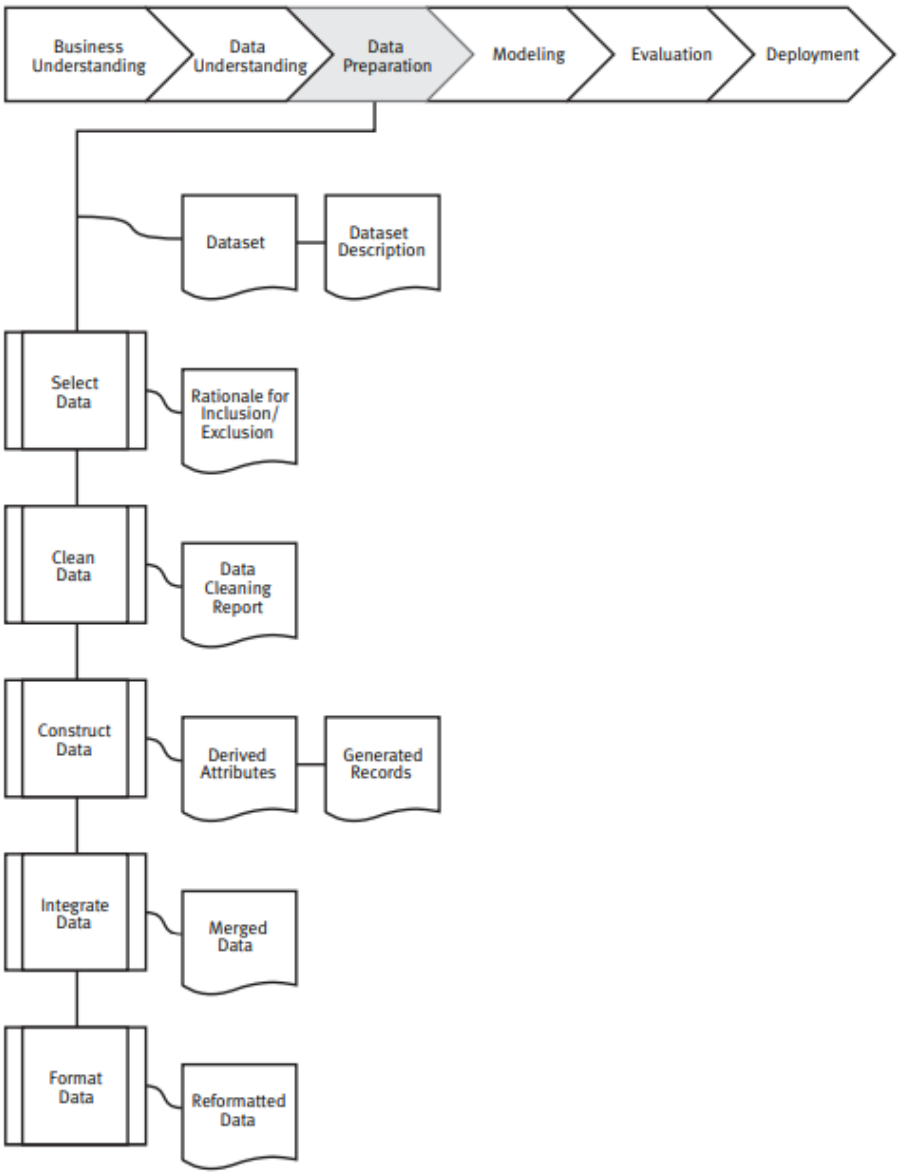

Abbildung 10: CRISP-DM Data Preparation Phase.[225]

4.3.1 Select Data

Es ist an dieser Stelle notwendig, festzulegen, welche Datensätze für die Analyse verwendet werden, und die Gründe für den Einschluss oder Ausschluss dieser Datensätze zu dokumentieren.[226] Wenn diese Tätigkeit manuell durchgeführt wird, können die in Tabelle 10 genannten kognitiven Verzerrungen auftreten.

[225] Chapman u. a. 2000, S. 20.
[226] Vgl. Chapman u. a. 2000, S. 21, 42–43.

Tabelle 10: Phänomene bei der Aufgabe Select Data.[227]

Phänomen	Begründung/Folgen
Belief bias	Bei der Auswahl der zu verwendenden Datensätze lassen sich die Gruppenmitglieder möglicherweise von dem beeinflussen, was sie für das Projekt für optimal halten, statt von dem, was für das Projekt am sinnvollsten ist.
Absent-mindedness	Es ist möglich, dass die Teammitglieder bei der Durchführung dieser Aufgabe zerstreut sind und infolgedessen Datensätze übersehen werden, die nicht notwendig sind und zu Komplikationen zum Zeitpunkt der Analyse führen können. Andererseits kann auch das Gegenteil passieren und es werden möglicherweise Datensätze gelöscht, die für eine gute Analyse notwendig waren.

4.3.2 Clean Data

Erhöhung der Datenqualität auf das Niveau, das für die gewählten Analyseverfahren erforderlich ist. Dies kann die Auswahl sauberer Teilmengen der Daten, das Einfügen geeigneter Standardwerte oder anspruchsvollere Techniken wie die Schätzung fehlender Daten durch Modellierung beinhalten.[228]

Viele dieser Punkte können vom Data-Mining-Tool automatisch ausgearbeitet werden. Es ist jedoch essenziell, die vom System bereitgestellten Informationen vor der Verwendung zu überprüfen, um sicherzustellen, dass alles ordnungsgemäß abgelaufen ist. In der Tabelle 11 ist ein mögliches Phänomen dargestellt, das in dieser Aufgabe auftreten kann.

Tabelle 11: Phänomene bei der Aufgabe Clean Data.[229]

Phänomen	Begründung/Folgen
Functional fixedness	Es kann vorkommen, dass die Mitglieder der Gruppe nur traditionelle Techniken verwenden und nicht die erwarteten Ergebnisse erzielen, weil sie nicht in der Lage sind, Techniken auf eine innovative Art zu verwenden, die es ihnen ermöglicht, das Problem auf eine bessere Weise zu lösen.

[227] Einige Darstellung.
[228] Vgl. Chapman u. a. 2000, S. 21, 43–44.
[229] Einige Darstellung.

4.3.3 Construct Data

Dies ist gedacht für konstruktive Datenaufbereitungsoperationen, z. B. das Erzeugen abgeleiteter Attribute, komplett neuer Datensätze oder transformierter Werte für vorhandene Attribute. Beispielsweise lässt sich der Body-Mass-Index einer Person aus den Feldern Größe und Gewicht ableiten. So gelingt es, völlig neue Datensätze zu erstellen, die bei der Modellierung helfen können.[230] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 12 dargestellt sind.

Tabelle 12: Phänomene bei der Aufgabe Construct Data.[231]

Phänomen	**Begründung/Folgen**
Essentialism	Ein positiver Einfluss dieses Phänomens kann hier gesehen werden, da es durch die Berücksichtigung der Überzeugung, dass alle Objekte einen Satz von Attributen haben, die zum Verständnis ihrer Identität notwendig sind, möglich ist, diese Attribute zu kombinieren, um neue Datensätze zu erstellen.
Context effect	Abhängig davon, ob eine Datenbank vollständig ist oder nicht, besteht die Notwendigkeit, weitere Attribute zu erstellen. Dabei sollte man allerdings immer auch den Kontext berücksichtigen und keine Attribute erzeugen, die keinen Bezug zum Ziel des Projekts haben.

4.3.4 Integrate Data

Es geht darum, neue Datensätze zu erstellen, indem Informationen aus mehreren Tabellen oder Datensätzen kombiniert werden, um neue Datensätze oder Werte zu kreieren.[232] In der Tabelle 13 ist ein mögliches Phänomen dargestellt, das in dieser Aufgabe auftreten kann.

[230] Vgl. Chapman u. a. 2000, S. 21–22, 44–45.
[231] Einige Darstellung.
[232] Vgl. Chapman u. a. 2000, S. 22, 46.

Tabelle 13: Phänomene bei der Aufgabe Integrate Data.[233]

Phänomen	Begründung/Folgen
Context effect	Die meisten Data-Mining-Programme übernehmen das automatische Anlegen neuer Strukturen und das Zusammenführen zwischen verschiedenen Datenbanktabellen, wobei es notwendig ist, dass die Teammitglieder die Gültigkeit der vom Programm gelieferten Informationen in Bezug auf den Kontext des Projektes überprüfen müssen.

4.3.5 Format Data

Formatierungstransformationen beziehen sich hauptsächlich auf syntaktische Änderungen an den Daten, die deren Bedeutung nicht verändern, allerdings vom Modellierungswerkzeug benötigt werden können.[234] In der Tabelle 14 ist ein mögliches Phänomen dargestellt, das in dieser Aufgabe auftreten kann.

Tabelle 14: Phänomene bei der Aufgabe Format Data.[235]

Phänomen	Begründung/Folgen
Absent-mindedness	Es ist möglich, dass Teammitglieder aufgrund ihrer Zerstreutheit Änderungen vornehmen, die die Bedeutung der Daten verändern. Dies führt dann zu Problemen oder Verzögerungen im Projekt.

4.3.6 Darstellung der Phänomene bei der Data Preparation Phase

Um die Analyse zu überschaubar zu gestalten, wurden die Ergebnisse der Phänomene in den einzelnen Aufgaben der Phase „Data Preparation“ in Abbildung 11 zusammengefasst.

[233] Einige Darstellung.
[234] Vgl. Chapman u. a. 2000, S. 22–23, 46–47.
[235] Einige Darstellung.

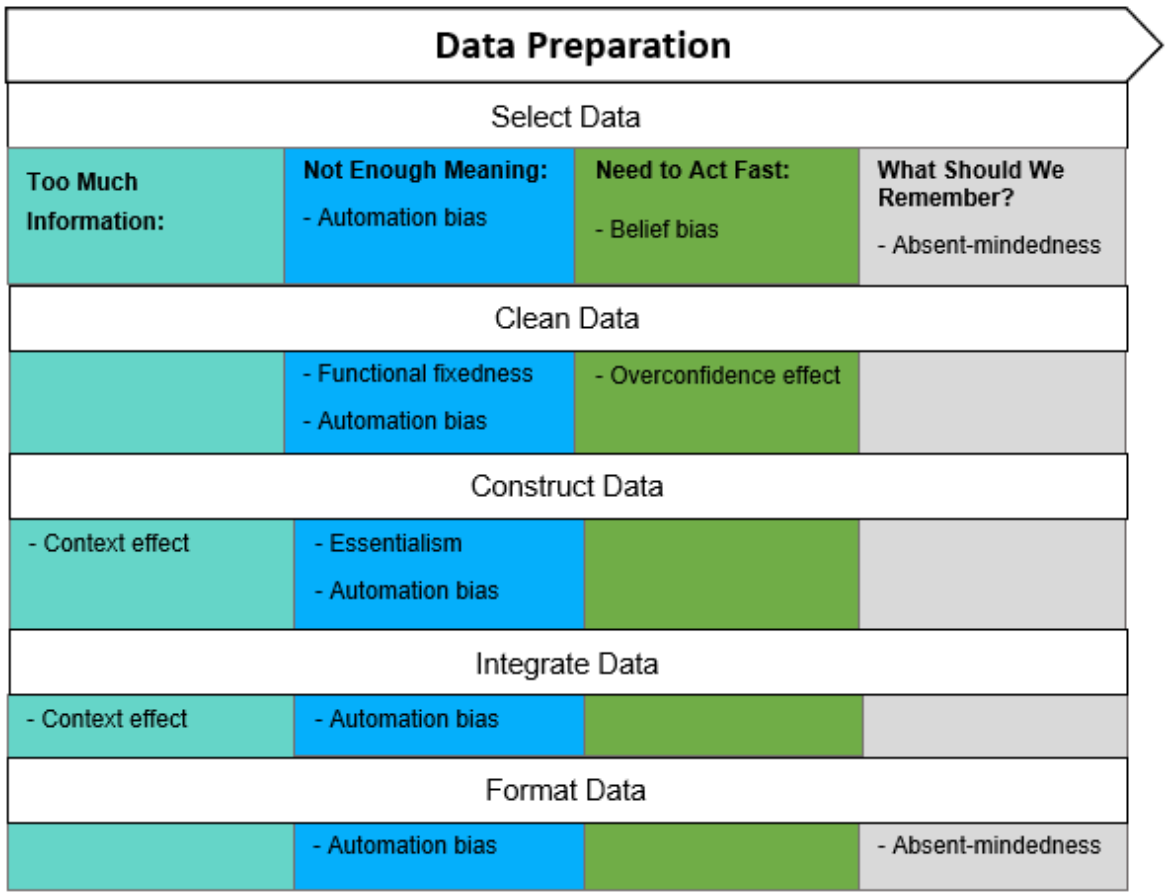

Abbildung 11: Kognitionspsychologische Phänomene bei der Data Preparation Phase.[236]

4.4 Modeling Phase

Hierbei werden mehrere Modelle auf Basis unterschiedlicher Modellierungstechniken erstellt und ausgewertet. Je nach den Anforderungen an die Datenformen einer bestimmten Technik kann es erforderlich sein, zur „Data Preparation“ Phase zurückzukehren.[237] Die Aufgaben dieser Phase sind in Abbildung 12 zu erkennen.

[236] Einige Darstellung.
[237] Vgl. Chapman u. a. 2000, S. 11, 60–61.

