

**Masterstudiengang der FHWien der WKW  
Financial Management & Controlling**

**Predictive Analytics im Controlling –  
Herausforderungen im Implementierungsprozess**

**Angestrebter akademischer Grad:  
Master of Arts in Business**

**Verfasst von: Bernadette Reifböck B.A.**

**Matrikelnummer: 51838768**

**Abschlussjahr: 2023**

**Betreut von: Christopher Liska B.A. M.A.**

Ich versichere hiermit,

- diese Arbeit selbständig verfasst, keine anderen als die angegebenen Quellen und Hilfsmittel benutzt und mich auch sonst keiner unerlaubten Hilfe bedient zu haben,
- diese Arbeit bisher weder im In- noch Ausland in irgendeiner Form als Prüfungsarbeit vorgelegt zu haben,
- die Übereinstimmung dieser Arbeit mit jener Version, die der Betreuung vorgelegt und zur Plagiatsprüfung hochgeladen wurde,
- mit der Veröffentlichung dieser Arbeit durch die Bibliothek der FHWien der WKW einverstanden zu sein, die auch im Fall einer Sperre nach Ablauf der genehmigten Frist erfolgt.

Wien, 14.04.2023

---

Ort, Datum

Unterschrift Verfasser\*in

## **Abstract**

Das Thema Predictive Analytics im Controlling sorgte in den vergangenen Jahren für viel Aufsehen. Es zeichnete sich ein klarer Trend ab, Predictive Analytics einzusetzen, um Planungsprozesse zu vereinfachen und zu verbessern. Dennoch finden diese Methoden bei einer Vielzahl von Unternehmen bis dato keinen Eingang in die Controllingprozesse. Dies wirft die Frage auf, ob der Implementierungsprozess in der Praxis eine unüberwindbare Hürde darstellt und die Anwendung von Predictive Analytics im Controlling überbewertet wird. Heute – einige Jahre sowie einige Krisen später – soll eine Bilanz gezogen werden. Im Rahmen dieser Arbeit werden die wesentlichen Herausforderungen bei der Implementierung von Predictive Analytics im Controlling erforscht und Grenzen sowie Restriktionen, die sich bei der Implementierung ergeben, aufgezeigt. Zur Beantwortung dieser Fragen wurden Experteninterviews durchgeführt, um die tatsächlichen Hürden, die sich im Zuge des Implementierungsprozesses stellen, zu analysieren. Die Auswertung der Ergebnisse zeigt, dass Unternehmen mit zahlreichen Herausforderungen bei der Implementierung konfrontiert werden. Allerdings zeichnen sich auch Grenzen bei der Implementierung von Predictive Analytics im Controlling ab, welche es zu beachten gilt. Daraus ableitend werden Empfehlungen für eine erfolgreiche Implementierung in dieser Arbeit angeführt.

## **Abstract**

The use of predictive analytics in controlling has attracted significant attention in recent years. There was a clear trend toward using predictive analytics to simplify and improve planning processes. Nevertheless, these methods have not yet found their way into the controlling processes of a large number of companies. This raises the question of whether the implementation process represents an insurmountable hurdle in practice and whether the use of predictive analytics in controlling is overrated. Today - some years as well as some crises later - a balance shall be drawn. In this thesis, the main challenges for the implementation of predictive analytics in controlling are analyzed and limits as well as restrictions that arise in the implementation process are identified. To answer these questions, expert interviews were conducted to analyze the actual hurdles that arise during the implementation process. The evaluation of the results shows that companies face numerous challenges during implementation. However, there are also limits to the implementation of predictive analytics in controlling that need to be considered. Based on this, recommendations for a successful implementation are given in this thesis.

## **Inhaltsverzeichnis**

Abbildungsverzeichnis .....	IV
Tabellenverzeichnis .....	V
Abkürzungsverzeichnis .....	VI
1 Einleitung .....	1
1.1 Ausgangssituation.....	1
1.2 Zielsetzung der Arbeit .....	3
1.3 Forschungsfragen .....	4
1.4 Methodische Vorgehensweise .....	4
1.5 Aufbau der Arbeit.....	5
2 Predictive Analytics – Begriffsbestimmung und Grundlagen.....	7
2.1 Hintergrund von Predictive Analytics .....	7
2.2 Predictive Analytics als Teilbereich von Business Analytics .....	8
2.3 Definition von Predictive Analytics .....	13
2.4 Big Data.....	14
2.5 Data Mining.....	15
3 Anwendungsbereiche von Predictive Analytics im Controlling .....	18
3.1 Digitalisierung im Controlling.....	19
3.2 Einsatzbereiche von Predictive Analytics im Controlling.....	19
3.2.1 Planung mit Predictive Analytics .....	20
3.2.2 Forecasting mit Predictive Analytics.....	21
3.2.3 Reporting mit Predictive Analytics .....	24
3.2.4 Anwendung im Vertriebscontrolling .....	26
3.2.5 Anwendung im Personalcontrolling .....	28
3.3 Zuverlässigkeit von Predictive Analytics in Krisenzeiten.....	30
4 Implementierungsprozess von Predictive Analytics im Controlling.....	33
4.1 Vorgehensweise bei der Implementierung von Predictive Analytics.....	33

4.2 Cross Industry Standard Process for Data Mining (CRISP-DM) .....	33
4.2.1 Business Understanding .....	35
4.2.2 Data Understanding.....	36
4.2.3 Data Preparation.....	37
4.2.4 Modeling .....	39
4.2.5 Evaluation .....	40
4.2.6 Deployment.....	41
4.3 Grundlegende Methoden.....	43
4.3.1 Klassifikationsanalysen.....	43
4.3.2 Regressionsanalysen .....	45
4.3.3 Cluster-Analysen.....	46
4.3.4 Zeitreihenanalyse .....	46
4.4 Implementierungsbeispiel .....	47
5 Herausforderungen im Implementierungsprozess .....	51
5.1 Datenproblematik.....	51
5.1.1 Datenverfügbarkeit und Datenqualität .....	51
5.1.2 Sensible personenbezogene Daten .....	53
5.1.3 Überanpassung als Fehlerquelle.....	54
5.2 Der menschliche Faktor .....	55
5.2.1 Fehlendes Know-how .....	55
5.2.2 Fehlende Akzeptanz.....	56
5.2.3 Ressourcenproblematik.....	57
5.2.4 Komplexitätsproblematik.....	58
6 Lösungsansätze .....	59
6.1 Datenproblematik.....	59
6.2 Überanpassung .....	60
6.3 Der menschliche Faktor .....	62

6.4 Komplexitäts- und Ressourcenproblematik .....	66
7 Empirische Untersuchung.....	67
7.1 Untersuchungsdesign.....	67
7.2 Konzeption des Interviewleitfadens .....	68
7.3 Auswahl der Interviewpartner .....	69
7.4 Auswertungsverfahren.....	71
7.5 Gütekriterien.....	72
7.6 Kategoriensystem .....	73
8 Interpretation der Ergebnisse.....	76
8.1 Entwicklung von Predictive Analytics im Controlling.....	76
8.2 Potenziale und Tipps für eine Implementierung von Predictive Analytics .....	81
8.3 Herausforderungen bei der Implementierung von Predictive Analytics im Controlling	90
9 Conclusio.....	98
9.1 Diskussion der Ergebnisse.....	98
9.2 Limitationen .....	101
9.3 Ausblick.....	102
10 Literaturverzeichnis .....	104
Anhang A.....	1

## **Abbildungsverzeichnis**

<i>Abbildung 1.</i> Analyse-Spektrum von BI und Business Analytics. ....	11
<i>Abbildung 2.</i> KDD Prozess. ....	16
<i>Abbildung 3.</i> Latenzmodell. ....	25
<i>Abbildung 4.</i> CRISP-DM Modell.....	35
<i>Abbildung 5.</i> Häufig auftretende Fehler in HR-Datenquellen. ....	59

## **Tabellenverzeichnis**

<i>Tabelle 1.</i> Übersicht der Interviewpartner .....	70
<i>Tabelle 2.</i> Kategoriensystem .....	74



## Abkürzungsverzeichnis

Abs.	Absatz
AI	Artificial Intelligence
BA	Business Analytics
BAO	Bundesabgabenordnung
BI	Business Intelligence
bzw.	beziehungsweise
ca.	circa
CRISP-DM	Cross Industry Standard Process for Data Mining
d.h.	das heißt
et al.	et alii
etc.	et cetera
G&V	Gewinn- und Verlustrechnung
HR	Human Resources
Hrsg.	Herausgeber:in
IP	Interviewpartner:in
KDD	Knowledge Discovery in Databases-Process
KI	Künstliche Intelligenz
OLAP	Online Analytical Processing
Rz	Randziffer
S.	Seite
vgl.	vergleiche
Z.	Zeile des Interviewtranskripts
z.B.	zum Beispiel

# 1 Einleitung

## 1.1 Ausgangssituation

Durch den unaufhaltsamen Digitalisierungstrend und die zunehmend schnelllebige Wirtschaft besteht die Notwendigkeit, Unternehmensprozesse sowohl agiler als auch effizienter zu gestalten. Um auf den Märkten bestehen zu können, müssen Unternehmen frühzeitig auf veränderte Marktbedingungen reagieren können und in der Lage sein, entsprechende Maßnahmen zeitnah zu ergreifen. Volatile Marktbedingungen, die nicht zuletzt durch verschiedenste Krisen verstärkt wurden, führen zu Schwierigkeiten bei der Prognose zukünftiger Entwicklungen. Die eingeschränkte Prognostizierbarkeit kann unter anderem zu verzögertem Handeln oder sogar zu Fehlentscheidungen führen. In diesem Zusammenhang werden Predictive Analytics seit einigen Jahren verstärkt als mögliche Hilfestellung für Unternehmen genannt. Sie sollen ein Instrument darstellen, um diesen Herausforderungen entgegenzutreten und verlässlichere Prognosen zu ermöglichen. Weiters bilden die im Zuge des Digitalisierungstrends ansteigenden Datenmengen der Unternehmen sowie der Einsatz von digitalen Technologien – Stichwort Big Data und Cloud-basierte Datenbanken – die Grundlagen für die Anwendung von Predictive Analytics (Möller, Federmann, Pieper & Knezevic, 2016, S. 509).