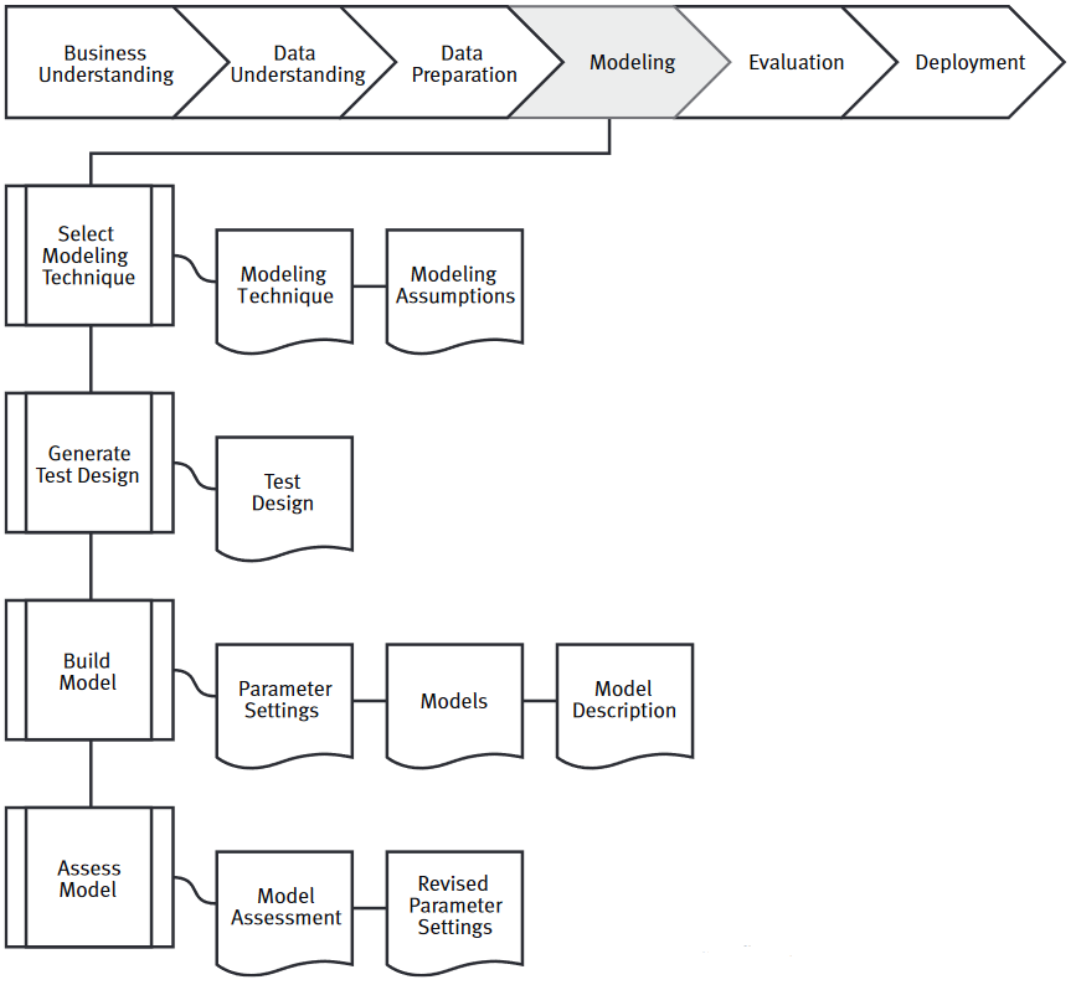

Abbildung 12: CRISP-DM Modeling Phase.[238]

4.4.1 Select modeling technique

Dabei geht es um die Auswahl einer bestimmten Modellierungstechnik und der dabei zu testenden Algorithmen, z. B. Entscheidungsbaumkonstruktion, neuronale Netzgenerierung usw.[239]

Damit diese Aufgabe richtig bearbeitet werden kann, muss die am besten geeignete Data-Mining-Technik ausgewählt werden, wobei sowohl das Hauptziel des Projekts als auch die Beziehung zu den vorhandenen Tools berücksichtigt werden muss.[240] Wenn es sich beispielsweise um ein Klassifizierungsproblem handelt, besteht die Möglichkeit, zwischen Entscheidungsbäumen, k-nearest neighbors oder Case-based Reasoning (CBR) zu wählen.[241] Handelt es sich um ein Vorhersageproblem, so kann zwischen Regressionsanalyse oder neuronalen Netzen gewählt werden.[242] Wenn es sich um ein Segmentierungsproblem handelt, ist es möglich, neuronale Netze,

[238] Chapman u. a. 2000, S. 23.
[239] Vgl. Chapman u. a. 2000, S. 24, 47–48.
[240] Vgl. Skilton; Hovsepian 2018, S. 153–154.
[241] Vgl. Skilton; Hovsepian 2018, S. 147–149.
[242] Vgl. Haber; Lampoltshammer; Mayr 2019, S. 4.

Visualisierungstechniken etc. zu verwenden.[243] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 15 dargestellt sind.

Tabelle 15: Phänomene bei der Aufgabe Select modeling technique.[244]

Phänomen	**Begründung / Folgen**
Overconfidence effect	Einige Team-Mitglieder neigen dazu, eine Modellierungstechnik zu wählen, die sie besser beherrschen, und nicht die, die für das zu lösende Problem besser geeignet ist.
Clustering illusion	Wenn die Stichprobe sehr gering ist, neigt man dazu, Muster zu sehen, die nicht existieren.
Appeal to probability fallacy	Dies kann geschehen, wenn die Gruppenmitglieder die Methode der Assoziationsanalyse wählen, um die Wenn-Dann-Regel anzuwenden. Das heißt, sie glauben, dass Leute, die Lachs kaufen, bestimmt auch Kren kaufen, sie neigen dazu, dies für sicher zu halten, obwohl es nur eine Wahrscheinlichkeit ist.
Post-purchase rationalization & Choice-support bias	Diese Phänomene können auftreten, wenn die Neigung besteht, im Nachhinein der gewählten Modellierungsmethode positive Eigenschaften zuzuschreiben und der nicht gewählten Methode negative Auswirkungen. Dies wiederum führt dazu, dass Menschen auf der Grundlage dieser Attribute Erinnerungen schaffen, die zukünftige Entscheidungen beeinflussen werden. Wird beispielsweise der Assoziationsmethode ein Mangel zugeschrieben, ist es möglich, dass in der Zukunft beim Nachdenken über diese Methode die Erinnerung kommt, dass diese Methode zahlreiche Fehler aufweist und aus diesem Grund wird man diese Methode nicht mehr wählen, obwohl sie für ein bestimmtes Projekt die an der besten geeigneten Methode sein könnte.

4.4.2 Generate test design

Es ist notwendig, vor der Erstellung des Modells ein Verfahren oder einen Mechanismus zu erstellen, um die Qualität und Gültigkeit des Modells zu testen. Bei überwachten Data-Mining-Aufgaben, wie beispielsweise der Klassifikation, ist es zum Beispiel üblich, Fehlerraten als Qualitätsmaß für Data-Mining-Modelle zu verwenden.[245] Daher ist es üblich, den Datensatz in einen Trainings- und einen Testsatz aufzuteilen, um das Modell auf dem Trainingssatz zu erstellen und seine Qualität auf dem separaten Testsatz zu bewerten.[246] Bei der Bearbeitung dieser Aufgabe ist es möglich, in das kognitionspsychologische Phänomen zu verfallen, die in Tabelle 16 dargestellt sind.

[243] Vgl. Skilton; Hovsepian 2018, S. 128–129.
[244] Einige Darstellung.
[245] Vgl. Chapman u. a. 2000, S. 24, 49.
[246] Vgl. Cleve; Lämmel 2020, S. 59–60.

Tabelle 16: Phänomene bei der Aufgabe Generate test design.[247]

Phänomen	Begründung / Folgen
Absent-mindedness	Die Messwerte dieser Aufgabe werden meist vom Tool berechnet, jedoch ist es sinnvoll, die ganze Zeit diesen Prozess zu verfolgen und zu analysieren, inwieweit diese Fehlermesswerte mit den Daten kompatibel sind.

4.4.3 Build Analysis Model

Es beinhaltet die Ausführung des Modellierungswerkzeugs auf dem vorbereiteten Datensatz, um ein oder mehrere Modelle zu erstellen, und anschließend die resultierenden Modelle zu beschreiben, indem Informationen über die Interpretation der Modelle und die Dokumentation aller aufgetretenen Schwierigkeiten in Bezug auf ihre Bedeutung vermittelt werden.[248] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 17 dargestellt sind.

Tabelle 17: Phänomene bei der Aufgabe Build Analysis Model.[249]

Phänomen	Begründung / Folgen
Pareidolia	Es kann vorkommen, dass sich die Mitglieder der Gruppe, insbesondere die Data-Mining-Spezialisten, zu sehr auf die Ergebnisse der vorherigen Aufgabe verlassen, ohne zu evaluieren, ob das Muster nur ein Zufall ist, sodass die Gruppenmitglieder ein Muster oder eine Bedeutung sehen oder interpretieren, wo es keine gibt.
Moral credential effect	Aufgrund der Tatsache, dass Data-Mining-Ingenieure viel Vertrauen in das erfolgreiche Ergebnis des Projekts haben, neigen sie möglicherweise leichter dazu, die Entscheidung zu treffen, Daten zu fälschen, um ein Modell vorweisen zu können.
Illusory correlation	Die Wahrnehmung einer Beziehung zwischen Variablen, die nicht existieren, ist im Moment der Erstellung eines Modells und seiner Analyse sehr riskant.
Confirmation bias	Erstellung von Modellen gemäß den Überzeugungen, die die Gruppenmitglieder haben, wobei die Informationen aus den Ergebnissen der vorherigen Aufgabe ignoriert werden.
Observer-expectancy effect & Experimenter's bias	Obwohl nicht von einem Experiment ausgegangen wird, ist es sehr wahrscheinlich, dass der Data-Mining-Ingenieur oder die Person, welche diese Aufgabe übernimmt, bei der Interpretation der Daten in diese Verzerrungen verfällt und die Daten nicht richtig interpretiert, sondern versucht, die Daten so auszurichten, dass ein Muster entsteht, das er/sie von Anfang an in den Daten zu sehen erwartete.

[247] Einige Darstellung.
[248] Vgl. Chapman u. a. 2000, S. 24, 49–50.
[249] Einige Darstellung.

4.4.4 Asses Analysis Model

Die Auswertung, die in dieser Phase durchgeführt wird, orientiert sich viel stärker an den Zielsetzungen des Data Mining. Hier interpretiert der Data-Mining-Ingenieur die Modelle entsprechend seines Domänenwissens, der Data-Mining-Erfolgskriterien und des gewünschten Testdesigns. Außerdem beurteilt er den Erfolg der Anwendung der Modellierungs- und Discovery-Techniken aus technischer Sicht. Danach nimmt er Kontakt zu den Business-Analysten und Domänenexperten auf, um die Ergebnisse des Data Mining im geschäftlichen Kontext zu diskutieren.[250]

Es ist erwähnenswert, dass es in Bezug auf Data Mining mehrere Indikatoren gibt, die zur Bewertung der Effektivität des Modells verwendet werden können, z. B. der „root mean squared error“ und der „mean absolute error“.[251] [252] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 18 dargestellt sind.

Tabelle 18: Phänomene bei der Aufgabe Asses Analysis Model.[253]

Phänomen	**Begründung / Folgen**
Suggestibility	Womöglich hat der Data-Mining-Ingenieur bei der Diskussion der Data-Mining-Ergebnisse so oft argumentiert, dass ein Modell richtig und gültig ist, dass der Datenanalyst und der Domänenexperte beeinflusst werden und infolgedessen verzerrte Informationen geschaffen werden.
Illusory superiority, Self-serving bias & Egocentric effect	Dieses Phänomen kann dazu führen, dass eines der Mitglieder mit mehr Erfahrung auf einem Gebiet, z. B. der Data-Mining-Experte, die Fähigkeiten der anderen bei der Beurteilung des Modells unterschätzt. Dadurch ist er überzeugt, dass er der Einzige ist, der Recht hat.
Curse of knowledge	Es kann vorkommen, dass der Data-Mining-Experte sich nicht verständlich machen kann, weil er glaubt, dass andere Menschen die gleichen Erfahrungen und das gleiche Wissen haben wie er.
Confirmation bias	Falsche Interpretation der Modellanalyse, weil man glaubt, dass diese mit den Unternehmenszielen übereinstimmt, auch wenn die Indikatoren das Gegenteil zeigen.

Es ist zu beachten, dass in dieser Aufgabe nur die Modelle betrachtet werden, während in der Auswertungsphase auch alle anderen Ergebnisse, die im Laufe des Projekts entstanden sind, berücksichtigt werden.[254]

[250] Vgl. Chapman u. a. 2000, S. 25, 50–51.
[251] Vgl. Haber u. a. 2021, S. 42.
[252] Vgl. Haber; Lampoltshammer; Mayr 2019, S. 25.
[253] Einige Darstellung.
[254] Vgl. Chapman u. a. 2000, S. 26.

4.4.5 Darstellung der Phänomene bei der Modeling Phase

Um die Analyse zu überschaubar zu gestalten, wurden die Ergebnisse der Phänomene in den einzelnen Aufgaben der Phase "Modeling" in Abbildung 13 zusammengefasst

Modeling			
Select modeling technique			
Too Much Information: - Post-purchase rationalization - Choice-support bias	**Not Enough Meaning:** - Clustering illusion - Appeal to probability fallacy	**Need to Act Fast:** - Overconfidence effect	**What Should We Remember?**
Generate test design			
			- Absent-mindedness
Build Analysis Model			
- Confirmation bias - Observer-expectancy effect - Experimenter's bias	- Pareidolia - Moral credential effect - Illusory correlation		
Assess Analysis Model			
- Confirmation bias	- Curse of knowledge	- Illusory superiority - Self-serving bias - Egocentric effect	- Suggestibility

Abbildung 13: Kognitionspsychologische Phänomene bei der Modelling Phase.[255]

4.5 Evaluation Phase

In dieser Phase wird näher analysiert, welches Modell am besten für das Unternehmen geeignet ist, d. h., welches dieser Modelle auf die Erfüllung der Erfolgskriterien des Projekts ausgerichtet ist und welche Schritte daraufhin zu folgen haben.[256] [257] Die Aufgaben dieser Phase sind in Abbildung 14 zu erkennen.

[255] Einige Darstellung.
[256] Vgl. Chapman u. a. 2000, S. 11, 62.
[257] Vgl. Provost; Fawcett 2017, S. 57.

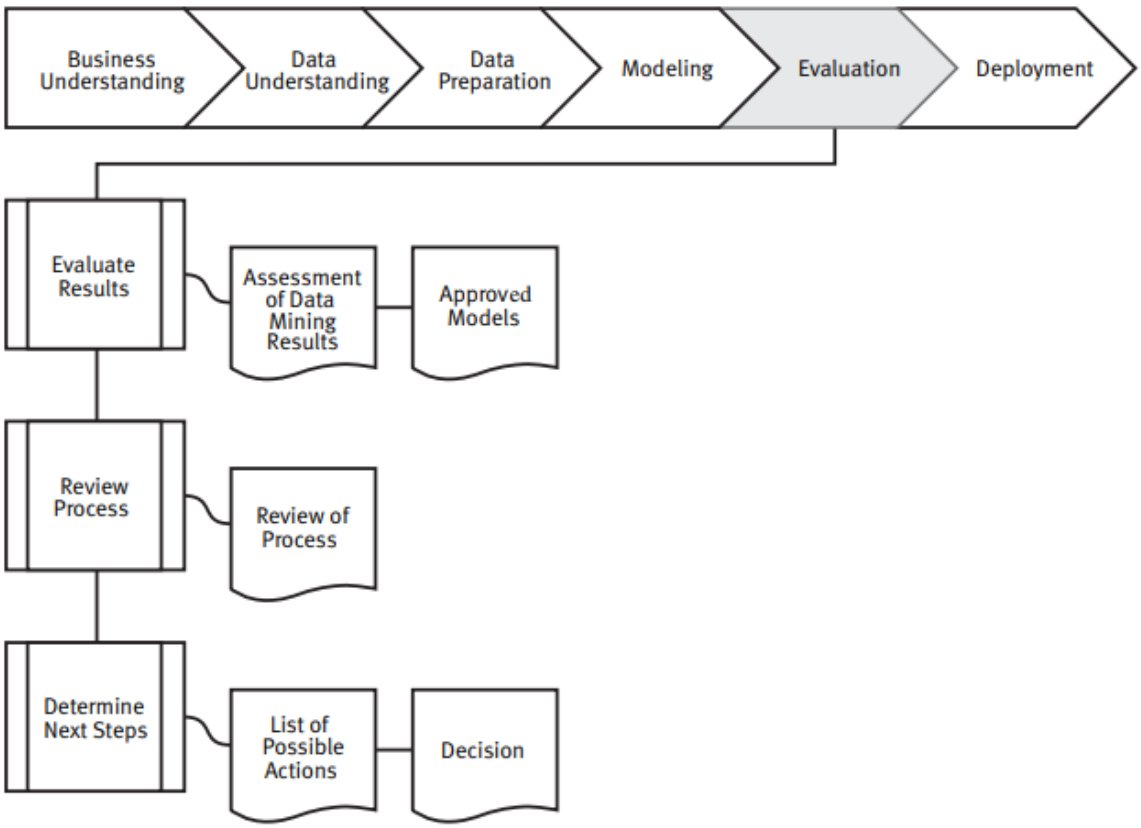

Abbildung 14: CRISP-DM Evaluation Phase.[258]

4.5.1 Evaluate results

Die vorangegangenen Auswertungsschritte befassten sich mit Faktoren wie der Genauigkeit und Allgemeinheit des Modells. In diesem Schritt wird bewertet, inwieweit das Modell die Geschäftsziele erfüllt. Außerdem wird festzustellen versucht, ob es geschäftliche Gründe gibt, warum das Modell mangelhaft ist. Nach der Evaluierung der Modelle anhand der geschäftlichen Erfolgskriterien werden die generierten Modelle, die die ausgewählten Kriterien erfüllen, zu den zulässigen Modellen erklärt. In dieser Aufgabe wird auch festgelegt, ob es empfehlenswert ist, das Modell in Abhängigkeit von den verfügbaren Ressourcen an einem realen Problem zu testen. Darüber hinaus wird bei dieser Aufgabe manchmal vorgeschlagen, das Modell in Bezug auf andere als die ursprünglichen Ziele zu bewerten, um zusätzliche Informationen aufzudecken.[259] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 19 dargestellt sind.

[258] Chapman u. a. 2000, S. 26.
[259] Vgl. Chapman u. a. 2000, S. 26–27, 52.

Tabelle 19: Phänomene bei der Aufgabe Evaluate results.[260]

Phänomen	**Begründung/Folgen**
Authority bias	Wenn der Manager seine Meinung äußert, ist sein Standpunkt deutlich glaubwürdiger als der eines anderen Gruppenmitglieds. Aus diesem Grund kann es vorkommen, dass das ausgewählte Modell nicht das Beste ist, sondern jenes, dass der Manager für das am besten geeignete hält.
Appeal to probability fallacy	Gruppenmitglieder können glauben, dass der Erhalt eines Modells mit einer hohen Erfolgswahrscheinlichkeit absolut sicher ist, ohne dass zuvor eine vollständige Analyse und Bewertung des Modells durchgeführt wurde.
Availability heuristic	Die Auswertung des Modells erfolgt nicht auf der Basis der Erfolgsfaktoren, die es hat, sondern auf der Basis der verfügbaren Informationen, die den Gruppenmitgliedern zum Zeitpunkt der Auswertung einfallen.
Occam's razor	Bei der Überprüfung der Auswahlmöglichkeiten neigen Menschen dazu, das Modell mit den wenigsten Hypothesen auszuwählen, nämlich das einfachste und nicht das am besten geeignete.
Illusion of validity	Einige oder alle Mitglieder neigen möglicherweise dazu, sich zu sehr auf die Interpretationen bezüglich des Modells zu verlassen und nicht zu berücksichtigen, dass außergewöhnliche Ereignisse eintreten können, die diese Vorhersagen nicht wahr werden lassen.
Less-is-better effect	Dieser Effekt führt dazu, dass Menschen dazu neigen, die schlechteste Option zu wählen, je nachdem, wie die Optionen präsentiert werden, ob einzeln oder in Kombination. Daher sollte bei der Präsentation darauf geachtet werden, dass die Modelle alle gleichzeitig präsentiert werden, damit sie zum Zeitpunkt der Bewertung verglichen werden können.
Neglect of Probability	Es lässt sich sagen, dass den Menschen ein intuitives Verständnis der Wahrscheinlichkeit fehlt, was zur Folge hat, dass sie sich nur auf die Bedeutung der Ereignisse konzentrieren und dabei zu analysieren vergessen, wie hoch die Wahrscheinlichkeit dieser Ereignisse ist.
Argument from fallacy	Es kann vorkommen, dass eine der Personen in der Gruppe legitime Gründe hat, zu befürchten, dass das gewählte Modell nicht mit den Zielen des Unternehmens übereinstimmt. Allerdings kann diese Person ihre Gründe, obwohl sie gültig sind, nicht adäquat argumentieren, so dass die anderen Mitglieder der Gruppe in dieses Phänomen verfallen, indem sie diese Behauptung für falsch halten, da die Argumentation nicht überzeugend ist.

[260] Einige Darstellung.

4.5.2 Review process

Die sich ergebenden Modelle wirken zu diesem Zeitpunkt zufriedenstellend und erfüllen die Anforderungen des Unternehmens. Es ist nun angebracht, eine gründlichere Überprüfung des Data-Mining-Einsatzes vorzunehmen, um festzustellen, ob es wichtige Faktoren oder Aufgaben gibt, die in irgendeiner Weise übersehen wurden oder verbessern werden sollten.[261] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 20 dargestellt sind.

Tabelle 20: Phänomene bei der Aufgabe Review process.[262]

Phänomen	**Begründung/Folgen**
Self-serving bias & Egocentric effect	Die Mitglieder der Gruppe definieren keine Probleme oder Schwierigkeiten, da sie dazu neigen, zu glauben, dass das Projekt perfekt war, und somit wichtige Informationen unterdrücken, die für Verbesserungen genutzt werden könnten.
Illusory truth effect & Mere exposure effect	Nachdem ein Modell immer wieder über mehrere Phasen als richtig bestätigt wurde, fällt es sehr schwer, diese Aussage zu widerlegen, selbst wenn das Modell falsch ist. Das liegt daran, dass an diesem Zeitpunkt des Projekts die die Mitarbeiter mit dem Modell vertraut sind und dazu neigen werden, es für wahr zu halten.
Selective perception	Es ist möglich, dass bei der Analyse der Faktoren, die verbessert werden sollten, nur die Ereignisse berücksichtigt werden, die mit den Erwartungen an das Projekt zu tun haben, anstatt mit der Realisierung der einzelnen Phasen.

4.5.3 Determine next steps

Basierend auf den Ergebnissen der Bewertung und der Prozessüberprüfung entscheidet das Projektteam über das weitere Vorgehen. Es beschließt, ob es dieses Projekt beendet und mit der Entwicklungsphase fortfährt, andere Iterationen startet oder neue Data-Mining-Projekte einrichtet. Diese Aufgabe beinhaltet eine Analyse der verbleibenden Ressourcen und des Budgets, welche die Entscheidungen beeinflussen können.[263] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 21 dargestellt sind.

[261] Vgl. Chapman u. a. 2000, S. 27, 53.
[262] Einige Darstellung.
[263] Vgl. Chapman u. a. 2000, S. 27, 53–54.

Tabelle 21: Phänomene bei der Aufgabe Determine next steps.[264]

Phänomen	Begründung/Folgen
Irrational escalation & Sunk cost fallacy	Es ist sehr wahrscheinlich, dass die Teammitglieder in dieser Phase des Projekts nicht in der Lage sind, das Projekt objektiv zu bewerten, weil sie alle möglichen Ressourcen investiert haben, um das Projekt voranzubringen. Deshalb kann es vorkommen, dass sie sich entscheiden, in die nächste Phase überzugehen.
Projection bias	Es ist wichtig, diese Verzerrung zu berücksichtigen, da die Ergebnisse des Projekts nicht unbegrenzt gültig sind. Zum Beispiel ändern sich die Kundenpräferenzen, weshalb es notwendig ist, das Modell regelmäßig zu evaluieren, damit eine kontinuierliche Verbesserung der Ergebnisse erfolgt.

4.5.4 Darstellung der Phänomene bei der Evaluation Phase

Um die Analyse zu überschaubar zu gestalten, wurden die Ergebnisse der Phänomene in den einzelnen Aufgaben der Phase „Evaluation“ in Abbildung 15 zusammengefasst.

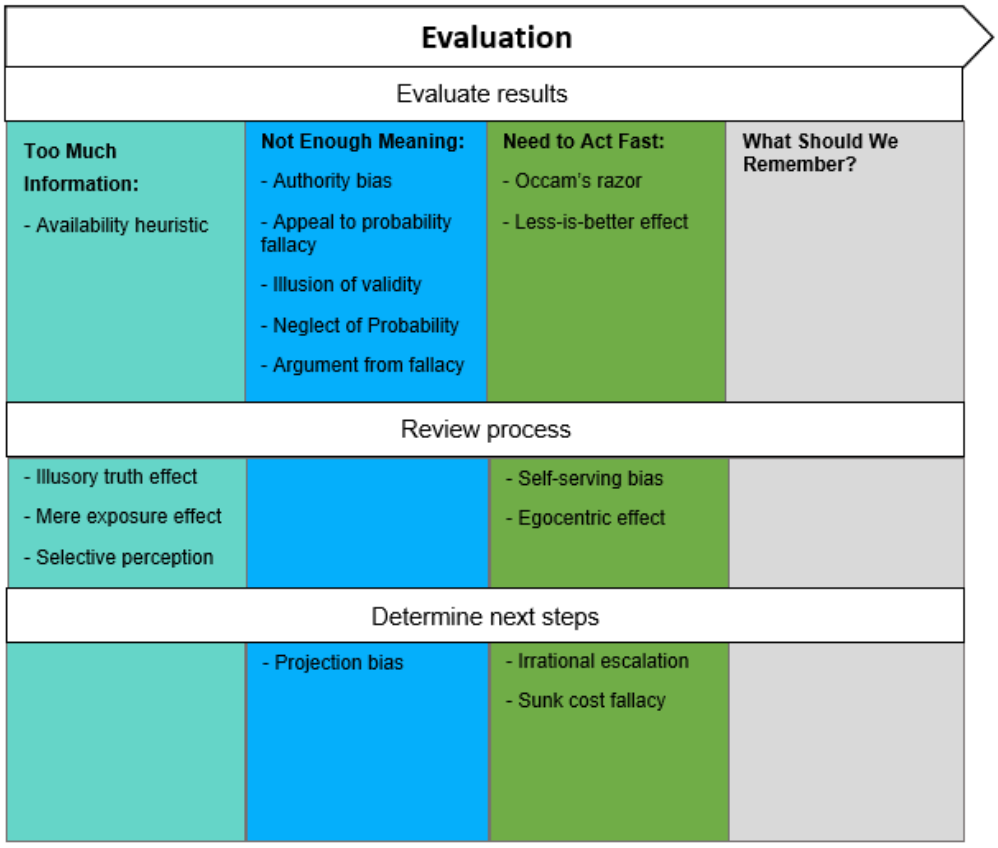

Abbildung 15: Kognitionspsychologische Phänomene bei der Evaluation Phase.[265]

[264] Einige Darstellung.
[265] Einige Darstellung.

4.6 Deployment Phase

Das Ziel in dieser Phase ist es, dass das Wissen die Form einer Strategie annimmt, so dass es sinnvoll eingesetzt werden kann.[266] [267] Die Aufgaben dieser Phase sind in Abbildung 16 zu erkennen.