Unter Predictive Analytics versteht man die Vorhersage zukünftiger Ereignisse und Daten, die durch den Einsatz von Analysemethoden und -techniken ermöglicht werden. Die bereitstehenden, großen Datenmengen eines Unternehmens werden durch statistische Algorithmen auf Muster und Strukturen untersucht. Auf Basis dieser Erkenntnisse werden zukünftige Entwicklungen prognostiziert (Burow, Gerards & Demmer, 2017, S. 50). Dabei werden anhand von Predictive Analytics-Tools Eintrittswahrscheinlichkeiten bestimmter Entwicklungen berechnet. Es wird analysiert, unter welchen Voraussetzungen bestimmte Ereignisse eintreten und wie hoch die Wahrscheinlichkeit des Eintritts liegt. Die berechneten Eintrittswahrscheinlichkeiten stellen eine Entscheidungsgrundlage für Unternehmen dar (Iffert, 2016, S. 17).

Einige Branchen nutzen und profitieren bereits seit längerem von der Anwendung von Predictive Analytics. Zum Beispiel setzen Kreditinstitute Analysetools ein, um die Ausfallwahrscheinlichkeiten der potenziellen Kreditnehmer:innen zu prognostizieren. Fluggesellschaften nutzen Predictive Analytics, um die Anzahl der Passagiere abschätzen zu können. Jedoch haben

sich die Einsatzmöglichkeiten von Predictive Analytics in den vergangenen Jahren enorm ausgeweitet, was wie bereits zuvor erwähnt unter anderem auf Big Data zurückgeführt werden kann (Endres & Helm, 2015, S. 59).

Branchenunabhängig wird in vielen Unternehmensbereichen vermehrt auf die Anwendung von Predictive Analytics gesetzt und versucht, dadurch Nutzungspotenziale bestmöglich auszuschöpfen. Beispielsweise werden im Human Capital Management Predictive Analytics eingesetzt, um die Personalbeschaffung sowie die Personalerhaltung effizienter zu gestalten und zukünftige Trends zu antizipieren (Kels & Vormbusch, 2020, S. 71). Des Weiteren bieten Vertrieb, Marketing, Produktion, Logistik und im Finanzbereich mögliche Anwendungsbereiche für Predictive Analytics (Tischler & Fuchs, 2022, S. 19).

Auch im Controlling kann von der Anwendung von Predictive Analytics-Verfahren profitiert werden. Häufig gestalten sich die Planungsprozesse der Unternehmen als sehr aufwendig und komplex. Die Prozesse werden durch langwierige Abstimmungsverfahren auf unterschiedlichsten Ebenen verzögert und die daraus resultierenden Ergebnisse liefern lediglich pseudogene Werte. Dies ist darauf zurückzuführen, dass die Ergebnisse präziser dargestellt werden, als es die zur Verfügung gestellten Daten erlauben. Mithilfe von Predictive Analytics kann diesem Problem begegnet werden und die Prognosegenauigkeit gesteigert werden (Burow, Gerards & Demmer, 2017, S. 50).

Aus diesem Grund werden Predictive Analytics-Tools unter anderem bei Planungsprozessen eingesetzt, um eine Effizienzsteigerung sowie eine Verbesserung der Planungsgenauigkeit zu erzielen. Eines der wesentlichen Ziele, die beim Einsatz von Predictive Analytics im Controlling verfolgt werden, ist die Schaffung von Flexibilität in der Planung. Daraus resultiert eine verbesserte Reaktionsfähigkeit der betreffenden Abteilungen bzw. Personen. Unternehmen können somit frühzeitig Chancen und Risiken erkennen und dementsprechend agieren (Möller & Pieper, 2015, S. 41).

Predictive Analytics im Controlling wird somit großes Potenzial zugeschrieben, dass in vielen Bereichen zu einer Optimierung der Steuerungsprozesse führen kann. Bereits im Implementierungsprozess können jedoch häufig die ersten Herausforderungen identifiziert werden (Holthoff & Decher, 2020, S. 52). In diesem Zusammenhang stellt sich die Frage, welche Probleme der Implementierungsprozess von Predictive Analytics im Controlling aufwirft und ob sich diese

durch umfangreiche Vorbereitungstätigkeiten als vermeidbar herausstellen. Weiters gilt es zu beantworten, ob es branchenspezifische Besonderheiten gibt, die Unternehmen vor spezielle Herausforderungen bei der Implementierung stellen und Grenzen bei der Implementierung aufzeigen. Schließlich stellt sich die Frage, welche Möglichkeiten gegeben sind und ob beispielsweise eine Implementierung in Krisenzeiten möglich ist bzw. sich als sinnvoll erweisen würde.

## **1.2 Zielsetzung der Arbeit**

Ziel dieser wissenschaftlichen Arbeit ist es, die Herausforderungen, die bei der Implementierung von Predictive Analytics im Controlling auftreten, zu identifizieren und aufzuzeigen. Im Zuge dessen werden die Phasen des Implementierungsprozesses beschrieben und Leitlinien für ein erfolgreiches Implementierungsprojekt vorgegeben. Auf kritische Erfolgsfaktoren, die über Gelingen oder Scheitern eines Projektes entscheiden wird eingegangen.

Es wird erforscht, ob erwartete Hindernisse bei der Implementierung von Predictive Analytics letztlich dafür ausschlaggebend sind, dass der Einsatz von Predictive Analytics-Tools von Unternehmen gar nicht erst in Erwägung gezogen wird. Relevante Problemfelder werden erarbeitet und mögliche Lösungsansätze werden aus den identifizierten Herausforderungen abgeleitet. Im Rahmen der Arbeit wurden Experteninterviews durchgeführt, mit Hilfe derer neue Erkenntnisse über den Implementierungsprozess gewonnen werden. Aus den gesammelten Erfahrungen der Interviewpartner, können in der Praxis auftretende Risiken bei der Implementierung erkannt und festgehalten werden. Dabei werden auch Empfehlungen für eine effiziente Implementierung ausgearbeitet, wobei unter anderem erforderliche Vorbereitungstätigkeiten und sonstige entscheidende Erfolgsfaktoren hervorgehoben werden.

Darüber hinaus wird erforscht, ob die Anwendung von Predictive Analytics im Controlling für Unternehmen erstrebenswert ist und die gewünschten Resultate erzielt werden können. Mögliche Anwendungsbereiche im Controlling, wie beispielsweise die Unterstützung von Predictive Analytics-Tools beim Forecasting, werden untersucht. Es wird geprüft, ob sich der Aufwand im Hinblick auf den langwierigen, intensiven Einführungsprozess für Unternehmen lohnen kann, und welche konkreten Vorteile sich aus der Anwendung ergeben.

Zudem stellt sich vor allem in volatilen Zeiten die Frage, wie die Zuverlässigkeit und Prognosegenauigkeit von Predictive Analytics einzustufen ist. Ob man hierbei bereits auf die Grenzen

der zukunftsorientierten Datenanalyse stößt und welche anderen Grenzen sich abzeichnen, wird im Rahmen dieser Arbeit behandelt. Weiters beschäftigt sich diese wissenschaftliche Arbeit mit der Frage, ob auf historischen Daten basierende Modelle in Krisenzeiten (beispielsweise Covid-19-Krise und Angriffskrieg auf die Ukraine) angewandt werden können, oder ob sich solche als ungeeignet herausstellen und von einer Implementierung in derart volatilen Zeiten Abstand genommen werden sollte.

### **1.3 Forschungsfragen**

#### **Hauptforschungsfrage:**

- Welche Herausforderungen stellen sich im Hinblick auf den Implementierungsprozess von Predictive Analytics im Controlling?

Aufbauend auf der Hauptforschungsfrage leitet sich folgende zweite Forschungsfrage ab:

- Inwiefern sind Predictive Analytics im Controlling Grenzen und Restriktionen bei der Implementierung gesetzt?

### **1.4 Methodische Vorgehensweise**

Als Basis dieser wissenschaftlichen Arbeit wurden die theoretischen Grundlagen zu Predictive Analytics im Controlling, den Implementierungsprozess sowie die Potenziale und Grenzen von Predictive Analytics im Controlling erhoben. Dazu wurde eine umfangreiche Literaturrecherche in den Datenbanken „beck-online“, „Lindedigital“, „Springer E-Books“ betrieben. Zusätzlich wurden die Google Scholar Dienste in Anspruch genommen. Die folgenden Stichworte wurden für die Suche verwendet: „Predictive Analytics im Controlling“, „Predictive Analytics Implementierungsprozess“, „Data Mining“, „Business Analytics“. Zudem wurden die in der Bibliothek der FHWien der WKW zur Verfügung gestellten Werke zu Big Data sowie zu den Controllingprozesse herangezogen.

Derzeit gibt es jedoch nur sehr wenig Fachliteratur, die sich mit den Herausforderungen und Problemfeldern befassen, welche sich im Zuge des Implementierungsprozesses, sowie durch den Einsatz von Predictive Analytics im Controlling ergeben. Aus diesem Grund wurden im

Rahmen dieser wissenschaftlichen Arbeit neben der Literaturanalyse auch Interviews mit Experten<sup>1</sup> aus dem Bereich Controlling durchgeführt. Es wurden neun Interviews durchgeführt. Die Auswahl der Interviewpartner basiert auf deren Expertise im Controlling sowie ihren Erfahrungswerten bei der Anwendung und Implementierung von Predictive Analytics. Ziel der Interviews ist es, Informationen über den Implementierungsprozess zu erlangen. Es wird erforscht, welche Erfahrungen die Interviewpartner im Rahmen des Implementierungsprozesses gemacht haben und welche Herausforderungen bei der Implementierung von Predictive Analytics im Controlling identifiziert wurden.

Das „Problemzentrierte Interview“ wird als geeignetes Interviewverfahren im Rahmen dieser Analyse erachtet. Zu Beginn der empirischen Untersuchung wird ein Interviewleitfaden erstellt. Im Gegensatz zu einer standardisierten Befragung kann bei dieser Form des Interviewverfahrens flexibler agiert werden und der Gesprächsverlauf, beispielsweise durch die Reihenfolge der Fragen, besser strukturiert werden. Durch die erhöhte Flexibilität kann auf Antworten spezifischer eingegangen werden und somit kommt dem Interview eine bedeutende Explorativfunktion zu. Weiters können basierend auf den Ergebnissen der bereits durchgeführten Interviews laufend Adaptierungen durchgeführt werden und einzelne Fragestellungen näher beleuchtet werden (Mey & Mruck, 2007, S. 252). Der Interviewleitfaden orientiert sich an den Forschungsfragen und deckt die relevantesten Themen im Zusammenhang mit dem Implementierungsprozess von Predictive Analytics im Controlling ab. Eine nähere Erläuterung des Untersuchungsdesigns folgt in Kapitel 7. Die Interviews wurden transkribiert und mithilfe einer qualitativen Inhaltsanalyse ausgewertet und anschließend den Ergebnissen der Literaturrecherche gegenübergestellt.

## **1.5 Aufbau der Arbeit**

Die Arbeit kann in nachfolgende drei Teilbereiche gegliedert werden:

Der erste Teilbereich der Arbeit umfasst eine ausführliche Literaturanalyse, welche sich über die Kapitel 2 bis 6 erstreckt. Im Einklang mit den Ergebnissen aus der Literaturanalyse werden Kategorien gebildet und diese als Basis für den Interviewleitfaden herangezogen. In Kapitel 2

---

<sup>1</sup> Im Hinblick auf das Erfordernis der Verwendung diskriminierungsfreier Sprache wird festgehalten, dass unterschiedlichste Expert:innen kontaktiert wurden. Jedoch konnten ausschließlich männliche Experten für die Durchführung der Interviews gewonnen werden.

wird die Definition von Predictive Analytics im Rahmen dieser Arbeit eingrenzt und die Grundlagen werden näher erläutert, um ein Basiswissen zu schaffen. Kapitel 3 umfasst die Potenziale und Risiken, welche sich bei der Anwendung von Predictive Analytics ergeben sowie die wichtigsten Anwendungsbereiche von Predictive Analytics im Controlling. In den Kapiteln 4-6 erfolgt eine Beschreibung und Analyse des Implementierungsprozesses, dabei liegt der Fokus auf der Erkennung von Problemfeldern bei der Implementierung und der Erarbeitung von Lösungsansätzen.

Im zweiten Teilbereich der Arbeit, wird der empirische Forschungsteil der Arbeit thematisiert. Dieser setzt sich zum Großteil aus der Vorbereitung und Durchführung der ExpertInneninterviews zusammen und wird in Kapitel 7 dargestellt. Hierbei wird zu Beginn das Untersuchungsdesign beschrieben und die Vorgehensweise der empirischen Untersuchung erläutert. Weiters folgt eine Beschreibung des Interviewleitfadens und des Auswahlverfahrens der InterviewpartnerInnen. Im Anschluss an die Durchführung der Interviews folgte die Auswertung, das herangezogene Auswertungsverfahren wird ebenfalls in Kapitel 7 erläutert.

Im dritten Teilbereich liegt der Fokus auf den Ergebnissen der Datenauswertung. Die gewonnenen Informationen werden kategorisiert und aufbereitet. Weiters werden die erlangten Erkenntnisse zusammengefasst und den, im Rahmen der Literaturanalyse erörterten theoretischen Überlegungen gegenübergestellt. Dem folgt eine kritische Reflexion der Arbeit und ein Ausblick für die Zukunft. Weiters wird m Anhang der Interviewleitfaden zur Verfügung gestellt.

## **2 Predictive Analytics – Begriffsbestimmung und Grundlagen**

Grundlegend ist zu definieren, worum es sich bei Predictive Analytics handelt und wo es im Bereich Business Analytics einzuordnen ist. Weiters ist eine Negativabgrenzung bezüglich der Begriffsdefinition zu treffen. Die in den nachfolgenden Kapiteln behandelte Implementierung von Predictive Analytics setzt ein Verständnis der Grundlagen von Predictive Analytics voraus, auf welche im Folgenden näher eingegangen wird.

### **2.1 Hintergrund von Predictive Analytics**

Unter Predictive Analytics kann im weiteren Sinne auch die Prognose der Absatzplanung in Form einer Excel-Berechnung unter Anwendung der Forecast-Funktion verstanden werden. Diese Funktion verwendet die exponentielle Glättung zur Absatzplanung (Iffert, 2016, S. 17). Die exponentielle Glättung stellt ein sehr einfaches Prognoseverfahren dar, bei dem zukünftige Werte auf Basis einer historischen Zeitreihe prognostiziert werden. Dabei wird aktuelleren Daten eine höhere Relevanz beigemessen als älteren Daten der gleichen Zeitreihe (Hansmann, 1983, S. 27 - 28). Heutzutage werden Softwarelösungen eingesetzt, um diese Prozesse praktischer und einfacher zu gestalten. Die Software unterstützt bei der Bestimmung eines Prognosemodells, bei der Aufbereitung der Erkenntnisse sowie bei der Einarbeitung der Ergebnisse in das jeweilige ERP-System (Iffert, 2016, S. 17).

Allerdings ist Predictive Analytics nicht ausschließlich auf die Vorhersage zukünftige Ereignisse beschränkt. Vielmehr können nicht bekannte Ereignisse in jeglicher Zeitform bestimmt werden. Es spielt somit keine Rolle, ob das zu benennende Ereignis in der Vergangenheit, der Gegenwart oder der Zukunft liegt. Dementsprechend kommen Predictive Analytics auch bei der Ermittlung der Täter von bereits begangenen Straftaten zum Einsatz oder zur Identifizierung von Kreditkartentransaktionen, welche sich als Betrugsfälle herausstellen (Bentley, 2017, S. 37). Auch die österreichische Finanzverwaltung setzt Predictive Analytics im Rahmen der Abgabenerhebung, aber auch zur Bekämpfung der Finanzkriminalität ein (Hacker, 2022, S. 3-4).

Predictive Analytics ist jedoch keine „Silver Bullet“ und die wichtigste Komponente für das Funktionieren der Predictive Analytics-Tools bildet das dahinterstehende Wissen der betreffenden Personen. Denn die erstellten Prognosen können nur einen Mehrwert schaffen, wenn die



richtigen Daten in entsprechender Form aufbereitet werden, geeignete Methoden gewählt werden und die Ergebnisse nachvollzogen und sinnvoll interpretiert werden (Eckerson, 2007, S. 6). Den erwarteten Mehrwert liefern Predictive Analytics nur, wenn die zugrunde liegenden Prozesse sorgfältig durchlaufen wurden und die Qualität der Daten, sowie die getroffenen Annahmen für die Zukunft, entsprechend hoch ist (Bentley, 2017, S. 37). Hinsichtlich der Genauigkeit von Predictive Analytics-Tools, wird häufig die Frage aufgeworfen, ob Predictive Analytics einen „Blick in die Glaskugel“ ermöglicht oder eine glasklare Prognose liefert. Doch keine der beiden Beschreibungen ist vollkommen zutreffend (Damm, 2017, S. 86). Meines Erachtens vermittelt der Vergleich mit einer Glaskugel falsche Erwartungen an die Möglichkeiten von Predictive Analytics, denn die Techniken basieren wie erwähnt auf historischen Werten und somit können erstmalig in der Zukunft eintretende Ereignisse, wie beispielsweise die Covid-19-Krise, nicht in der Prognose berücksichtigt werden.

Nach Eckerson werden Predictive Analytics-Ansätze schon seit vielen Jahren verfolgt. Jedoch wurden frühere Ansätze unter dem Begriff Data Mining geführt. Insbesondere Softwarelösungsanbieter haben sich dazu entschieden, ihre Produkte und Leistungen als Predictive Analytics-Tools zu vermarkten, da der Begriff Data Mining in der Vergangenheit vielfältig benutzt wurde und ihm daher kein einheitliches Begriffsverständnis zukommt (Eckerson, 2007, S. 7). Die Data Mining zugrundeliegende Wissenschaft kann auf die 60iger bis 70iger Jahre zurückgeführt werden. Data Mining hat sich bereits vor geraumer Zeit durchgesetzt, wobei die Faszination an Data Mining jedoch über die Jahre hinweg verblasste und erst später wieder durch Predictive Analytics neu entfacht wurde. Predictive Analytics wird ebenso als Teil von Data Mining verstanden (Kotu & Deshpande, 2015, S. 1). Nach Abbott bildet Predictive Analytics eine Weiterentwicklung von Data Mining. Beide Techniken, also Predictive Analytics und Data Mining folgen den gleichen Ansätzen und wenden dieselbe Art von Algorithmen an. Die Prozesse und Techniken, die noch Anfang der 2000er Jahre allgemein hin als Data Mining bezeichnet wurden, werden heutzutage als Predictive Analytics verstanden (Abbott, 2014, S. 13).

## **2.2 Predictive Analytics als Teilbereich von Business Analytics**

Predictive Analytics stellt einen Teilbereich von Business Analytics dar. Um ein allgemeines Verständnis für den Begriff Predictive Analytics aufzubauen, wird in diesem Unterkapitel auf den Terminus Business Analytics eingegangen.

Bereits seit einigen Jahren ist der Begriff Business Analytics in allen wirtschaftlichen Bereichen vertreten und kaum noch wegzudenken. Im Laufe der Zeit und bedingt durch die steigende Popularität des Themas, war auch ein Anstieg der Definitionen von Business Analytics zu verzeichnen (Power, Heavin, McDermott & Daly, 2018, S. 40). Es gibt jedoch keine allgemein gültige Definition von Business Analytics, sondern eine Vielzahl variierender Definitionen. Alle Definitionen sind jedoch vom gemeinsamen Begriffsverständnis getragen, dass Business Analytics primär eine Unterstützung bei der Entscheidungsfindung darstellt (Power et al., 2018, S. 40).

Um sich einer Definition von Business Analytics zu nähern, ist es von Relevanz, die Begriffe Analytics und Analyse voneinander abzugrenzen. Häufig werden diese beiden Begriffe verwechselt oder synonym verwendet. Um ein Verständnis für die weiteren Prozesse zu schaffen, ist eine Unterscheidung jedoch unerlässlich. Bei der Analyse wird der zu untersuchende Gegenstand systematisch in seine Bestandteile aufgegliedert und es werden Muster und Auffälligkeiten ausgewertet (Lanquillon & Mallow, 2015a, S. 55). Der Begriff Analytics umfasst den gesamten Prozess, der zur Durchführung einer Datenanalyse erforderlich ist. Des Weiteren stellt Analytics den Überbegriff für statistische und auf Data Mining basierende Analysemethoden dar. Somit repräsentiert die Datenanalyse eine Teilkomponente von Data Analytics (Lanquillon & Mallow, 2015a, S. 55).

In diesem Kontext wird unter Business eine Vielzahl an Aktivitäten verstanden, welche in vielen unterschiedlichen Bereichen eines Unternehmens gesetzt werden, um die Geschäftstätigkeit durchzuführen (Power et al., 2018, S. 41). Im Rahmen von Business Analytics werden die Bereiche Data Science und Betriebswirtschaftslehre verknüpft und Standards wie analytisches Denken, technisches Wissen und die Fähigkeit zur geeigneten Datenillustration kombiniert (Mehanna, Tatzel & Vogel, 2016, S. 502).