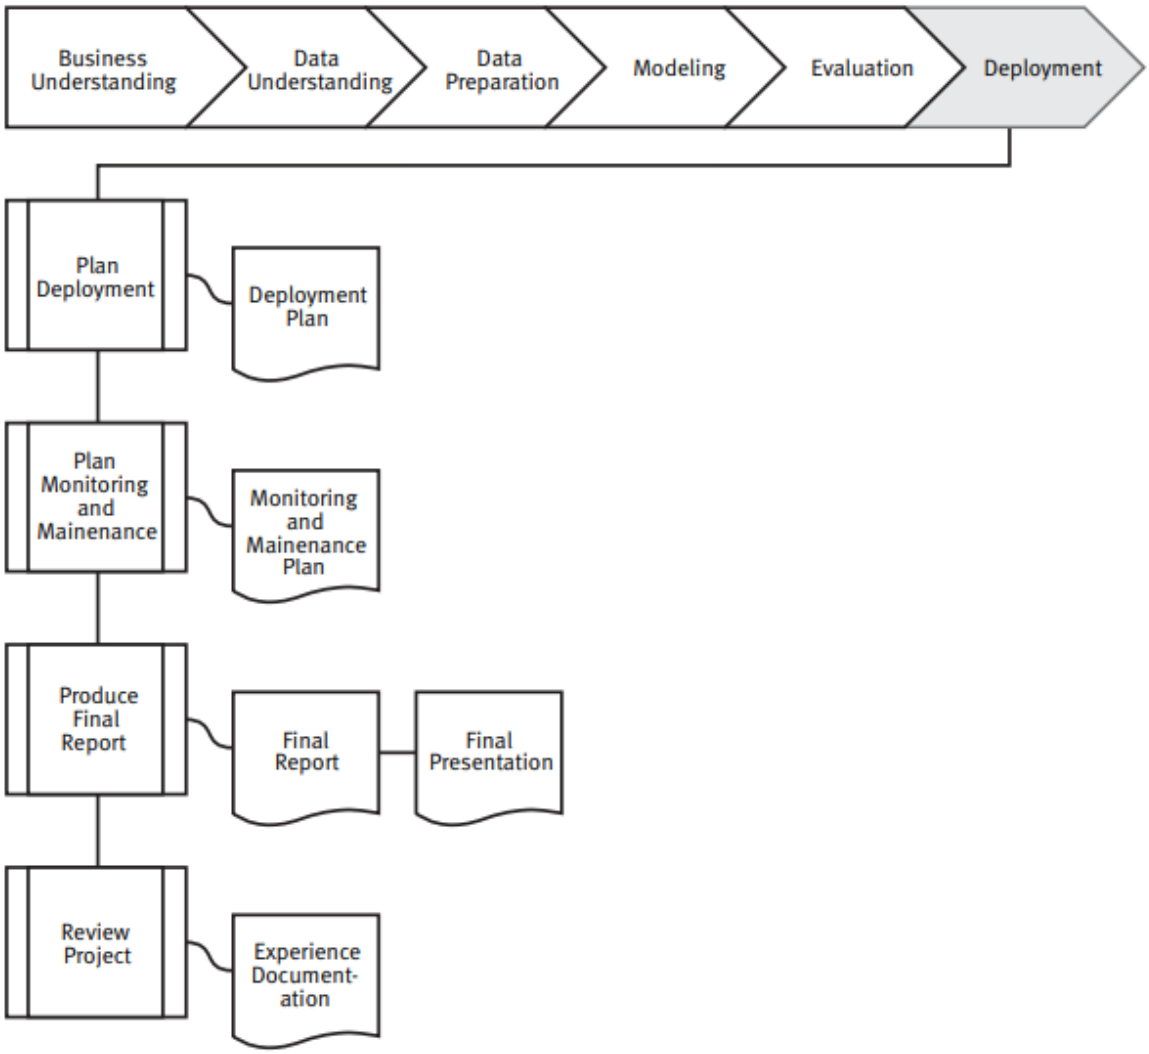

Abbildung 16: CRISP-DM Deployment Phase.[268]

4.6.1 Plan deployment

Hier werden die Ergebnisse der Auswertung verwendet und eine Umsetzungsstrategie wird festgelegt, die die notwendigen Schritte sowie deren Durchführung beinhaltet.[269] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 22 dargestellt sind.

[266] Vgl. Chapman u. a. 2000, S. 11, 62–63.
[267] Vgl. Dietrich u. a. 2015, S. 50–52.
[268] Chapman u. a. 2000, S. 28.
[269] Vgl. Chapman u. a. 2000, S. 28, 54.

Tabelle 22: Phänomene bei der Aufgabe Plan deployment.[270]

Phänomen	Begründung/Folgen
Planning fallacy	Es ist wichtig, sorgfältig zu analysieren, was für die Umsetzung des Projekts erforderlich ist, sowie die Anforderungen und Schritte aufzulisten, die befolgt werden müssen. Aus diesem Grund soll versucht werden, dieses Phänomen zu vermeiden und die Menge an Ressourcen, die für die Umsetzung des Projekts benötigt werden, nicht zu unterschätzen.
Context effect	Um eine Strategie zu erstellen, ist dieser Effekt zu berücksichtigen, denn er besagt, dass die Wahrnehmung eines Ereignisses in Abhängigkeit von seinem Kontext beurteilt wird. Deswegen wird empfohlen, den Kontext der Personen, die von dem Projekt betroffen sein werden, zu berücksichtigen, sodass sie sich immer wohlfühlen, falls sie ihren Kontext verändern müssen.

4.6.2 Plan monitoring and maintenance

Überwachung und Instandhaltung sind wichtige Aufgaben, wenn die Ergebnisse von Data Mining Teil des täglichen Lebens des Unternehmens und seiner Umgebung werden. Die sorgfältige Ausarbeitung einer Wartungsstrategie hilft, unnötig lange Zeiträume des Missbrauchs von Data-Mining-Ergebnissen zu vermeiden. Um den Einsatz von Data-Mining-Ergebnissen zu überwachen, benötigt das Projekt einen detaillierten Monitoring-Prozessplan.[271] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 23 dargestellt sind.

Tabelle 23: Phänomene bei der Aufgabe Plan monitoring and maintenance.[272]

Phänomen	Begründung/Folgen
Escalation of commitment & Irrational escalation & Sunk cost fallacy	Trotz der Tatsache, dass durch die Entwicklung dieser Aufgabe nachgewiesen werden konnte, dass die Ergebnisse des Projekts negativ sind, halten die Projektmitglieder an ihrer Vorstellung fest, dass das Projekt irgendwann positive Ergebnisse liefern wird. Somit lassen sich die während des Projekts getroffenen Entscheidungen rechtfertigen. Dieses Phänomen ist auch mit der **Sunk Cost Fallacy** verbunden, denn die Mitglieder der Gruppe sind der Meinung, dass all ihre Bemühungen und Investitionen irgendwann zu positiven Ergebnissen führen werden.
Ostrich effect	Es geht darum, negative Informationen zum Zeitpunkt der Überwachung und des Projektfeedbacks aus Angst vor der Auseinandersetzung mit der Situation zu vermeiden. Dadurch

[270] Einige Darstellung.
[271] Vgl. Chapman u. a. 2000, S. 29, 55.
[272] Einige Darstellung.

Phänomen	Begründung/Folgen
	entstehen unnötige Kosten, weil sich die Situation immer weiter hinzieht, bis sich diese negativen Auswirkungen nicht mehr vermeiden lassen und die Lösung des Problems viel schwieriger geworden ist, als sie es zu Beginn war.
Illusion of control	Es ist essenziell, die Ereignisse, die während der Entwicklung des Projekts auftreten können, nicht zu überschätzen. Daher ist es notwendig, einen detaillierten Plan zur Überwachung und Wartung des Projekts zu entwickeln.
Overconfidence effect	Diese Aufgabe ernst zu nehmen und nicht planlos darauf zu vertrauen, dass alles perfekt wird, ist der einzige Weg, um sicherzustellen, dass alle investierten Anstrengungen und Ressourcen auch die erwarteten Ergebnisse bringen. Andernfalls wäre es nur eine Verschwendung von Zeit und Ressourcen gewesen.

4.6.3 Produce final report

Am Ende des Projekts schreibt das Projektteam einen Abschlussbericht. Je nach Durchführungsplan kann dieser Bericht nur eine Zusammenfassung des Projekts und seiner Erfahrungen sein – oder er kann eine abschließende und vollständige Präsentation der Ergebnisse der Datenextraktion sein.[273] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 24 dargestellt sind.

Tabelle 24: Phänomene bei der Aufgabe Produce final report.[274]

Phänomen	Begründung/Folgen
Curse of knowledge	Bei der Erstellung des Berichts ist es wichtig, dass das Team versucht, die Projektergebnisse detailliert und leicht verständlich zu erklären, ohne in dieses Phänomen zu verfallen, so dass alle Personen, die den Bericht lesen, diesen nachvollziehen können. Es ist auch wichtig, zu berücksichtigen, dass Menschen Bilder viel besser wahrnehmen. Aus diesem Grund sollte darauf geachtet werden, dass der Bericht eine angenehme Kombination aus Text und Grafik aufweist.
Selective perception	Da Menschen dazu neigen, Informationen zu übersehen, die nicht mit ihren Erwartungen oder Überzeugungen übereinstimmen, ist es höchst wahrscheinlich, dass der Bericht nicht eine objektive Zusammenfassung der Ereignisse zeigt, sondern eher die Meinung widerspiegelt, wie die Gruppe das Projekt gemäß ihren Erwartungen wahrgenommen hat.

[273] Vgl. Chapman u. a. 2000, S. 29, 55–56.
[274] Einige Darstellung.

Phänomen	Begründung/Folgen
	Deswegen ist die Wahrscheinlichkeit sehr groß, dass jedes der Mitglieder einen völlig anderen Bericht erstellt.
Negativity bias	Aufgrund dieser Verzerrung erinnern sich einige Mitglieder des Projektes automatisch an die negativen Ereignisse, die während der Entwicklung des Projekts passiert sind, und übersehen dabei, was gut gelaufen ist. Somit wird der Report mit einer negativen Konnotation erstellt.

4.6.4 Review project

Um das Projekt ordnungsgemäß zu beenden, ist es erforderlich, zu bewerten, was richtig und was falsch gelaufen ist, was gut gemacht wurde und was verbessert werden sollte. Es handelt sich um eine Zusammenfassung wichtiger Erfahrungen, die während des Projekts gesammelt wurden – z. B. Schwierigkeiten, falsche Ansätze oder Tipps für die Auswahl der am besten geeigneten Datenextraktionstechniken in ähnlichen Situationen.[275] Bei der Bearbeitung dieser Aufgabe ist es möglich, in die kognitionspsychologischen Phänomene zu verfallen, die in Tabelle 25 dargestellt sind.

Tabelle 25: Phänomene bei der Aufgabe Review project.[276]

Phänomen	Begründung/Folgen
Defensive attribution hypothesis	Falls im Projekt etwas schiefgelaufen ist, kann es vorkommen, dass jemand, der nicht vollständig Teil der Projektgruppe war, aber bei der Entwicklung einer der Phasen geholfen hat, eingeladen wird, einen Beitrag zum Review zu leisten. Allerdings ist zu bedenken, dass diese Person dazu neigen wird, die Schuld für die schlechten Ereignisse ganz auf die Angehörigen der Gruppe zu schieben und zu betonen, dass sie diejenigen waren, die das Projekt aufgesetzt haben und am meisten damit zu tun hatten.
Anecdotal fallacy	Dieses Phänomen kann auftreten, wenn der Bericht nur auf persönlichen Beobachtungen, jedoch nicht auf tatsächlichen Ereignissen basiert.
Positivity effect	Durch diesen Effekt ist es den Mitgliedern möglich, die negativen Ergebnisse des Modells konstruktiv zu analysieren, wodurch eine zukünftige Weiterentwicklung möglich wird.
Illusion of external agency	Die Gruppenmitglieder können sowohl positive als auch negative Ereignisse auf externe Faktoren zurückführen, anstatt die wahren Ursachen für Erfolg oder Misserfolg zu analysieren. Sollten beispielsweise auf der einen Seite die Ergebnisse des Projekts positiv sein, neigen die Gruppenmitglieder dazu, zu denken, dass es ein Glücksfall war, wenn auf der anderen Seite

[275] Vgl. Chapman u. a. 2000, S. 29, 56.
[276] Einige Darstellung.

Phänomen	Begründung/Folgen
	etwas schief geht, werden die Gruppenmitglieder glauben, dass es ein Unglück war.

4.6.5 Darstellung der Phänomene bei der Deployment Phase

Um die Analyse übersichtlicher zu gestalten, wurden die Ergebnisse aus der Analyse jeder Aufgabe in der Abbildung 17 zusammengefasst.

Deployment			
Plan deployment			
Too Much Information: - Context effect	**Not Enough Meaning:** - Planning fallacy	**Need to Act Fast:**	**What Should We Remember?**
Plan monitoring and maintenance			
- Ostrich effect		- Escalation of commitment - Sunk cost fallacy - Irrational escalation - Illusion of control - Overconfidence effect	
Produce final report			
- Selective perception - Negativity bias	- Curse of knowledge		
Review project			
	- Anecdotal fallacy - Positivity effect - Illusion of external agency	- Defensive attribution hypothesis	

Abbildung 17: Kognitionspsychologische Phänomene bei der Deployment Phase.[277]

[277] Einige Darstellung.

4.7 Ergebnisse der Analyse

Wie in Abbildung 18 zu erkennen ist, treten die meisten Phänomene in der Aufgabe „Determine Business Objectives“ der ersten Phase namens „Business Understanding“ auf. Diese Ergebnisse bestätigen erneut die Informationen aus dem Kapitel 3.5, dass die Phasen und Aufgaben, die Menschen ohne Hilfe eines Systems ausführen, am wahrscheinlichsten von kognitionspsychologischen Phänomenen beeinflusst werden.

Aus diesem Grund und in Anlehnung an die Ideen von Herbert Simon, wie sie in Unterkapitel 3.1.3 beschrieben wurden, ist es empfehlenswert, dass Unternehmen die Entscheidungen ihrer Mitarbeiter durch computergestützte Programme unterstützen, um die Probleme zu minimieren, die durch diese Phänomene entstehen können.[278] [279]

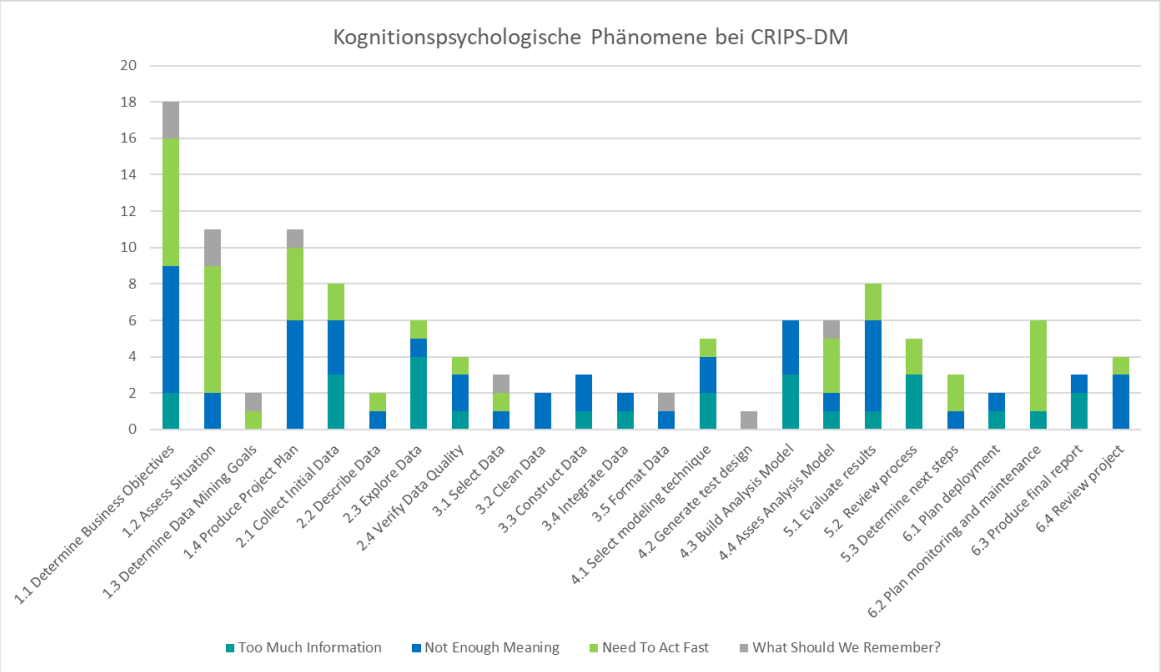

Abbildung 18: Kognitionspsychologische Phänomene bei dem CRIPS-DM-Vorgehensmodell.[280]

Ebenfalls lässt sich feststellen, dass die Phasen, die am wenigsten von den Phänomenen beeinflusst werden, diejenigen sind, die mit Hilfe eines Data-Mining-Systems automatisch durchgeführt werden. Allerdings ist es wichtig, die Risiken von BA, welche im Kapitel 2.4 aufgeworfen worden sind, zu beachten, da der Automatisierungs-Bias immer latent vorhanden ist – und selbst wenn es viele Systeme mit sehr leistungsfähigen Algorithmen gibt, um Informationen aus den Daten zu extrahieren, sollten diese Informationen immer von einem Mitarbeiter berichtigt sowie in einen Kontext gesetzt werden, so dass diese Informationen im Unternehmen zur Verbesserung der Effizienz und Effektivität genutzt werden können.

[278] Vgl. Simon 1971, S. 10–13.
[279] Vgl. Simon 1995, S. 123.
[280] Einige Darstellung.

In Abbildung 19 ist es möglich, die Summe der Phänomene nach ihrer Kategorie einzuordnen. In dieser Summe ist zu sehen, wie die meisten Phänomene, die in dem CRISP-DM-Vorgehensmodell vorkommen, zur Kategorie „Not Enough Meaning“ gehören. Das lässt sich damit erklären, dass in dieser Kategorie die Phänomene zu finden sind, die damit zu tun haben, wie Menschen Informationen wahrnehmen und Entscheidungen treffen, die größtenteils auf intuitiven Urteilen basieren. Dies entspricht den Erläuterungen von Kahneman et al. in Kapitel 3.1.3, welche die Idee vertreten, dass Menschen nicht in der Lage sind, immer logischen Verfahren zu folgen sowie statistische Daten so zu abstrahieren und zu analysieren, dass valide Schlussfolgerungen abgeleitet werden können – und dass sie stattdessen versuchen, einfachen Regeln, mentalen Abkürzungen oder Heuristiken zu folgen, um zu einer Schlussfolgerung zu gelangen.[281]

Weiterhin ist es möglich, zu visualisieren, dass die zweite Kategorie „Need To Act Fast“ ist. Demzufolge kann festgestellt werden, dass Gruppenmitglieder, welche in einem Data-Mining-Projekt unter Druck agieren, sehr wahrscheinlich dazu tendieren, in eines der Phänomene dieser Kategorie zu fallen. Gemäß der Analyse betreffen die Phänomene, die in dieser Kategorie vorkommen, die Planung über die Forschung bis hin zu den Gefühlen und der Motivation der Gruppenmitglieder. Unter Berücksichtigung der von Kahneman und Tversky in Kapitel 3.1.3 dargelegten Prospect Theory lässt sich die zuvor aufgestellte Aussage bestätigen, denn die Autoren argumentieren, dass Individuen danach streben, Verluste zu vermeiden (für mehr Informationen siehe Seite 20). Dies führt dazu, dass beispielsweise bei der Projektplanung in Vorurteile dieser Kategorie wie Zero Risk bias, Verlustaversion etc. leicht verfallen wird.

Zwar wurden bei der Analyse nicht viele Phänomene gefunden, die zur Kategorie „Too Much Information“ gehören, dennoch ist es essenziell, zu erwähnen, dass einige Phänomene aus dieser Kategorie bei der Durchführung eines Data-Mining-Projekts relevant sind. So gehören z. B. viele der Phänomene in diese Kategorie, welche die Neigung von Menschen ansprechen, ihre Gedanken und Überzeugungen bestätigen zu wollen, wenn sie genügend Informationen dazu haben. Eines dieser Phänomene ist der Confirmation Bias, der, wie bereits in Kapitel 1.1 erwähnt wurde, Manager betrifft, die immer ihren Standpunkt bzw. ihre Meinung in einem Projekt durchsetzen wollen.[282]

Abschließend ist festzustellen, dass in der Kategorie „What Should I Remember?“ nur sehr wenige Phänomene zu finden sind, die das Data-Mining-Projekt beeinflussen. Dies liegt möglicherweise daran, dass sich viele der Phänomene, die zu dieser Kategorie gehören, auf Entscheidungen von Menschen in einem eher persönlichen als beruflichen Kontext beziehen. Hier gibt es Effekte wie den sogenannten Google-Effekt, der die Tendenz beschreibt, dass die Menschen Informationen vergessen, die leicht im Internet zu finden sind[283] – was wenig mit der Durchführung eines Data-Mining-Projekts zu tun hat.

[281] Vgl. Gilovich; Griffin; Kahneman 2002, S. 19–20.
[282] Vgl. Costa u. a. 2017, S. 1776–1777.
[283] Vgl. Kahn; Martinez 2020, S. 1–2.

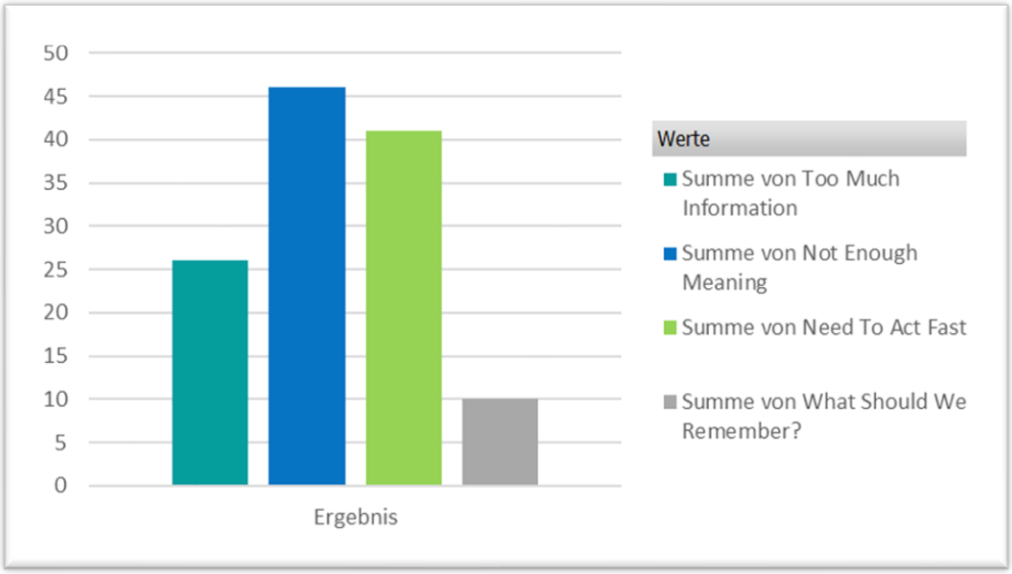

Abbildung 19: Summe der kognitionspsychologischen Phänomene bei dem CRIPS-DM.[284]

Im Folgenden wird eine Zusammenfassung jeder Kategorie in Bezug auf jede der CRISP-DM-Aufgaben dargestellt, so dass ersichtlich wird, in welcher dieser Aufgaben ein stärkerer Einfluss der zur jeweiligen Kategorie gehörenden Phänomene besteht.

In Abbildung 20 ist zu erkennen, dass die Phänomene, die zur Kategorie „Too Much Information“ zählen, einen sehr starken Einfluss auf die Aufgabe „Explore Data“ ausüben. Dies kann in Übereinstimmung mit der zuvor durchgeführten Analyse bestätigt werden, denn in der Untersuchung der Aufgabe „Explore Data“ im Kapitel 4.2.3 konnte nachgewiesen werden, dass die Projektmitglieder in dieser Aufgabe tief die Analyse der aufgehobenen Daten angehen sollen. Wenn diese Datenmenge zu groß ist, besteht die Möglichkeit, leicht in die Phänomene diese Kategorie zu verfallen. Darüber hinaus ist es bei dieser Aufgabe notwendig, erste Schlussfolgerungen oder Hypothesen zu ziehen, die sich von der Art, wie die Informationen von jeder Person wahrgenommen werden, völlig unterscheiden, was den Rest des Projekts vollständig beeinflussen kann.

[284] Einige Darstellung.

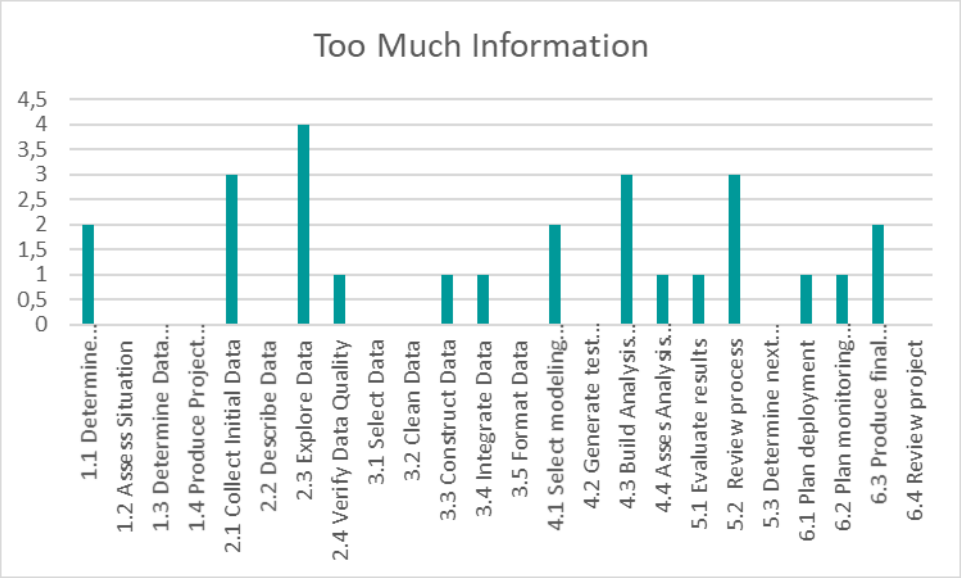

Abbildung 20: Zusammenfassung der Kategorie „Too Much Information“.[285]

In Abbildung 21 ist erkennbar, dass diejenige Aufgabe, die am stärksten von den Phänomenen der Kategorie „Not Enough Meaning“ beeinflusst wird, „Determine Business Objectives“ ist. Gemäß der Analyse in Kapitel 4.1.1 ist dies möglicherweise darauf zurückzuführen, dass es in dieser Phase wichtig ist, mehr als genug Informationen über das Unternehmen zu haben, um Ziele im Rahmen des Unternehmenserfolgs zu definieren. Ansonsten ist es möglich, dass mehrere Mitglieder in Phänomene dieser Kategorie fallen, indem sie versuchen, diese Bedeutungs- oder Informationslücken mit Verallgemeinerungen, Merkmalen und Stereotypen zu füllen, die unbewusst begründet sind. Außerdem ist unter Berücksichtigung der Aussage von Kahneman in Kapitel 3.1.3, dass die meisten Entscheidungen von System 1 getroffen werden, das unbewusst intuitiv und voller Stereotypen ist, zu erkennen, dass die Ergebnisse der Analyse in völliger Übereinstimmung mit den Ergebnissen von Kahnemans Experimenten sind.[286]

[285] Einige Darstellung.
[286] Vgl. Kahneman 2012, S. 23–24.