Daraus kann abgeleitet werden, dass Business Analytics die Durchführung von Datenanalysen, die unternehmerische Fragestellungen adressieren, bezeichnet. Die Resultate werden herangezogen, um Probleme aufzuzeigen und Maßnahmen zu definieren sowie um als Entscheidungsgrundlage zu dienen (Power et al., 2018, S. 41). Business Analytics kann auch als „toolkit“ dargestellt werden, das unterschiedliche Tools und Technologien zur Erkenntnisgewinnung beinhaltet. Diese ermöglichen es, Erkenntnisse aus vorhandenen Daten zu gewinnen und basierend darauf unternehmerische Entscheidungen zu treffen (Chamoni & Gluchowski, 2017, S. 9).

Diese Darstellung von Business Analytics weist eine große Ähnlichkeit zu der Definition von Business Analytics als Entscheidungsunterstützung nach Laursen & Thorlund auf (Laursen & Thorlund, 2016, S. 248). Das Ziel von Business Analytics ist es, zur Verbesserung der Leistung eines Unternehmens beizutragen, indem datenbasierte Entscheidungsgrundlagen zur Verfügung gestellt werden (Mehanna et al., 2016, S. 502).

Konkret bedeutet das, dass Business Analytics ein Prozess ist, bei dem Daten eines Unternehmens mithilfe statistischer Analysen untersucht werden. Bei den Analysen wird versucht, Muster zu erkennen und neue Informationen aus den Daten zu gewinnen. Diese werden verwendet, um Geschäftsentwicklungen zu beschreiben und zu verbessern, sowie um zukünftige Entwicklungen zu prognostizieren. So kann beispielsweise aus vorhandenen Daten abgeleitet werden, welche Prozesse bereits gut integriert sind und in welchen Bereichen Verbesserungspotenziale bestehen (Delen & Ram, 2018, S. 2).

Eine Vielzahl an Unternehmen betrachtet die Anwendung von Business Analytics als Notwendigkeit, um ihre Wettbewerbsfähigkeit zu erhalten. Denn Unternehmen sind einem steigenden Wettbewerbsdruck ausgesetzt und versuchen in dieser Zeit der Schnelligkeit auf die veränderten Bedingungen der globalen Märkte zu reagieren. Business Analytics unterstützen Unternehmen hierbei und ermöglichen eine frühzeitige Problemerkennung. Dadurch können entsprechende Problemlösungen entwickelt werden und als Basis für eine zeitnahe Entscheidungsfindung herangezogen werden (Möller & Pieper, 2015, S. 41).

Business Analytics setzt sich aus nachfolgenden fünf Teilbereichen zusammen:

- Descriptive Analytics
- Diagnostic Analytics
- Real-Time Analytics
- Predictive Analytics
- Prescriptive Analytics

Jede dieser Varianten behandelt eine anderslautende Fragestellung. Nachfolgend werden die Teilbereiche kurz erläutert, siehe in diesem Zusammenhang Abbildung 1 (Mehanna et al., 2016, S. 503).




Abbildung 1. Analyse-Spektrum von BI und Business Analytics. (Lanquillon & Mallow, 2015, S. 56)

**Descriptive Analytics** beschäftigt sich mit der Fragestellung, „Was ist in der Vergangenheit geschehen?“. Dies entspricht dem Unternehmensreporting, da die unter Descriptive Analytics fallenden Aktivitäten meist in Verbindung mit der Aufbereitung von Berichten über den Verlauf der Geschäftstätigkeit zusammenhängt. Hierbei werden häufig konfigurierbare Dashboards eingesetzt, um Daten mithilfe visueller Illustrationen übersichtlicher und verständlicher in der gewünschten Form zur Verfügung zu stellen (Delen & Ram, 2018, S. 8).

**Diagnostic Analytics** entspricht einer Vertiefung von Descriptive Analytics und befasst sich mit der Fragestellung, „Warum ist etwas in der Vergangenheit geschehen?“. Es sollen die Ursachen für das Eintreten gewisser Ereignisse bestimmt werden (Lanquillon & Mallow, 2015a, S. 57). Unter Diagnostic Analytics fällt unter anderem die Anwendung von OLAP-Systemen (Online Analytical Processing). OLAP-Systeme ermöglichen die mehrdimensionale Analyse von Geschäftsdaten. Beispielsweise lässt sich der Detaillierungsgrad der dargestellten Daten

über Drill-down erhöhen. Hier ist etwa daran zu denken, dass das Umsatzwachstum nach einzelnen Produkten aufgeschlüsselt werden kann, um Zusammenhänge festzustellen und diese auf weitere Daten übertragen zu können (Ereth & Kemper, 2016, S. 459).

**Real-Time Analytics** verfolgen das Ziel, Daten in Echtzeit zu verarbeiten und adressieren die Fragestellung „Welche aktuellen Ereignisse finden statt?“. Die Daten werden, sobald sie im System erfasst wurden, aufbereitet und analysiert, um die Zeitspanne zwischen dem Eintritt des Ereignisses und der Maßnahmensetzung möglichst gering zu halten. Somit können Unternehmen schneller reagieren und Chancen zeitnah nutzen bzw. Probleme lösen, bevor negative Auswirkungen auftreten. Beispielsweise werden diese Ansätze beim Monitoring der operativen Steuerung verwendet (Lanquillon & Mallow, 2015a, S. 57-59).

**Predictive Analytics** bieten nicht wie die bisher genannten Analytics-Varianten statische, vergangenheitsorientierte Ansätze, sondern Prognosemöglichkeiten. Der Fokus liegt auf der Fragestellung „Was wird passieren?“. Basierend auf mathematischen Modellen werden zukünftige Ereignisse vorhergesagt, siehe dazu Kapitel 2.3 (Ereth & Kemper, 2016, S. 460).

**Prescriptive Analytics** stellen eine erweiterte Betrachtung von Predictive Analytics dar und befassen sich mit der Fragestellung „Was soll geschehen?“. Prescriptive Analytics ermitteln die beste Handlungsalternative, um die gesetzten geschäftlichen Ziele zu erreichen. Die möglichen Handlungsalternativen werden im Allgemeinen durch eine Kombination aus Descriptive und Predictive Analytics bestimmt (Delen & Ram, 2018, S. 9). In einigen Fällen werden nicht nur Maßnahmen zur Zielerreichung vorgeschlagen, sondern es erfolgt eine automatisierte Umsetzung dieser Maßnahmen. Durch lernende Algorithmen können Prozesse im Hinblick auf konkrete Anforderungen optimiert werden. Hier ist beispielsweise daran zu denken, dass Produktionsprozesse hinsichtlich ihrer Kapazität verbessert und Leerläufe vermieden werden (Mehanna et al., 2016, S. 505).

Häufig werden Predictive Analytics und Prescriptive Analytics auch als Advanced Analytics bezeichnet, da diese beiden Varianten zukunftsorientiert sind und die Methoden der Statistik und des maschinellen Lernens verfolgen. Somit gehen Predictive Analytics und Prescriptive Analytics über die Funktionen von „Basic Analytics“ – also vergangenheitsorientierte, deskriptive Analyseformen, welche unter den Begriff Business Intelligence (BI) subsumiert werden können – hinaus. Dadurch erfolgt sogleich eine Abgrenzung zwischen Business Analytics und

BI, bzw. kann Business Analytics als Erweiterung von BI angesehen werden (Lanquillon & Mallow, 2015a, S. 62).

### **2.3 Definition von Predictive Analytics**

Wie bereits erwähnt stellen Predictive Analytics ein Einsatzgebiet von Business Analytics dar. Im Gegensatz zu BI folgt Predictive Analytics einer induktiven Vorgehensweise. Es werden vorab keine Hypothesen getroffen, welche anschließend mithilfe der zur Verfügung stehenden Daten unterlegt werden, sondern es wird die Gesamtheit der Daten untersucht und daraus werden Schlussfolgerungen gezogen. Bei BI Techniken, verfügen die Anwendenden bereits über Kenntnisse dahingehend, welche Verbindung die Daten zueinander vorweisen bzw. welche Tendenzen die Daten enthalten. Basierend auf ihren Vorkenntnissen werden Hypothesen gebildet, die beispielsweise durch OLAP-Systeme hinterlegt und bestätigt werden sollen. Daraus kann eine deduktive Vorgehensweise abgeleitet werden (Eckerson, 2007, S. 6).

Predictive Analytics bezeichnet die Anwendung von mathematischen Modellen und Methoden an großen Datenmengen, um nutzenstiftende Erkenntnisse aus den Daten zu gewinnen und darauf basierend zukünftige Ereignisse und deren Eintrittswahrscheinlichkeiten vorherzusagen (Iffert, 2016, S. 17). Hierbei werden historische Daten auf Verknüpfungen zwischen den Variablen analysiert, um daraus Informationen zu generieren und mögliche Muster in den Daten zu bestimmen. Basierend auf den identifizierten Mustern und Trends in den Daten können potenzielle auftretende Risiken und Chancen erkannt, vorhergesagt und bewertet werden (Bentley, 2017, S. 37). Die erkannten Muster und Trends werden durch Algorithmen angelernt und diese werden dann in Form eines Modells verwendet, um Vorhersagen zu treffen (Stephan & Grether, 2020, S. 45).

Das Konzept von Predictive Analytics zur Erstellung von Prognosen ist keine neue Entdeckung. Bereits im 19. Jahrhundert wandte der Mediziner Dr. Snow in Großbritannien ähnliche Methoden an, um die Verbreitung einer Epidemie einzudämmen. Er markierte die Todesfälle auf einer Karte und konnte dadurch das Epizentrum lokalisieren. In dessen Mitte war eine Wasserpumpe angesiedelt, auf welche sich die Verbreitung der Epidemie zurückführen ließ. Dem Mediziner war es gelungen, durch eine Aufarbeitung und Visualisierung der historischen Ereignisse Zusammenhänge zu erkennen und weitere Todesfälle abzuwenden (Damm, 2017, S. 83).

In den letzten Jahren gab es große Änderungen hinsichtlich der zur Analyse zur Verfügung stehenden Daten und der Möglichkeiten diese Datenmengen zu verarbeiten. Vor allem Begriffe wie Big Data spielen hierbei eine maßgebliche Rolle (Stephan & Grether, 2020, S. 43). Durch den Einsatz von fortschrittlichen Predictive Analytics-Techniken, können selbst Big Data erfasst werden (Iffert, 2016, S. 17).

## **2.4 Big Data**

Big Data nimmt erheblichen Einfluss auf die Controllingprozesse und bietet unter anderem Möglichkeiten zur Verbesserung der Informationsaufbereitung und der Datenanalyse. Ein verbessertes Prozessverständnis sowie eine Transparenzsteigerung wird durch die Erschließung neuer Datenmengen (wie beispielweise Daten über die Geschäftsprozesse und das Kundenverhalten) ermöglicht. Die Datenanalyse sowie die Aufbereitung und Bereitstellung der Informationen lässt sich durch Big Data weitgehend automatisieren und erlaubt eine Effizienzsteigerung bei den Controllingprozessen (Gänßlen & Losbichler, 2014, S. 145).

Big Data wird häufig durch die sogenannten „Vier V“ Merkmale beschrieben: Volume, Variety, Veracity and Velocity. Es handelt sich um die Schaffung und gleichzeitige Verarbeitung immenser Datenmengen (Volume), welche verschiedene Datenformate aufweisen (Variety), deren Ursprung oftmals nicht vertrauenswürdige Quellen darstellen (Veracity) bei sehr hoher Geschwindigkeit (Velocity) (Lanquillon & Mallow, 2015b, S. 260).

In manchen Definitionen werden diese vier Vs zum Teil noch um ein bis zwei Vs ergänzt. Zum einen stellt Value das fünfte V dar und beschreibt den Nutzen, den Big Data einem Unternehmen durch die gewonnenen Erkenntnisse bringt (Singh & Singh, 2017, S. 822). Zum anderen werden die definierenden Merkmale noch um Variability erweitert. Variability bringt zum Ausdruck, dass bei der Erzeugung von Datenströmen Abweichungen bei der Geschwindigkeit und Qualität auftreten können und dass ohne die erforderliche Flexibilität derartige Abweichungen die Ergebnisse beeinträchtigen würden (Rehman et al., 2016, S. 267).

Gerne wird Big Data auch als polystrukturierte Daten bezeichnet, da nicht nur strukturierte Daten, wie zum Beispiel tabellarische Daten (jene Daten, die aus den ERP-Systemen stammen), sondern auch teilstrukturierte und unstrukturierte Daten, wie beispielsweise Videodateien, verarbeitet werden (Gadatsch, 2016, S. 63). Bei Big Data handelt es sich um Datenmengen, deren

Größe in der Regel die Kapazitäten gewöhnlicher Datenverarbeitungssysteme überschritten hat. Aus diesem Grund wurden eigene Verarbeitungssysteme geschaffen, für die die Handhabung großer Datenmengen keine Herausforderung darstellt. Diese Big Data Datenverarbeitungssysteme werden oft unterstützend bei Data-Mining-Verfahren eingesetzt (Provost & Fawcett, 2017, S. 31).

## **2.5 Data Mining**

Nach allgemeinem Verständnis bezeichnet Data Mining den Prozess, in dem relevante Muster in großen Datensätzen identifiziert werden (Keating, 2008, S. 33). Synonym für Data Mining wird auch der Begriff „Knowledge Discovery“ (d.h. Wissensentdeckung) verwendet (Kotu & Deshpande, 2015, S. 2-3). Data Mining zeichnet sich unter anderem dadurch aus, dass bei der Anwendung des Verfahrens Informationen und Muster in den Datensätzen erkannt werden, deren Existenz vor der Analyse nicht bekannt war. Dadurch grenzt sich Data Mining von gewöhnlichen Datenabfragen ab. Bei diesen werden Informationen abgefragt, von denen bereits feststeht, dass sie in den Datensätzen enthalten sind (Lee, 2013, S. 55). Data Mining kombiniert Techniken und Wissen aus den Bereichen künstliche Intelligenz, Statistik, Machine Learning und Datenbankarchitektur. Ein wichtiges Kriterium für ein nutzenbringendes Data Mining-Verfahren, ist ein profundes Wissen über die Daten generierenden Geschäftstätigkeiten bzw. geschäftlichen Abläufe als auch über die Daten per se (Kotu & Deshpande, 2015, S. 2-3).

Es kann zwischen überwachten und unüberwachten Lernverfahren zur Erstellung eines Prognosemodells unterschieden werden (Chamoni & Gluchowski, 2017, S. 11).

Bei einem überwachten Lernverfahren werden historische Daten und die daraus bereits gewonnenen Erkenntnisse zur Verfügung gestellt, um die Beziehungen der Variablen nachvollziehen und erlernen zu können (Eckerson, 2007, S. 7). Es wird anhand von den zur Verfügung gestellten Inputvariablen die unbekannte, zu bestimmende Variable vorhergesagt (Kotu & Deshpande, 2015, S. 9). Möchte etwa ein:eine Vertriebsleiter:in wissen, welche Kund:innen voraussichtlich bei einem Gewinnspiel mitmachen werden, würden die Kundendaten aus dem zuletzt organisierten Gewinnspiel herangezogen werden, um daraus die Kundenmerkmale zu erlernen (Eckerson, 2007, S. 7). Zu den überwachten Lernverfahren zählen unter anderem die Zeitreihenanalyse, Regressionsverfahren, Klassifikationsverfahren (Chamoni & Gluchowski, 2017, S. 11).



Im Gegensatz zu den überwachten Lernverfahren werden bei dem Prozess der Erstellung des Prognosemodells bei den unüberwachten Lernverfahren keine bekannten Beziehungen der Variablen, also keine Lernmuster, zur Verfügung gestellt. Bei den unüberwachten Lernverfahren werden keine Prognosen erstellt. Die Daten werden auf Verbindungen der Variablen untersucht und es wird versucht, Muster zu identifizieren. Bei dem Prozess werden neue, unabhängige Hypothesen, basierend auf den zugrunde liegenden Daten gebildet (Kotu & Deshpande, 2015, S. 8). Zu den unüberwachten Lernverfahren werden unter anderem Prognosen basierend auf Assoziationsanalysen, Sequenzmusteranalysen und Segmentierungsverfahren zugeordnet (Chamoni & Gluchowski, 2017, S. 11).

Um einen effizienten Projektablauf sicherzustellen wird, analog zu größeren Projekten in anderen Bereichen, ein Standard-Vorgehensmodell verfolgt. Bei der Umsetzung von Predictive Analytics-Projekten kommt häufig das Konzept des Cross Industry Standard Process for Data Mining (CRISP-DM) zum Einsatz, welches nachfolgend im Kapitel 4.2 näher beschrieben wird (Abmann, Sauer & Schulz, 2020, S. 3). Weitere Konzepte, die bei der Durchführung von Predictive Analytics-Projekten als Rahmen herangezogen werden sind der KDD-Prozess (Knowledge Discovery in Databases-Process) nach Fayyad und der SEMMA-Prozess. Bei dem KDD-Prozess nach Fayyad wird die iterative Vorgehensweise innerhalb des Projekts in die Phasen Datenauswahl, Datenvorverarbeitung, Datentransformation, Data Mining und der Interpretation der Ergebnisse untergliedert (siehe Abbildung 2) (Haneke, Trahasch, Zimmer & Felden, 2019, S. 9-11).

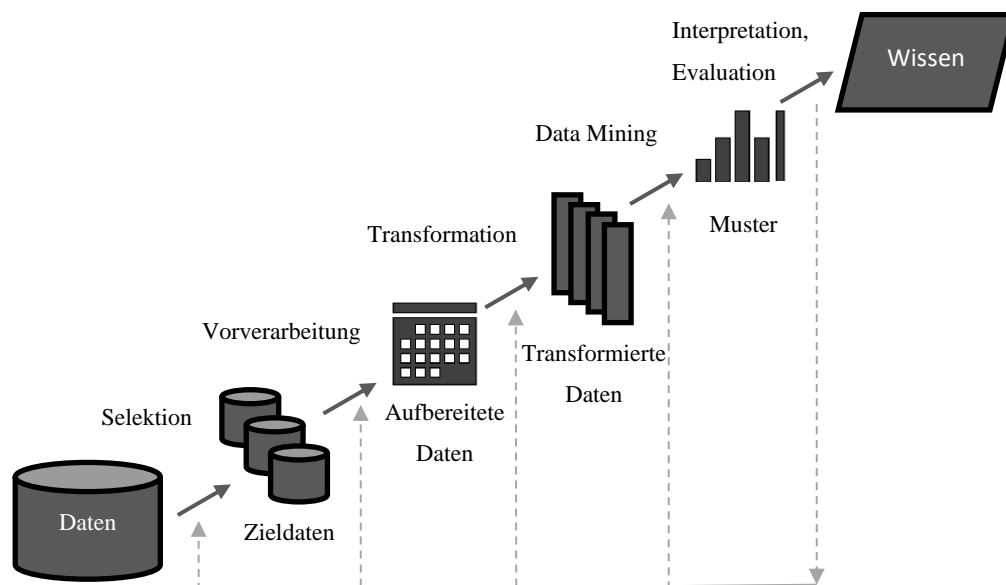


Abbildung 2. KDD Prozess. (Haneke et al., 2019, S. 11)

Das Konzept nach Fayyad beinhaltet eine Vielzahl von Schritten, welche in den einzelnen Phasen durchgeführt werden müssen, um ein Verständnis für den gesamten Prozess und dadurch auch für das daraus resultierende Ergebnis aufbauen zu können (Azevedo & Santos, 2008, S. 183). Der SEMMA-Ansatz stellt ebenfalls den Projektablauf in Phasen dar. Die Bezeichnung SEMMA steht für die fünf Phasen des Projekts: Sample (Datenauswahl), Explore (Datenverständnis), Modify (Anpassung), Model (Algorithmus Anwendung) und Assess (Evaluation) (Haneke et al., 2019, S. 11). In der Praxis werden die Konzepte durchaus auch miteinander kombiniert und um einzelne Teilschritte erweitert (Iffert, 2016, S. 19).

Die Modelle werden mit Unterstützung der Lernverfahren basierend auf den aufbereiteten Daten erstellt. Bei einem Modell handelt es sich in diesem Kontext um ein Resultat der Analyse, d.h. abhängig von den zu behandelnden Fragestellungen sowie von den angewandten Lernverfahren. Somit wäre das Resultat bzw. das Modell einer Klassifizierung der Klassifikator. Es werden jedoch auch Entscheidungsbäume als Modell bezeichnet. Gleiches gilt beim Clustering, wo die Gliederung der Daten in Cluster als Modell bezeichnet wird (Lanquillon & Mallow, 2015a, S. 72).

In den nachfolgenden Kapiteln wird mehrfach der Einsatz der Berufsgruppe Data Scientists beschrieben. Aus diesem Grund wird vorweg klargestellt, was unter einem Data Scientist verstanden wird und welche Aufgabenbereiche dieses Berufsbild in der Regel abgedeckt. Data Scientists sind Experten, welche sowohl über IT- als auch statistische Fähigkeiten verfügen und mit den relevanten betriebswirtschaftlichen Zusammenhängen und Prozessen vertraut sein sollten. Ihre Fähigkeiten werden im Rahmen von Predictive Analytics-Projekten in Anspruch genommen. Die zentralen Aufgaben eines Data Scientists in einem Predictive Analytics-Projekt sind die Beschaffung der erforderlichen Daten und die Aufbereitung der Rohdaten zu einer strukturierten Datenbasis, sodass die Algorithmen auf die Daten angewandt werden können (Chamoni & Gluchowski, 2017, S. 15-16). Die Aufgabenaufteilung kann jedoch von Projekt zu Projekt etwas variieren und das Controlling kann Teile dieser Aufgaben übernehmen (Fink, 2021, S. 149).