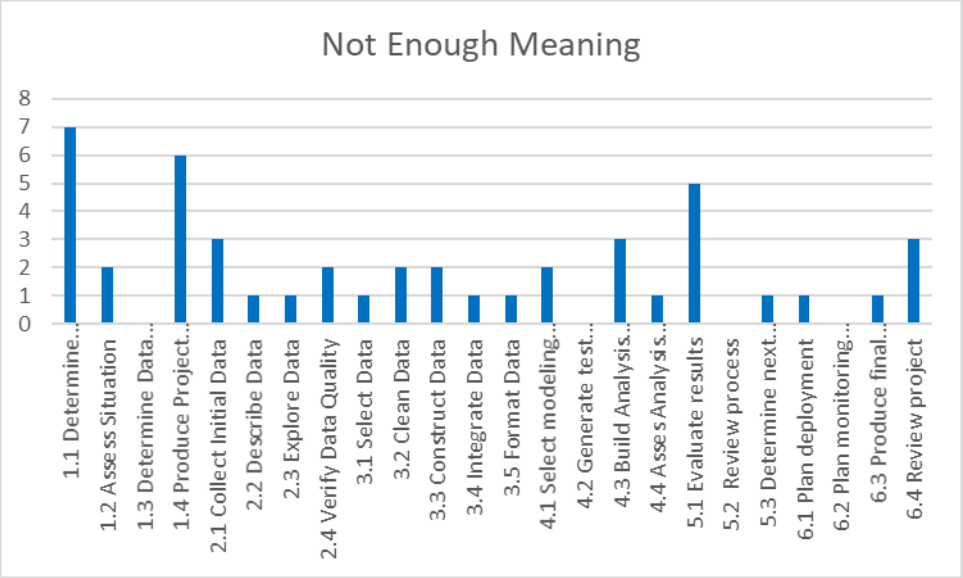

Abbildung 21: Zusammenfassung der Kategorie „Not Enough Meaning“.[287]

Bei Abbildung 22 ist zu erkennen, dass es zwei Aufgaben gibt, die gleichermaßen von Phänomenen der Kategorie „Need to Act Fast“ beeinflusst werden: zum einen die Aufgabe „Determine Business Objectives“. Hier konnte aus der Analyse in Kapitel 4.1.1 sowie aus dem zuvor vorgenommenen Vergleich dieser Kategorie mit der Prospect Theory erkannt werden, dass Druck einen großen Einfluss auf die Festlegung von Zielen hat, so dass einige Mitglieder der Gruppe die Situation nicht verändern wollen und in den „status quo bias“ verfallen, während andere Mitglieder die Situation verändern möchten, weshalb es sehr wahrscheinlich ist, dass der Fokus völlig verloren geht und keine angemessenen Ziele festgelegt werden.

Zum andere ist die Aufgabe „Asses Situation“ zu nennen. Die Analyse in Kapitel 4.1.2 hat gezeigt, dass die Phänomene dieser Kategorie einen erheblichen Einfluss auf diese Aufgabe haben können, da bei der Beurteilung der Situation die Tendenz besteht, Entscheidungen zu treffen, die auf eher egozentrischen Aspekten basieren, z. B. auf dem Wunsch, bei den Teammitgliedern gut dazustehen und auf diese Weise Anerkennung zu erhalten, anstatt eine echte Analyse der Situation vorzunehmen.

[287] Einige Darstellung.

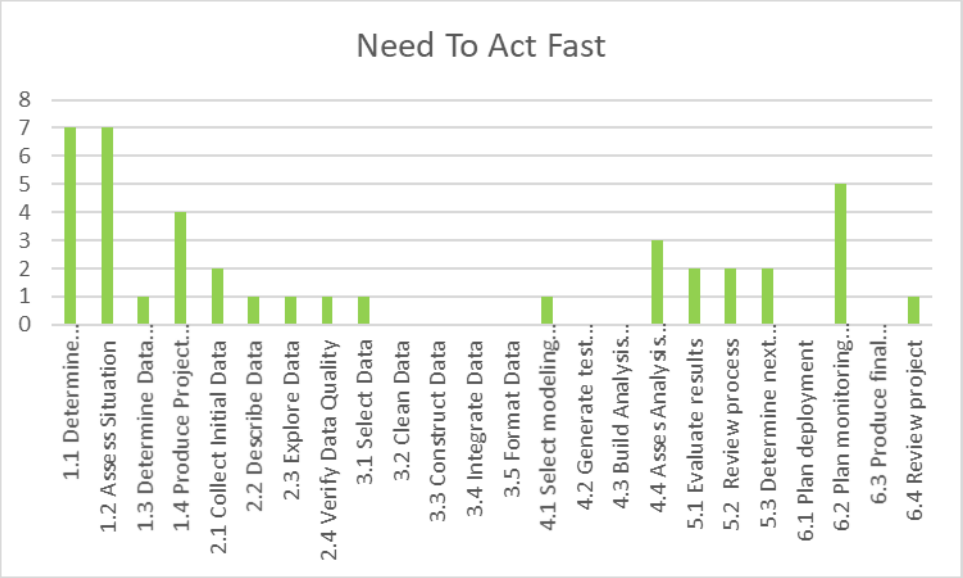

Abbildung 22: Zusammenfassung der Kategorie „Need To Act Fast“.[288]

Wie aus Abbildung 23 hervorgeht, ist „What Should We Remember?“ die Kategorie, die den geringsten Einfluss auf das CRISP-DM-Vorgehensmodell hat. Zugleich lässt sich allerdings erkennen, dass es sich bei den Aufgaben, die es am stärksten beeinflusst, um dieselben zwei handelt wie in der vorherigen Kategorie. Was die Aufgabe „Determine Business Objectives“ betrifft, ist laut der Analyse in Kapitel 4.1.1 dieser Einfluss darauf zurückzuführen, dass die Erfahrungen der Personen, die die Ziele setzen, diese Zielsetzung stark beeinflussen können.

Bei der Aufgabe „Assess Situation“ gemäß Kapitel 4.1.2 passiert das Gleiche wie bei der Aufgabe „Determine Business Objectives“, nur dass sich die Mitglieder eher auf ihre Gefühle über ihre vergangenen Erfahrungen verlassen, wodurch ihre Fähigkeit, Situationen objektiv zu bewerten, beeinträchtigt wird.

[288] Einige Darstellung.

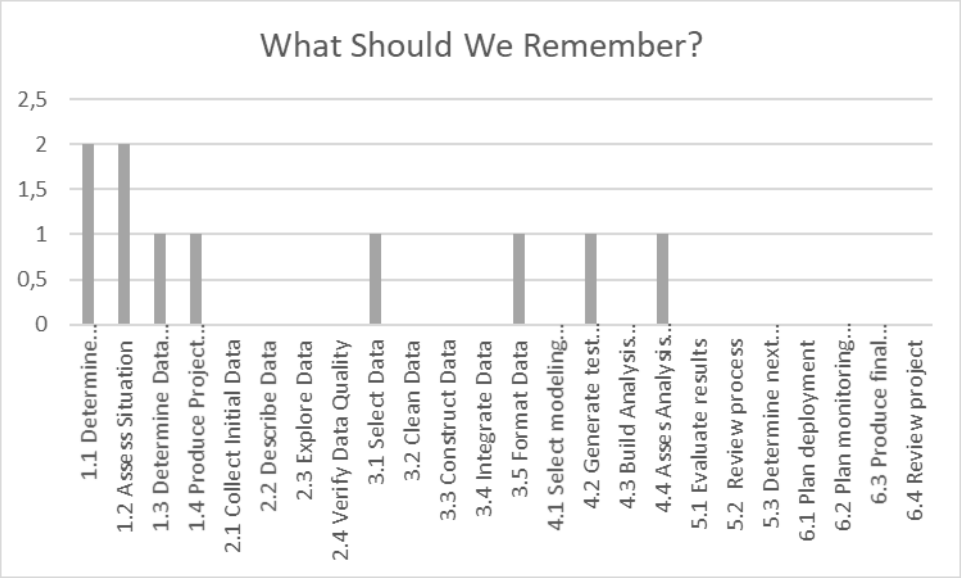

Abbildung 23: Zusammenfassung der Kategorie „What Should We Remember?“.[289]

5. Reflexion und Diskurs

5.1 Beantwortung der Forschungsfragen

Diese Masterarbeit behandelte die folgende Fragestellung: Welchen Einfluss haben die kognitionspsychologischen Phänomene des Verhaltens in der Business Analytics?

Wie sich rückblickend feststellen lässt, haben kognitionspsychologische Phänomene einen erheblichen Einfluss auf die Business Analytics, und zwar in mehrfacher Hinsicht:

- auf die Entscheidungen der Führungskräfte sowie der Mitarbeiter,
- auf die Programmierung von Systemen,
- auf die Entscheidungen von Kunden,
- auf die Bewertung einer statistischen Methode,
- auf die Auswertung von computergestützten Informationen,
- auf Gruppenentscheidungen sowie
- auf die Erstellung von Berichten.

Somit lässt sich die folgende Schlussfolgerung ziehen: Wer das Beste aus Business Analytics herausholen will, muss diese Phänomene unbedingt in Betracht ziehen.

[289] Einige Darstellung.

5.2 Wichtige Argumente

Kognitionspsychologische Probleme haben einen Einfluss auf die Datenanalyse. Dennoch sind BA-Systeme sowie andere computergestützte Systeme eine äußerst wichtige Unterstützung für Führungskräfte und können dementsprechend nicht weggelassen werden.

- Die Komplexität von Entscheidungen kann mit Hilfe computergestützter Lösungen reduziert werden. Wissen ist Macht und hilft, Entscheidungen zu treffen. Daten können dieses Wissen schaffen, aber nur, wenn ein geeignetes Umfeld nicht nur auf der Ebene der IT-Infrastruktur, sondern auch auf derjenigen der Organisationskultur geschaffen wird.

- Die ausführliche Erkennung von kognitionspsychologischen Problemen führt zu besseren Entscheidungen. Der Grund dafür ist, dass, wenn diese überwunden werden, es möglich ist, Entscheidungen auf Basis von Daten und Evidenzen zu treffen. Es ist wichtig zu erwähnen, dass die Option besteht, diese Phänomene durch Training zu überwinden. Deswegen sollten sich sowohl Manager als auch Mitarbeiter mit solchen Trainings auseinandersetzen, um eine Verbesserung im Entscheidungsprozess zu erzielen.

- Business Analytics vereint ebenso wie Verhaltensökonomie eine Reihe verschiedener Fächer wie Statistik, Mathematik, Informatik u. a., aber die Wissenschaft, die nach wie vor die grundlegende Rolle für die Entscheidungsfindung spielt, ist die Psychologie – denn am Ende wird ein Manager trotz der besten BA-Systeme, die für eine Analyse verwendet werden, seine Entscheidung zwar zum Teil auf der Grundlage der vorgelegten Analyse treffen, aber vor allem auf der Grundlage aller Prozesse, die zum Zeitpunkt der Analyse in seinem Gehirn ablaufen. Oft wird dieses Thema im Unternehmen auf die Seite geschoben, allerdings sollte sich ein guter Manager mit psychologischen sowie mit kognitiven Themen auskennen, denn dies ermöglicht nicht nur, die Entscheidungen der Mitarbeiter nachvollziehen zu können, sondern auch, das Kundenverhalten zu verstehen. Außerdem wird es im Sinne der Analytik allen Teammitgliedern, die sich in diesem Bereich gut auskennen, leichter fallen, eine bessere Analyse zu durchführen – und somit werden diese die Ergebnisse oder Ziele eines Projektes mit der höchsten Effektivität erreichen können, denn wie die Analyse gezeigt hat, sind die Phänomene bei der CRISP-DM vielfältig.

- Obwohl sich im Laufe der Jahre durch wissenschaftliche Erkenntnisse eine Reihe von Fehlermöglichkeiten und Theorien ergeben hat, welche das Verständnis dafür ermöglichen, wie Menschen entscheiden, täuscht das Gehirn immer noch den Menschen. Deutlich ist lediglich Folgendes: Selbst, wenn die Analyse, die von verschiedenen Tools erzeugt wurde, die genaueste ist und den Weg eines Unternehmens adäquat vorhersagt, ist es unmöglich, zu prognostizieren, wie sich ein Mensch schlussendlich entscheiden wird. Deswegen ist das Thema Verhaltensökonomie essenziell. Hiermit wird den Unternehmen empfohlen, beispielsweise eine kleine Bibliothek aufzumachen und für jene Bücher aus diesen Bereichen zu beschaffen. Außerdem können Unternehmen die Belegschaft auf solche

Themen aufmerksam machen, indem sie den Mitarbeitern bewusst machen, dass z. B. psychologische Phänomene alle Entscheidungen des Lebens beeinflussen.

- Die Notwendigkeit, psychologische und kognitive Bereiche zu kennen, gilt auch für die zukünftigen KI-Projekte, denn diese Bereiche spielen eine elementare Rolle, um die KI weiterzuentwickeln. Hiermit sind Forschungen aus verschiedenen Bereichen erforderlich, weil die Erstellung von korrekten Algorithmen nur dann richtig sein kann, wenn vollständig verstanden wird, wie menschliches Wissen bzw. Verhalten entsteht.

5.3 Forschungserkenntnisse und kritische Reflexion der Arbeit

Business Analytics ist ein Thema, das Unternehmen aller Größen betrifft. Die wichtigste Tatsache ist, dass Volatilität und Globalisierung Teil jeder Umgebung sind, unabhängig davon, in welchem Land der Welt das Unternehmen angesiedelt ist. Der Erfolg hängt von Faktoren wie den folgenden ab: Innovation von Produkten, Geschäftsmodellen und Dienstleistungen, Prozessverbesserung sowie Anpassungsfähigkeit.

In der Forschungsmethodik dieser Arbeit wurde erwähnt, dass die Forschung in drei Sprachen: Spanisch, Englisch und Deutsch durchgeführt wurde. Aus diesem Grund konnte festgestellt werden, dass die meisten südamerikanischen Autoren ihre Studien auf kleine und mittlere Unternehmen fokussierten, außerdem konzentrieren sie sich auf Untersuchungen, die über die Implementierung von Datenanalysesystemen berichten.

Auf der anderen Seite ist zu erkennen, dass Autoren aus europäischen Ländern, meist deutsche Forscher, ihre Bemühungen auf die Forschung zur Verbesserung von Konzepten der KI und der verschiedenen bestehenden Algorithmen konzentrieren. Die Ergebnisse der Untersuchung stimmen mit dem technologischen Niveau überein, das sowohl die europäische als auch die südamerikanische Region kennzeichnet. Es ist jedoch wichtig, klarzustellen, dass diese Prämisse nicht verallgemeinert werden kann, ohne eine quantitative Analyse durchgeführt zu haben.