### 3 Anwendungsbereiche von Predictive Analytics im Controlling

Im folgenden Kapitel werden die Anwendungsbereiche und Potenziale von Predictive Analytics im Controlling dargestellt. In einem ersten Schritt wird untersucht, in welchen Unternehmensbereichen, abgesehen von dem Controllingbereich, Predictive Analytics zur Anwendung kommt. Dies ist insofern relevant, da Predictive Analytics in vielen Unternehmensbereichen eine Vorreiterrolle zu kommt (Winters, 2017, S. 7). Hier ist zunächst an den Bereich Marketing zu denken. Predictive Analytics kommt beispielweise zum Einsatz, um Kund:innen durch spezielle Kundentreueprogramme und die passende Kundenansprache zu binden sowie um Kund:innen vom Kauf weiterer, nicht direkt nachgefragter Produkte zu überzeugen (Chamoni & Gluchowski, 2017, S. 13). Im Produktionsbereich und in der Logistik werden Predictive Analytics etwa eingesetzt, um die Kapazitätsplanung und die Lagerverwaltung zu verbessern (Tischler & Fuchs, 2022, S. 19). Ein weiteres Einsatzfeld ist Predictive Maintenance, also die Erstellung von Vorhersagen, zu welchem Zeitpunkt Wartungen durchgeführt werden sollten. Zudem werden Predictive Analytics-Methoden angewandt, um bei der Risikobewertung (z.B. bei der Bestimmung des Ausfallsrisikos einer Kundschaft) und bei der Betrugserkennung (z.B. Kreditbetrug) zu unterstützen (Stephan & Grether, 2020, S. 44).

Predictive Analytics-Tools werden nicht nur von Unternehmen eingesetzt, sondern auch die öffentliche Verwaltung bedient sich dieses Instruments. Bereits im Jahr 2016 hat das österreichische Bundesministerium für Finanzen eine selbstständige Organisationseinheit, das Predictive Analytics Competence Center, eingerichtet, um die Vorteile vollumfänglich nutzen zu können (Setnicka, 2016, S. 322). Predictive Analytics-Methoden werden von der österreichischen Finanzverwaltung angewandt, um bei Prüfungen und der Betrugsbekämpfung zu unterstützen (Hacker, 2022, S. 3). Die Aufgabe der Abgabenbehörden ist, die Gleichmäßigkeit der Besteuerung sicherzustellen, also darauf zu achten, dass alle Abgabepflichtigen erfasst und gleichmäßig behandelt werden und darüber zu wachen, dass Abgabeneinnahmen nicht zu Unrecht verkürzt werden (§ 114 Abs. 1 BAO; vgl. weiterführend Ritz & Koran, 2021, § 114, Rz 1-4). Im Zuge von etwa 15.000 Außerprüfungen und 22.000 Lohnabgabenprüfungen pro Jahr überprüft die Steuerverwaltung die richtige und vollständige Steuerabfuhr. Bei der Auswahl der Prüfungsfälle wurden bisher unterschiedliche Methoden eingesetzt, wie beispielsweise die Einzelauswahl oder Zeitauswahl. Jedoch erfolgte die Fallauswahl immer auf Basis der Erfahrungen und Fachkenntnisse der Expert:innen und enthält somit einen sehr subjektiven Charakter. Die Problematik bestand jedoch darin, jene Unternehmen für die Prüfungen auszuwählen, bei denen

ein höheres Risiko zur Abgabenverkürzung besteht, als bei durchschnittlichen Unternehmen (Setnicka & Madlberger, 2020, S. 252). Aus diesem Grund implementierte das Bundesministerium für Finanzen Predictive Analytics-Tools zur Fallauswahl, um die Trefferquote bei der Auswahl zu erhöhen und somit gemäß dem Pareto-Prinzip mit 20% des Aufwandes, 80% der Ergebnisse erzielen (Setnicka, 2016, S. 323). Basierend auf den Daten früherer Prüfungsfeststellungen bzw. Betrugsfälle werden Muster identifiziert und Rückschlüsse für ähnlich gelagerte Fälle gezogen (Setnicka, 2020, S. 30).

### **3.1 Digitalisierung im Controlling**

Bei der Anwendung von Data Mining bzw. Advanced Analytics-Tools gab es einen großen Wandel in den letzten Jahren. In den 90iger Jahren wurden Advanced Analytics-Tools nur in wenigen, sehr fortschrittlichen Unternehmen angewandt. Für die große Mehrheit der Unternehmen wäre daran nicht erst zu denken gewesen, da es in einem ersten Schritt die Herausforderung der Datenspeicherung und Datenverwaltung zu überwinden galt. Doch heutzutage sind Predictive Analytics kein Nischenprodukt mehr, die Tools werden auch bei klein und mittelgroßen Organisationen eingesetzt (Abbott, 2014, S. 13-14). Die Entwicklungen können unter anderem auf den Anstieg der zur Verfügung stehenden Datenmengen und die gesteigerten Rechenkapazitäten, die zur Verfügung stehen, um die Daten speichern und auswerten zu können, zurückgeführt werden (Leyk, Kirchmann & Tobias, 2017, S. 52). Doch der Anstieg der verfügbaren Datenmengen, schafft für ein Unternehmen per se keinen Mehrwert. Ein Mehrwert kann nur geschaffen werden, wenn aus den Daten neues Wissen generiert werden kann und ein Erkenntnisgewinn stattfindet (Engelbergs, 2017, S. 256).

### **3.2 Einsatzbereiche von Predictive Analytics im Controlling**

Die Hauptfunktion des Controllings ist die Unterstützung des Managements bei der Unternehmenssteuerung. Mithilfe von zahlreichen Tools und Methoden stellt das Controlling Informationen bereit, welche als Entscheidungsgrundlage dienen (Kieninger & Schimank, 2017, S. 5). Zu den wesentlichsten Anwendungsbereichen von Predictive Analytics im Controlling zählen die Planung, die Forecast-Erstellung und die Budgetierung. Predictive Analytics wird eingesetzt, um Umsatzprognosen, Materialkostenplanungen, Liquiditätsplanungen etc. effizient zu erstellen (Stephan & Grether, 2020, S. 43). Darüber hinaus werden die Möglichkeiten von Predictive Analytics im Reporting genutzt (Isensee & Hüsler, 2020, S. 37). Weiters haben sich

über die Jahre hinweg die Potenziale von Predictive Analytics im Bereichscontrolling – worunter das Vertriebs- und das Personalcontrolling fallen – herauskristallisiert. Auf die Anwendungsmöglichkeiten in diesen Controllingbereichen wird in den Kapiteln 3.2.4 und 3.2.5 näher eingegangen.

### **3.2.1 Planung mit Predictive Analytics**

Die Erstellung einer Planung ist eine wesentliche Aufgabe des Controllings und eine notwendige Maßnahme, um ein Unternehmen bewusst steuern zu können. Eine Prognose über die zukünftige Unternehmensentwicklung bildet hierbei die Basis für die Planung der Ressourcenverteilung und der finanziellen Mittel. Anhand der erstellten Prognosen über die zukünftigen Entwicklungen welche beispielsweise die Umsatzentwicklung, Kostenentwicklung, Personalentwicklung, etc. beinhalten, können Budgets festgelegt und Zielsetzungen definiert werden (Möller, Federmann, Pieper & Knezevic, 2016, S. 510). Jener Aufwand, der mit der manuellen Planung einhergeht, nimmt in vielen Fällen einen Großteil der zeitlichen Ressourcen der Controller:innen ein. In einer im Jahr 2019 durchgeführten Studie des ‚Big Four‘-Beratungsunternehmens KPMG, gaben mehr als die Hälfte der 49 Teilnehmenden (CFOs, Controllingleiter:innen, Controllingmitarbeitende) an, ihre Planungen nicht fristgerecht finalisieren zu können und somit mit ihren Planungen regelmäßig in Verzug zu geraten. Bei einem Drittel der Befragten dauert der Planungsprozess sogar länger als vier Monate. Dementsprechend unzufrieden hat sich der Großteil der Studienteilnehmenden über den Planungsprozess geäußert (Bley, Giesel & Ruhwedel, 2020, S. 49). Mithilfe von Predictive Analytics kann der Planungsprozess schneller und effizienter durchgeführt werden. Die Planungswerte bzw. deren Eintrittswahrscheinlichkeiten werden von Vorhersagemodellen prognostiziert und müssen im Anschluss von den Controller:innen lediglich validiert werden. Auf diese Weise können beispielsweise Umsatzplanungen basierend auf den aktuellen Marktentwicklungen und den Umsatzentwicklungen der Vergangenheit erstellt werden (Grönke & Ahr, 2017, S.136). Durch die Anwendung von Predictive Analytics gestalten sich die Planungsprozesse flexibler und ressourcenschonender. Dies ermöglicht ein Umdenken bei der Planung beispielsweise könnte von der klassischen Jahresplanung auf eine Quartals- oder Monatsplanung umgestellt werden und der Planungsprozess an das Geschäftsmodell anpasst werden (Nobach, Zirkler & Hofmann, 2020, S. 59).

### **3.2.2 Forecasting mit Predictive Analytics**

Das Forecasting stellt ein zentrales Steuerungsinstrument des Controllings dar. Es wird zur Kontrolle und Unterstützung der Zielerreichung innerhalb der betrachteten Periode eingesetzt. Forecasts werden in einem Unternehmen erstellt, um auf Basis der aktuellen Situation zu ermitteln, wo die Organisation am Ende der Zielperiode stehen wird. Es wird somit anhand von Ist-Werten die aktuelle Lage des Unternehmens festgestellt und auf dieser Grundlage eine Prognose für die Zielperiode erstellt. Anhand des Forecasts können Abweichungen zur Planung festgestellt werden und frühzeitig Handlungsinitiativen eingeleitet werden. Ziel ist es, die betroffenen Bereiche wieder „on track“ zu bringen, sodass die Planungswerte erreicht werden können (S. D. Becker & Schäffer, 2017, S. 9). Dem Forecasting kommt somit eine essenzielle Steuerungsfunktion zu (Nasca, Munck & Gleich, 2018, S. 84).

Forecasts können regelmäßig oder anlassbezogen – bei Bedarf – erstellt werden. Hierbei gibt es keine allgemeingültige Empfehlung. Die Entscheidung, wann und wie häufig Forecasts erstellt werden sollen, ist individuell von den Unternehmen zu treffen. Dabei sollten das Geschäftsmodell sowie die Veränderungshäufigkeit und Wesentlichkeit der zu berücksichtigenden Faktoren beachtet werden (Jenßen & Klatt, 2004, S. 262). Analog zu dem hohen Aufwand der Planungsprozesse, gestaltet sich das Forecasting gleichermaßen als zeitintensive Controllingaufgabe (S. D. Becker & Schäffer, 2017, S. 9). Daher wird bei der Erstellung eines Forecasts geraten, den Blick auf das Wesentliche zu konzentrieren und keine insignifikanten Details auf Kostenstellenebene bei der Prognose zu berücksichtigen (Schulze, Thiele & Gleich, 2019, S. 65). Bei manuell erstellten Forecasts ist das – neben dem außer Acht lassen individueller Ansichten und Erwartungen – jedoch häufig eine der größten Herausforderungen. Eine Lösung bieten digitale Forecasts, welche mithilfe von Algorithmen erstellt werden (S. D. Becker & Schäffer, 2017, S. 14).

#### **Digitale Forecasts**

Digitale Forecasts sind computergestützte Vorhersagen, welche statistische und mathematische Techniken bei den zur Verfügung stehenden Daten anwenden, um eine Effizienzsteigerung zu erzielen (Mayer, Stegmüller & Zeibig, 2017, S. 231). Digitale Forecasts bieten die Möglichkeit, bei reduziertem Aufwand genauere Ergebnisse zu erzielen. Die auf Predictive Analytics basierenden Prognosen überzeugen durch ihren Detaillierungsgrad, ihrer Aktualität und der verbesserten Prognosegenauigkeit. Ausschlaggebend hierfür sind die erhöhte Datenverfügbarkeit und

die fortschrittlichen Predictive Analytics-Methoden, welche einen maßgeblichen Einfluss auf die Qualität der Planung nehmen. Mithilfe der umfangreichen Datenmengen können die Eintrittswahrscheinlichkeiten für die Prognosen präziser prognostiziert werden (Kieninger & Schimank, 2017, S. 9). Dementsprechend überzeugen digitale Forecasts durch eine höhere Qualität als bei manuellen Forecasts (Brauchle & Hanisch, 2017, S. 213). Immer wieder wurden in der Vergangenheit von Expert:innen Versuche gestartet, das optimale Vorhersagemodell beispielsweise in Excel selbst zu entwerfen. Es gelang hoch komplexe Modelle zu erstellen, jedoch wurde die gewünschte Genauigkeit der Prognosen niemals erreicht. Einer der erschwerenden Gründe für die Erstellung manueller Forecasts liegt in der Dynamik und Schnelllebigkeit der Wirtschaft. Diese damit verbundene Komplexität lässt sich nur sehr schwer abbilden und in Modellen erfassen. Weiters ist eine große Datenbasis erforderlich, um die Prognosegenauigkeit zu erhöhen. In manuellen Forecasts können nicht derart große Datenmengen, wie Predictive Analytics-Tools diese anwenden, verarbeitet werden (Mayer et al., 2017, S. 231).

### **Potenziale des digitalen Forecasts**

Digitale Forecasts können jederzeit ad hoc erstellt werden. Es sind im Vergleich zu dem herkömmlichen Forecasting keine langen Erstellungszeiten zu berücksichtigen (Bischof & Wilfinger, 2018, S. 164). Für die Erstellung digitaler Forecasts ist nur ein Knopfdruck erforderlich, was den Anforderungen der Schnelllebigkeit, mit der Unternehmen heutzutage konfrontiert werden, entspricht. Es besteht der Bedarf, kurzfristig, schnell und zunehmend aktuelle Prognosen zu erstellen, sodass die Informationen zeitnah zur Verfügung gestellt werden (Leyk et al., 2017, S. 54). Die kurzfristige Erstellung von Forecasts mithilfe von Predictive Analytics Lösungen schafft die Möglichkeit zeitgerecht auf veränderte Bedingungen zu reagieren und somit die Wettbewerbsfähigkeit aufrecht zu erhalten (Seufert & Oehler, 2016, S. 75). Zusätzlich erlaubt die erhöhte Flexibilität von digitalen Forecasts, diese zur Szenario-Simulation anzuwenden, welche eine unterstützende Rolle im Entscheidungsfindungsprozess bildet (Bayerl, 2020, S. 293).

Ein weiterer Vorteil der digitalen Forecasts im Vergleich zu den herkömmlichen Forecasts, ist die erhöhte Aktualität. Die Ergebnisse der digitalen Forecasts basieren auf den aktuellsten vorhandenen Daten (Kieninger & Schimank, 2017, S. 9). Häufig treten bei manuellen Forecasts lange Planungszeiten auf, es werden Inputs gesammelt, diese werden aggregiert und durchlau-

fen dann zahlreiche Abstimmungsrunden. Nicht selten kommt es bei diesem Prozess zu Verzögerungen. Bis zum Vorliegen der finalen Prognose hat sich der Wissensstand bereits mehrfach geändert, da in der Regel zwischenzeitlich aktuellere Daten vorhanden sind, welche nachträglich jedoch nicht in den Forecast miteinbezogen werden können (Bley et al., 2020, S. 49). Im Vergleich zu den klassischen Forecasts kann somit auf Basis der Ergebnisse der digitalen Forecasts zeitnah auf die zugrundeliegenden Geschehnisse reagiert werden. Zum Beispiel kann bei signifikanten Abweichungen kurzfristig ein Meeting mit den jeweiligen Verantwortlichen einberufen werden, um die Ursachen zu erörtern und gegebenenfalls unmittelbar einen Handlungsplan mit Gegenmaßnahmen zu implementieren. Die Chance zeitnah auf die Ergebnisse des Forecasts zu reagieren wird durch digitale Forecasts ermöglicht, da deren Grundlage die aktuellsten Informationen darstellen. Vorab fixierte Abstimmungsmeetings, welche häufig starr abgehalten werden, ohne bestehende Notwendigkeit und ohne einen Mehrwert zu schaffen, könnten auf diese Weise zumindest reduziert werden (Schäffer, 2017, S. 38).

Wie bereits erwähnt ist die manuelle Erstellung von Forecasts sehr aufwändig und zeitintensiv und es besteht wie bei allen manuellen Prozessen ein höheres Risiko für Fehler. Zudem muss bei klassischen Forecasts davon ausgegangen werden, dass die Interessen einzelner sowie deren subjektive Ansichten in den Forecasts berücksichtigt wurden. Im Gegensatz dazu sind digitale Forecasts durch ihre Automatisierung weniger fehleranfällig und weisen einen höheren Grad an Objektivität auf (Stephan & Grether, 2020, S. 44). Subjektive Erwartungen finden keinen Eingang in die algorithmenbasierten Forecasts und damit einhergehende systematische Verzerrungen können vermieden werden (S. D. Becker & Schäffer, 2017, S. 14). In vielen Unternehmen werden die klassischen Forecasts zu umfangreich aufgebaut. Dabei werden irrelevante Details erfasst, die den Blick auf das Entscheidende verstellen und das Verständnis für den Gesamtzusammenhang erschweren (Schäffer, 2017, S. 35).

Während klassische Forecasts externe Informationen selten miteinbeziehen, werden im Zuge von digitalen Forecasts sowohl interne als auch externe Faktoren ausreichend berücksichtigt (Stephan & Grether, 2020, S. 44). Auch exogene Aspekte können in Forecasts, welche mit Predictive Analytics-Tools erstellt wurden, beachtet werden. Im Zuge des Implementierungsprozesses werden exogene Faktoren, wie beispielsweise Marktpreise und gesetzliche Änderungen, auf deren Einfluss in der Vergangenheit untersucht. Im Anschluss wird entschieden, ob es sich um wesentliche Einflussfaktoren handelt, welche in den Prognosen berücksichtigt werden sollten (Sanders, Fiedler & Radtke, 2021, S. 38).



### 3.2.3 Reporting mit Predictive Analytics

Des Weiteren zählt das Reporting zu den zentralen Aufgaben des Controllings (Losbichler, Falschlunger & Eisl, 2017, S. 66). Controller:innen versorgen die Entscheidungstragenden der Organisation mit den Informationen, die für die Unternehmenssteuerung von Relevanz sind. Die Informationen werden in Form von Berichten aufbereitet und den Entscheidungstragenden zur Verfügung gestellt (Mussnig, Juritsch, Rausch & Sitter, 2021, S. 729). Beim Reporting wird eine verständliche und übersichtliche Aufbereitung der Daten vorausgesetzt, um für die Entscheidungstragenden eine vertrauenswürdige Entscheidungsgrundlage darzustellen, aus der schnell und einfach die richtigen Schlüsse gezogen werden können (Losbichler et al., 2017, S. 66). Häufig verfehlen die vorbereiteten Berichte, trotz sehr aufwendiger Aufbereitung, ihr Ziel – die Übermittlung der steuerungsrelevanten Informationen. Gründe hierfür sind unter anderem die unterschiedlichen Formate (Hardcopy, Excel-Datei, PowerPoint-Datei, etc.), die variierenden Inhalte und Aufbereitungszeitpunkte (Isensee & Hüsler, 2020, S. 27). Neben den Inhalten sind die Struktur, das Format sowie die Gestaltung des Berichts entscheidende Kriterien für einen verständlichen Bericht (Pollmann, 2020, S. 123).

Die manuelle Erstellung eines verlässlichen, aktuellen und verständlichen Berichts beansprucht in den meisten Controllingabteilungen viele Ressourcen. Für die Verknüpfung der Daten, die Formatierung und die Verteilung der Berichte fallen in der Praxis oftmals 75% des Reportingaufwands an. Unter Berücksichtigung des Zeitdrucks und der steigenden Berichtsanforderungen der vergangenen Jahre bleibt somit meist wenig Zeit zur umfangreichen Analyse der Daten. Weiters erweist sich das Reporting neben dem Planungsprozess als zweit aufwendigste Tätigkeit im Controlling. In der Praxis hat sich im Zuge von zahlreichen Optimierungsprojekten gezeigt, dass im Durchschnitt etwa 30% Einsparpotenzial bei in Reportingprozessen eingesetzten Ressourcen besteht (Isensee & Hüsler, 2020, S. 27-28, 38).