Eine Kritik an dieser Arbeit besteht darin, dass, obwohl eine umfangreiche Literaturrecherche vorgenommen wurde, die Erkenntnisse bzw. Aussagen in Bezug auf den Einfluss von kognitionspsychologischen Phänomenen in Business Analytics nur eingeschränkt aussagekräftig sind. Dies liegt auf der einen Seiten daran, dass keine empirische Untersuchung durchgeführt wurde, auf der anderen Seite daran, dass keine der Forschungen, die sogar auf mehreren Jahren basieren, die endgültige Wahrheit enthält, denn die meisten Begriffe und Theorien befinden sich im ständigen Wandel. Außerdem ist zu erwähnen, dass das Gebiet der Entscheidungsfindung sehr breit und komplex ist.

5.4 Ausblick und offene Punkte

Diese Masterarbeit lässt viele Punkte noch offen. Um diese Fragestellung weiter zu erforschen, können zusätzliche Untersuchungen in verschiedenen Bereichen vorgenommen werden, etwa die folgenden:

- Gehirntraining: Wie kann das Gehirn am besten trainiert werden, um kognitive Verzerrungen zu verringern?
- Ethik: Die ethischen Aspekte von vielen der in dieser Arbeit erwähnten Themen (Nudge Theorie, KI, ML usw.) sind zu analysieren. Dazu gehören Fragen wie die folgenden: Wer soll die Konsequenzen in dem Fall, dass es zur Diskriminierung von Bewerbern kommt, tragen? Derjenige, der die verzerrte Software programmiert, oder derjenige, der Entscheidungen auf Grundlage dieser Software trifft?
- Innovation: Welche Rolle spielt die Intuition beim Innovationsgrad eines Unternehmens? Inwiefern beschränkt Business Analytics (datenbasierte Entscheidungen) die Innovationsfähigkeit der Menschen?

Literaturverzeichnis

Abbasi, Asif (2021): AWS Certified Data Analytics Study Guide with Online Labs: Specialty DAS-C01 Exam. John Wiley & Sons.

Albers Ben Chamo, Sophie (2017): Vogue Germany. Der Einfluss von Robotern auf die Modewelt. Online im Internet: URL: https://www.vogue.de/mode/mode-news/roboter-technologie-modeindustrie (Zugriff am: 12.07.2021).

Albright, S. Christian; Winston, Wayne L. (2017): Business analytics: data analysis and decision making. 6th edition. Boston, MA: Cengage Learning.

Ashraf, Nava; Camerer, Colin F.; Loewenstein, George (2005): „Adam Smith, Behavioral Economist.“ In: The Journal of Economic Perspectives, 19 (2005), 3, S. 131–145.

Baars, Henning; Kemper, Hans-Georg (2015): „Integration von Big Data-Komponenten in die Business Intelligence.“ In: Controlling, 27 (2015), 4–5, S. 222–228. Online im Internet: DOI: 10.15358/0935-0381-2015-4-5-222

Baars, Henning; Kemper, Hans-Georg (2021): Business Intelligence & Analytics – Grundlagen und praktische Anwendungen: Ansätze der IT-basierten Entscheidungsunterstützung. 4., überarbeitete und erweiterte Auflage. Wiesbaden: Springer Vieweg (= Lehrbuch).

Bak, Peter Michael (2020): Wahrnehmung, Gedächtnis, Sprache, Denken: Allgemeine Psychologie I - das Wichtigste, prägnant und anwendungsorientiert. Berlin [Heidelberg]: Springer (= Angewandte Psychologie Kompakt).

Banasiewicz, Andrew D. (2019): Evidence-based decision-making: how to leverage available data and avoid cognitive biases. New York: Routledge, Taylor & Francis Group.

Beck, Hanno (2014): Behavioral economics: eine Einführung. Wiesbaden: Springer Gabler (= Lehrbuch). Online im Internet: DOI: 10.1007/978-3-658-03367-5

Bell, Robert M.; Koren, Yehuda; Volinsky, Chris (2010): „All Together Now: A Perspective on the Netflix Prize.“ In: CHANCE, 23 (2010), 1, S. 24–29. Online im Internet: DOI: 10.1080/09332480.2010.10739787

Bentley, Drew (2017): Business Intelligence and Analytics. Larsen and Keller Education.

Bonnefon, Jean-François; Rahwan, Iyad (2020): „Machine Thinking, Fast and Slow.“ In: Trends in Cognitive Sciences, 24 (2020), 12, S. 1019–1027. Online im Internet: DOI: 10.1016/j.tics.2020.09.007

Brijs, Bert (2016): Business Analysis for Business Intelligence. Boca Raton, Fla: CRC Press, an imprint of Taylor & Francis Group.

Brown, Reva (2004): „Consideration of the origin of Herbert Simon’s theory of ‚satisficing‘ (1933-1947).“ In: Management Decision, 42 (2004), 10, S. 1240–1256. Online im Internet: DOI: 10.1108/00251740410568944

Brown, Steven R. (2002): „Herbert Alexander Simon: 15 June 1916 - 9 February 2001.“ In: Policy sciences, 35 (2002), 3, S. 237–238.

Bruttel, Lisa V.; Stolley, Florian (2017): „Richard H. Thaler — Wirtschaftsnobelpreisträger 2017.“ In: Wirtschaftsdienst, 97 (2017), 11, S. 780–784. Online im Internet: DOI: 10.1007/s10273-017-2214-2

Burton, Edwin T.; Shah, Sunit N. (2013): Behavioral finance: understanding the social, cognitive, and economic debates. Hoboken, New Jersey: Wiley (= Wiley finance series).

Callebaut, Werner (2007): „Herbert Simon’s Silent Revolution.“ In: Biological Theory, 2 (2007), 1, S. 76–86. Online im Internet: DOI: 10.1162/biot.2007.2.1.76

Chamoni, Peter; Gluchowski, Peter (2017): „Business Analytics — State of the Art.“ In: Controlling & Management Review, 61 (2017), 4, S. 8–17. Online im Internet: DOI: 10.1007/s12176-017-0030-6

Chapman, Pete u.a. (2000): „CRISP-DM 1.0 - Step-by-step data mining guide.“ In: SPSS Inc., (2000), S. 76.

Cleve, Jürgen; Lämmel, Uwe (2020): Data Mining. 3. Auflage. Berlin Boston: De Gruyter (= De Gruyter Studium).

Costa, Daniel Fonseca u.a. (2017): „Bibliometric analysis on the association between behavioral finance and decision making with cognitive biases such as overconfidence, anchoring effect and confirmation bias.“ In: Scientometrics, 111 (2017), 3, S. 1775–1799. Online im Internet: DOI: 10.1007/s11192-017-2371-5

Davenport, Thomas H. (2018): The AI advantage: how to put the artificial intelligence revolution to work. Cambridge, MA: The MIT Press (= Management on the cutting edge).

Davenport, Thomas H.; Harris, Jeanne G. (2007): Competing on analytics: the new science of winning. Boston, Mass: Harvard Business School Press.

De Bono, Edward (2016): Six thinking hats. Revised and updated. London: Penguin Life, an imprint of Penguin books.

DellaVigna, Stefano (2009): „Psychology and Economics: Evidence from the Field.“ In: Journal of Economic Literature, 47 (2009), 2, S. 315–372.

Devens, Richard Miller (1865): Cyclopaedia of Commercial and Business Anecdotes: Comprising Interesting Reminiscences and Facts, Remarkable Traits and Humors ... of Merchants, Traders, Bankers ... Etc. in All Ages and Countries ... D. Appleton.

Dietrich, David u.a. (Hrsg.) (2015): Data science & big data analytics: discovering, analyzing, visualizing and presenting data. Indianapolis, IN: Wiley.

Elena, Cebotarean; University, Titu Maiorescu (2011): „Business intelligence.“ In: Journal of Knowledge Management, Economics and Information Technology, 1 (2011), 2, S. 12.

Ereth, Julian; Kemper, Hans-Georg (2016): „Business Analytics und Business Intelligence.“ In: Controlling, 28 (2016), 8–9, S. 458–464. Online im Internet: DOI: 10.15358/0935-0381-2016-8-9-458

Euchner, Jim (2017): „What Managers Need to Know About Big Data: An Interview with Foster Provost.“ In: Research Technology Management, 60 (2017), 3, S. 11–17. Online im Internet: DOI: http://dx.doi.org/10.1080/08956308.2017.1300991

European Simulation and Modelling Conference (2011): Modelling and Simulation 2011: the European Simulation and Modelling Conference 2011 ; ESM ’2011: October 24-26, 2011, Guimarães, Portugal. Herausgegeben von Paulo Novais u.a. Ostent: EUROSIS-ETI.

Geschwill, Roland; Nieswandt, Martina (2020): Laterales Management: das Erfolgsprinzip für Unternehmen im digitalen Zeitalter. 2. überarbeitete und erweiterte Auflage. Wiesbaden: Springer (= Sachbuch). Online im Internet: DOI: 10.1007/978-3-658-27735-2

Gigerenzer, Gerd (2008): „Why Heuristics Work.“ In: Perspectives on Psychological Science, 3 (2008), 1, S. 20–29. Online im Internet: DOI: 10.1111/j.1745-6916.2008.00058.x

Gigerenzer, Gerd (2015): Risk savvy: how to make good decisions. Online im Internet: URL: http://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=1124783 (Zugriff am: 17.07.2021).

Gilovich, Thomas; Griffin, Dale W.; Kahneman, Daniel (Hrsg.) (2002): Heuristics and biases: the psychology of intuitive judgment. Cambridge, U.K. ; New York: Cambridge University Press.

Gluchowski, Peter (2016): „Business Analytics – Grundlagen, Methoden und Einsatzpotenziale.“ In: HMD Praxis der Wirtschaftsinformatik, 53 (2016), 3, S. 273–286. Online im Internet: DOI: 10.1365/s40702-015-0206-5

Gluchowski, Peter; Chamoni, Peter (Hrsg.) (2016): Analytische Informationssysteme: Business Intelligence-Technologien und -Anwendungen. 5., vollständig überarbeitete Auflage. Berlin Heidelberg: Springer Gabler.

H. Davenport, Thomas (2014): „How strategists use ‚big data‘ to support internal business decisions, discovery and production.“ In: Strategy & Leadership, 42 (2014), 4, S. 45–50. Online im Internet: DOI: http://dx.doi.org/10.1108/SL-05-2014-0034

Haber, Peter u.a. (Hrsg.) (2021): Data science - analytics and applications: proceedings of the 3rd International Data Science Conference - iDSC2020. Wiesbaden [Heidelberg]: Springer Vieweg.

Haber, Peter; Lampoltshammer, Thomas; Mayr, Manfred (Hrsg.) (2019): Data Science – Analytics and applications: proceedings of the 2nd International Data Science Conference – iDSC2019. Wiesbaden [Heidelberg]: Springer Vieweg.

Hallinan, Blake; Striphas, Ted (2016): „Recommended for you: The Netflix Prize and the production of algorithmic culture.“ In: New Media & Society, 18 (2016), 1, S. 117–137. Online im Internet: DOI: 10.1177/1461444814538646

Harris, Jeanne; Craig, Elizabeth; Egan, Henry (2010): „How successful organizations strategically manage their analytic talent.“ In: Strategy & Leadership, 38 (2010), 3, S. 15–22. Online im Internet: DOI: 10.1108/10878571011042069

Hedgebeth, Darius (2007): „Data-driven decision making for the enterprise: an overview of business intelligence applications.“ In: VINE: Very Informal Newsletter on Library Automation, 37 (2007), 4, S. 414–420. Online im Internet: DOI: http://dx.doi.org/10.1108/03055720710838498

Hofinger, Gesine; Heimann, Rudi (Hrsg.) (2016): Handbuch Stabsarbeit: Führungs- und Krisenstäbe in Einsatzorganisationen, Behörden und Unternehmen. Berlin Heidelberg: Springer.

Hölscher, Stefan u.a. (Hrsg.) (2006): Die Kunst gemeinsam zu handeln: soziale Prozesse professionell steuern. Berlin, Heidelberg: Springer.

Hormigo, Isabel Guitart; Caralt, Jordi Conesa i (2014): „Uso de analítica para dar soporte a la toma de decisiones docentes.“ In: JENUI 2014 XX Jornadas de Enseñanza Universitaria de la Informática, del 9 al 11 de Julio Oviedo 2014, 2014, ISBN 978-84-697-0774-6, págs. 83-90. Universidad de Oviedo, S. 83–90. Online im Internet: URL: https://dialnet.unirioja.es/servlet/articulo?codigo=7368128 (Zugriff am: 11.07.2021).

Humm, Bernhard; Wietek, Frank (2005): „Architektur von Data Warehouses und Business Intelligence Systemen.“ In: Informatik-Spektrum, 28 (2005), 1, S. 3–14. Online im Internet: DOI: 10.1007/s00287-004-0450-5

Kahn, Adam S.; Martinez, Todd M. (2020): „Text and you might miss it? Snap and you might remember? Exploring “Google effects on memory” and cognitive self-esteem in the context of Snapchat and text messaging.“ In: Computers in Human Behavior, 104 (2020), S. 106166. Online im Internet: DOI: 10.1016/j.chb.2019.106166

Kahneman, Daniel (2003): „Maps of Bounded Rationality: Psychology for Behavioral Economics †.“ In: The American Economic Review, 93 (2003), 5, S. 1449–1475.

Kahneman, Daniel (2012): Thinking, Fast and Slow. London: Penguin Books (= Penguin psychology).

Kahneman, Daniel; Tversky, Amos (1979): „Prospect Theory: An Analysis of Decision under Risk.“ In: Econometrica, 47 (1979), 2, S. 263–291. Online im Internet: DOI: 10.2307/1914185

Kemper, Hans-Georg; Baars, Henning; Mehanna, Walid (2010): Business Intelligence - Grundlagen und praktische Anwendungen: eine Einführung in die IT-basierte Managementunterstützung ; [mit Online-Service]. 3., überarbeitete und erweiterte Auflage. Wiesbaden: Vieweg + Teubner (= Studium Wirtschaftsinformatik).

Kerr, Gerry (2011): „What Simon said: the impact of the major management works of Herbert Simon.“ In: Journal of Management History, 17 (2011), 4, S. 399–419. Online im Internet: DOI: 10.1108/17511341111164418

Kimbrough, Steve; Lau, Hoong Chuin (2016): Business analytics for decision making. Online im Internet: URL: https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=1366974 (Zugriff am: 04.05.2021).

Łatuszyńska, Małgorzata; Nermend, Kesra (Hrsg.) (2018): Problems, Methods and Tools in Experimental and Behavioral Economics: Computational Methods in Experimental Economics (CMEE) 2017 Conference. 1st ed. 2018. Cham: Springer International

Publishing : Imprint: Springer (= Springer Proceedings in Business and Economics). Online im Internet: DOI: 10.1007/978-3-319-99187-0

LaValle, Steve u.a. (2011): „Big Data, Analytics and the Path From Insights to Value.“ In: MIT Sloan Management Review, 52 (2011), 2, S. 21–32.

Liang, Ting-Peng; Liu, Yu-Hsi (2018): „Research Landscape of Business Intelligence and Big Data analytics: A bibliometrics study.“ In: Expert Systems with Applications, 111 (2018), S. 2–10. Online im Internet: DOI: 10.1016/j.eswa.2018.05.018

Luce, Leanne (2018): Artificial intelligence for fashion: how AI is revolutionizing the fashion industry. New York, NY: Springer Science+Business Media.

Luhn, H. P. (1958): „A Business Intelligence System.“ In: IBM Journal of Research and Development, 2 (1958), 4, S. 314–319. Online im Internet: DOI: 10.1147/rd.24.0314

Lyell, David; Coiera, Enrico (2017): „Automation bias and verification complexity: a systematic review.“ In: Journal of the American Medical Informatics Association, 24 (2017), 2, S. 423–431. Online im Internet: DOI: 10.1093/jamia/ocw105

Manoogian III, John; Benson, Buster (2016): The Cognitive Bias Codex - 180+ biases. Online im Internet: URL: https://commons.wikimedia.org/wiki/File:Cognitive_bias_codex_en.svg (Zugriff am: 26.06.2021).

Masao, Masao; Tanaka, Saori (2017): Behavioral Economics: Toward a new economics by integration with traditional economics. New York, NY: Springer Berlin Heidelberg.

McCredie, Jack; Simon, Herbert A. (2001): The Steam Engine and the Computer: What Makes Technology Revolutionary. Online im Internet: URL: https://er.educause.edu/articles/2001/1/the-steam-engine-and-the-computer-what-makes-technology-revolutionary (Zugriff am: 02.07.2020).

Morin, Pierre (2001): „Comment Herbert Simon a transformé l’économie.“ In: Sociétal, (2001), 33, S. 21.

Müller, Roland M.; Lenz, Hans-Joachim (2013): „Data Mining.“ In: Business Intelligence. Herausgegeben von Roland M. Müller; Hans-Joachim Lenz. Berlin, Heidelberg: Springer (= eXamen.press), S. 75–120. Online im Internet: DOI: 10.1007/978-3-642-35560-8_3 (Zugriff am: 06.06.2021).

Myagkov, Mikhail; Plott, Charles R. (1997): „Exchange Economies and Loss Exposure: Experiments Exploring Prospect Theory and Competitive Equilibria in Market Environments.“ In: The American Economic Review, 87 (1997), 5, S. 801–828.

Myerson, Roger B. (1991): Game theory: analysis of conflict. Cambridge, Mass: Harvard University Press.

Naidoo, Sherylene Shamma (2019): Business Intelligence Systems Input: Effects on Organizational Decision-Making. ProQuest Dissertations and Theses. D.B.A. Capella University. United States -- Minnesota. Online im Internet: URL: https://search.proquest.com/docview/2191193907/abstract/BF41230B4FEA4F99PQ/1 (Zugriff am: 17.12.2020).

Nermend, Kesra (2017): Neuroeconomic and behavioral aspects of decision making: proceedings of the 2016 computational methods in experimental economics (cmee) conference. New York, NY: Springer Science+Business Media, LLC.

Nettleton, David (2014): Commercial data mining: processing, analysis and modeling for predictive analytics projects. Amsterdam: Elsevier.

Niebler, Paul; Lindner, Dominic (2019): Datenbasiert entscheiden: ein Leitfaden für Unternehmer und Entscheider. Wiesbaden: Springer Gabler (= Essentials). Online im Internet: DOI: 10.1007/978-3-658-23928-2

Núñez Partido, Juan Pedro (2006): „La consciencia y el inconsciente desde un punto de vista cognitivo.“ In: Revista: Aperturas Psicoanalíticas, Periodo: 1, Volumen: Abril 2006, Número: 22, Página inicial: 1, Página final: 36, (2006). Online im Internet: URL: https://repositorio.comillas.edu/xmlui/handle/11531/17738 (Zugriff am: 13.07.2021).

Pinto, Tiago u.a. (2015): „Six thinking hats: A novel metalearner for intelligent decision support in electricity markets.“ In: Decision Support Systems, 79 (2015), S. 1–11. Online im Internet: DOI: 10.1016/j.dss.2015.07.011

Pompian, Michael M. (2012): Behavioral Finance and Wealth Management: How to Build Investment Strategies That Account for Investor Biases. Somerset, UNITED STATES: John Wiley & Sons, Incorporated. Online im Internet: URL: http://ebookcentral.proquest.com/lib/vorarlberg/detail.action?docID=817502 (Zugriff am: 13.07.2021).

Provost, Foster; Fawcett, Tom (2013): Data science for business: what you need to know about data mining and data-analytic thinking. 1. ed., 2. release. Beijing: O'Reilly.

Provost, Foster; Fawcett, Tom (2017): Data Science für Unternehmen: Data Mining und datenanalytisches Denken praktisch anwenden. Übersetzt von Knut Lorenzen. 1. Auflage. Frechen: mitp.

Quesnel, Bruno (2018): „CAR T-cells: A John von Neumann legacy?“ In: Current Research in Translational Medicine, (= Second French International Symposium on CAR T Cells (CARTday)) 66 (2018), 2, S. 35–36. Online im Internet: DOI: 10.1016/j.retram.2018.04.002

Rabin, Matthew (2002): „A perspective on psychology and economics.“ In: European Economic Review, 46 (2002), 4, S. 657–685. Online im Internet: DOI: 10.1016/S0014-2921(01)00207-0

Rauner, Max (2015): „Verhaltensforschung: Die Fliege im Klo - und die Stupser der Kanzlerin.“ In: Die Zeit, 10. März 2015. Online im Internet: URL: https://www.zeit.de/zeit-wissen/2014/06/nudging-politik-verhaltensforschung-psychologie/seite-3 (Zugriff am: 10.05.2021).

Rothfuss, Gunther (2021): 21SS Lecture Statistics 3 Groundwork. Statistics Lecture. Statistics Lecture FV-Vorarlberg. Vorarlberg am 2021.

Schnebel, Eberhard; Homann, Karl; Picot, Arnold (2017): Wirtschaftsethik im Management: Rationalität und Verantwortung in organisationalen Handlungen. Wiesbaden [Heidelberg]: Springer Gabler (= Research). Online im Internet: DOI: 10.1007/978-3-658-17564-1

Schniederjans, Marc J.; Schniederjans, Dara G.; Starkey, Christopher M. (2014): Business Analytics Principles, Concepts, and Applications: What, Why, and How. Upper Saddle River, New Jersey: Pearson Education.

Schön, Dietmar (2016): Planung und Reporting. Wiesbaden: Springer Fachmedien Wiesbaden. Online im Internet: DOI: 10.1007/978-3-658-08009-9 (Zugriff am: 09.05.2021).

Schön, Dietmar (2018): Planung und Reporting im BI-gestützten Controlling: Grundlagen, Business Intelligence, Mobile BI und Big-Data-Analytics. 3., erweiterte Auflage. Wiesbaden [Heidelberg]: Springer Gabler. Online im Internet: DOI: 10.1007/978-3-658-19963-0

Seiter, Mischa (2017): Business Analytics für Controller. München: Franz Vahlen.

Shrestha, Yash Raj; Ben-Menahem, Shiko M.; von Krogh, Georg (2019): „Organizational Decision-Making Structures in the Age of Artificial Intelligence." In: California Management Review, 61 (2019), 4, S. 66–83. Online im Internet: DOI: 10.1177/0008125619862257

Simon, Herbert A. (1960): The new science of management decision. New York, NY, US: Harper & Brothers (= The new science of management decision), S. xii, 50. Online im Internet: DOI: 10.1037/13978-000

Simon, Herbert A. (1971): „Designing Organizations for an Information-Rich World." In: The Johns Hopkins Press, Computers, Communication, and the Public Interest (1971), S. 40–41.

Simon, Herbert A. (1993): „Altruism and Economics." In: The American economic review, 83 (1993), 2, S. 156–161.

Simon, Herbert A. (1995): „Artificial intelligence: an empirical science." In: Artificial Intelligence, 77 (1995), 1, S. 95–127. Online im Internet: DOI: 10.1016/0004-3702(95)00039-H

Simon, Herbert Alexander (2008): The sciences of the artificial. 3. ed., [Nachdr.]. Cambridge, Mass.: MIT Press.

Skilton, Mark; Hovsepian, Felix (2018): The 4th Industrial Revolution: Responding to the Impact of Artificial Intelligence on Business. 1st ed. 2018. Cham: Springer International Publishing : Imprint: Palgrave Macmillan. Online im Internet: DOI: 10.1007/978-3-319-62479-2

Skitka, Linda J.; Mosier, Kathleen L.; Burdick, Mark (1999): „Does automation bias decision-making?" In: International Journal of Human-Computer Studies, 51 (1999), 5, S. 991–1006. Online im Internet: DOI: 10.1006/ijhc.1999.0252

Smith, Adam (1795): Theorie der sittlichen Gefühle: ¬Zweyter ¬Band, welcher die Zusäzze zur sechsten Ausgabe enthält. Gräff.

Takemura, Kazuhisa (2014): Behavioral Decision Theory: Psychological and Mathematical Descriptions of Human Choice Behavior. Tokyo: Springer.

Thaler, Richard H. (2018): „From Cashews to Nudges: The Evolution of Behavioral Economics." In: The American Economic Review, 108 (2018), 6, S. 1265–1287.

Varona, Daniel; Lizama-Mue, Yadira; Suárez, Juan Luis (2021): „Machine learning's limitations in avoiding automation of bias." In: AI & SOCIETY, 36 (2021), 1, S. 197–203. Online im Internet: DOI: 10.1007/s00146-020-00996-y

Velupillai, K. Vela; Venkatachalam, Ragupathy (2018): „Herbert Alexander Simon: 15th June, 1916–9th February, 2001 A Life." In: Computational Economics, (2018), Journal Article, S. 1–3. Online im Internet: DOI: 10.1007/s10614-018-9811-z

Wachter, Klaus (2016): Entscheidungsfindung bei Führungskräften und Mitarbeitern: Ein Ratgeber zum Entscheidungsverhalten in Wirtschaftsbetrieben und Organisationen.

Weber, Felix (2020): Künstliche Intelligenz für Business Analytics: Algorithmen, Plattformen und Anwendungsszenarien. Wiesbaden [Heidelberg]: Springer Vieweg.

Wickens, Christopher D. u.a. (2015): „Complacency and Automation Bias in the Use of Imperfect Automation." In: Human Factors: The Journal of the Human Factors and Ergonomics Society, 57 (2015), 5, S. 728–739. Online im Internet: DOI: 10.1177/0018720815581940

Wilz, Sylvia Marlene (2010): Entscheidungsprozesse in Organisationen: eine Einführung. 1. Aufl. Wiesbaden: VS Verlag für Sozialwissenschaften (= Studientexte zur Soziologie).

Zhang, Arthur (2017): Data Analytics: Practical Guide to Leveraging the Power of Algorithms, Data Science, Data Mining, Statistics, Big Data, and Predictive Analysis to Improve Business, Work, and Life. CreateSpace Independent Publishing Platform.

Anhang

Excel-Tabelle für die Analyse

Quelle: Einige Darstellung

Process	Too Much Information	Not Enough Meanin	Need To Act Fas	What Should We Remembe
1.1 Determine Business Objectives	2	7	7	2
1.2 Assess Situation	0	2	7	2
1.3 Determine Data Mining Goals	0	0	1	1
1.4 Produce Project Plan	0	6	4	1
2.1 Collect Initial Data	3	3	2	0
2.2 Describe Data	0	1	1	0
2.3 Explore Data	4	1	1	0
2.4 Verify Data Quality	1	2	1	0
3.1 Select Data	0	1	1	1
3.2 Clean Data	0	2	0	0
3.3 Construct Data	1	2	0	0
3.3 Integrate Data	1	1	0	0
3.4 Format Data	0	1	0	1
4.1 Select modeling technique	2	2	1	0
4.2 Generate test design	0	0	0	1
4.3 Build Analysis Model	3	3	0	0
4.4 Asses Analysis Model	1	1	3	1
5.1 Evaluate results	1	5	2	0
5.2 Review process	3	0	2	0
5.3 Determine next steps	0	1	2	0
6.1 Plan deployment	1	1	0	0
6.2 Plan monitoring and maintenance	1	0	5	0
6.3 Produce final report	2	1	0	0
6.4 Review project	0	3	1	0

Eidesstattliche Erklärung

Ich erkläre hiermit an Eides statt, dass ich vorliegende Masterarbeit selbstständig und ohne Benutzung anderer als der angegebenen Hilfsmittel angefertigt habe. Die aus fremden Quellen direkt oder indirekt übernommenen Stellen sind als solche kenntlich gemacht. Die Arbeit wurde bisher weder in gleicher noch in ähnlicher Form einer anderen Prüfungsbehörde vorgelegt und auch noch nicht veröffentlicht.

Dornbirn, am 28.07.2020 Alejandra Zapata Patiño