Um die optimalen Bedingungen zur effektiven Unternehmenssteuerung für die Entscheidungstragenden zu schaffen, muss eine effiziente Informationsvermittlung sichergestellt werden (Pollmann, 2020, S. 27). Diese sollte zeitnah, flexibel und mit geringem Ressourcenaufwand die steuerungsrelevanten Informationen zur Verfügung stellen. Aufgrund dieser Anforderungen erweist sich die Anwendung von computergestützten Tools, wie Predictive Analytics als hilfreich (Isensee & Hüsler, 2020, S. 29). Wie in Abbildung 3 veranschaulicht, treten bei manuellen

Analysen und Aufbereitungen jedenfalls Zeitverzögerungen zwischen dem Eintritt des relevanten Geschäftsvorfalles, der Fertigstellung der Analyse sowie dem Reporting an die Entscheidungstragenden auf. In der Regel erfolgt dies oft im Zuge des Monatsabschlusses. Durch die eintretende Zeitverzögerung kann der durch die Informationen gewonnene Wertgewinn für das Unternehmen meist nicht mehr gänzlich abgeschöpft werden. Es geht zu viel Zeit verloren, bis anhand der zur Verfügung gestellten Informationen entsprechende Maßnahmen eingeleitet werden können. Bei der Anwendung von Business Analytics-Tools erfolgt die Analyse der Daten umgehend, nachdem sie im IT-System vorhanden sind. Die Analyseergebnisse sind außerdem sofort abrufbar. Somit kann wertvolle Zeit eingespart werden, wodurch der Wertgewinn für das Unternehmen steigt, da frühzeitig Maßnahmen eingeleitet werden können (Reizenstein & Sdahl, 2018, S. 14).

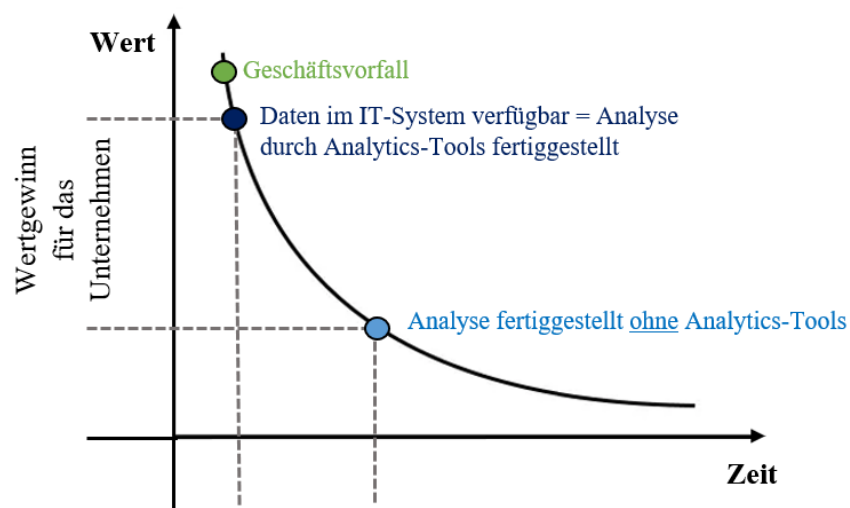


Abbildung 3. Latenzmodell. (Reizenstein & Sdahl, 2018, S. 14)

Durch den Einsatz von Predictive Analytics können im Reporting digitale Forecasts in die standardisierten Berichte integriert werden und dadurch können die Berichte laufend und ohne großen manuellen Aufwand aktualisiert werden (Isensee & Hüsler, 2020, S. 37). Die erhöhte Automatisierung des Prozesses führt zugleich zu einer Aufwandsreduktion der Controller:innen als auch der Empfänger:innen der Berichte. Denn im Zuge der Automatisierung erfolgt die Formatierung und die Gestaltung der Berichte einheitlicher, als bei einer manuellen Aufbereitung, und somit ist die Aufnahme und Interpretation der Informationen einfacher und schneller (Nobach et al., 2020, S. 60). Predictive Analytics verringern den hohen zeitlichen Aufwand der

Controller:innen für das Reporting und unterstützen bei der Herausforderung, Berichte zeitnah und flexibel bereitzustellen (Isensee & Hüsler, 2020, S. 37).

### **3.2.4 Anwendung im Vertriebscontrolling**

Das Vertriebscontrolling gestaltet sich in den meisten Unternehmen, abhängig von der Größe und dem strukturellen Aufbau des Unternehmens, unterschiedlich. Tätigkeiten, die dem Vertriebscontrolling zuzurechnen sind, werden meist vom Controlling und – vor allem bei kleineren Unternehmen – von der Vertriebsführung oder der Geschäftsführung selbst durchgeführt. Zu den vertriebsspezifischen Tätigkeiten zählen die Unterstützung bei der Erstellung der Vertriebsplanung und -budgetierung, die Überwachung der Vertriebsplanung mithilfe von Soll-Ist-Vergleichen, die Informationsaufbereitung für das Vertriebsmanagement sowie das Berichtswesen. Häufig werden diese Aufgaben von vertriebsspezialisierten Controller:innen übernommen. Die organisatorische Eingliederung der Vertriebscontroller:innen erfolgt meist in der Controllingabteilung oder im Vertriebsmanagement (Krügerke & Weber, 2010, S. 70-71). Zusammengefasst kann die Funktion des Vertriebscontrollings als zielgerichtete Steuerung des Vertriebes beschrieben werden (Häusl & Leitinger, 2009, S. 123).

Im Zuge der Digitalisierung und unter Anwendung von Big Data und Business Analytics-Tools wurden im Vertriebscontrolling zahlreiche Maßnahmen gesetzt, um eine Effizienzsteigerung zu erzielen. Häufig werden bei der Aufbereitung der Auftragseingänge sowie der Umsatzzahlen spezifische Vertriebs-Dashboards genutzt. Diese können tagesaktuell und automatisiert abgerufen werden und dienen sowohl der Effizienzsteigerung als auch zur Transparenzschaffung im Vertriebsmanagement. Durch eine individuelle Aufbereitung können die Vertriebsmitarbeiter:innen sowie die Controller:innen die Dashboards nach bestimmten Kriterien, wie beispielsweise nach Kund:innen oder Geschäftsbereichen, auswerten (Wilhelm, 2022, S. 189).

Im Rahmen des Vertriebscontrollings hat sich die Vertriebsplanung in der Vergangenheit immer wieder als sehr zeitaufwendige Tätigkeit herausgestellt (Pufahl, 2014, S. 122). Durch den Einsatz von Predictive Analytics kann die Vertriebsplanung automatisiert werden. Neben dem beträchtlichen Zeiteinsparungsfaktor würde durch die Anwendung von Predictive Analytics eine erhöhte Objektivität der Vertriebsplanung sichergestellt werden (Oehler, 2018, S. 25). Speziell im Vertriebscontrolling ist die Kombination von automatisierten Tools und menschlichem Wissen essenziell. So können zusätzliche Erkenntnisse, welche in der Planung bisher keine

Berücksichtigung fanden, wie beispielsweise das Bekanntwerden eines Kunden-Konkursfalls, manuell in die Planung miteinbezogen werden (Oehler, 2019, S. 198).

Weiters liegt es im Aufgabenbereich des Vertriebscontrollings, ergänzend zur Vertriebsplanung, regelmäßige Forecasts zu erstellen, wobei die Auswahl der Erstellungsintervalle unternehmensspezifisch ist (Pufahl, 2014, S. 123). Die Erstellung von Forecasts im Vertriebswesen ist sowohl für das operative als auch für das strategische Controlling von exorbitanter Bedeutung. Denn nur anhand qualitativ hochwertiger Forecasts können Trends und Anomalien frühzeitig erkannt und entsprechende Gegenmaßnahmen eingeleitet werden (Möller et al., 2016, S. 509). Die bereits im Kapitel 3.2.2 beschriebenen digitalen Forecasts können bei der Prognose der Umsätze und Auftragseingänge eingesetzt werden und führen sowohl zu einer Automatisierung des Forecastingprozesses als auch zu einer Erhöhung der Prognosegenauigkeit (Reuter, 2019, S. 2).

Exemplarisch kann dafür das Logistikunternehmen Deutsche Post International angeführt werden. Einer der Gründe für die Einführung von Predictive Analytics-Ansätzen war die fehlende Prognosegenauigkeit bei den Umsatzforecasts. Das Unternehmen stellte bei den klassisch erstellen Prognosen zwischen den prognostizierten Umsätzen und den tatsächlich erwirtschafteten Umsätzen eine Abweichung von 4,07% fest. Mithilfe von Predictive Analytics konnten basierend auf historischen Daten sowie unter Einbeziehung externer Daten (z.B. anstehende Wahltermine, Schulferienkalender, etc.) Vorhersagen erstellt werden. Durch die Berücksichtigung externer Daten kann in diesem Fall das vermehrte Briefaufkommen durch Wahlkarten einkalkuliert und somit eine genauere Prognose erstellt werden. Bei der Deutschen Post International wurde die erhoffte Erhöhung der Prognosegenauigkeit durch die Anwendung von Predictive Analytics erreicht. Die Abweichung zwischen den digitalen Umsatzforecasts und den tatsächlich realisierten Umsatzzahlen konnte auf 2,18% gesenkt werden (Deipenbrock, Landewe & Sälzer, 2019, S. 48-49).

Darüber hinaus unterstützen Vertriebscontroller:innen das Vertriebsmanagement bei diversen betriebswirtschaftlichen Sonderthemen. Anwendungsbereiche sind Analysen bezüglich Kundenzufriedenheit, Stärken-Schwächen-Analysen sowie Vertriebserfolgsrechnungen (Krügerke & Weber, 2010, S. 72). Zudem wird etwa durch eine Analyse der Kundenstruktur eine effektivere Marktbearbeitung durch die Vertriebsmitarbeiter:innen ermöglicht (Pufahl, 2014, S. 15).

Hierbei können vermehrt Predictive Analytics-Lösungen unterstützend angewandt werden. Predictive Analytics-Tools können beispielsweise die im Rahmen einer Kundenstrukturanalyse identifizierten Muster und Trends für die Vorhersage zukünftiger Transaktionen nutzen. Diese Erkenntnisse liefern oftmals eine wichtige Basis für die Vertriebsplanung (Holthoff & Decher, 2020, S. 53).

### **3.2.5 Anwendung im Personalcontrolling**

Das Personalcontrolling wird ebenso wie das Vertriebscontrolling als Funktionscontrolling bezeichnet. In den Unternehmen erfolgt die organisatorische Eingliederung des Personalcontrollings entweder beim Unternehmenscontrolling oder im Personalbereich (International Group of Controlling, 2015, S. 145). Zu den Hauptaufgaben des Personalcontrollings zählt die Planung, Steuerung, Kontrolle und das Reporting der personalwirtschaftlichen Aktivitäten innerhalb des Unternehmens. Im Rahmen der Planungstätigkeit erstellen die Personalcontroller:innen beispielsweise Prognosen über den Personalbedarf sowie den damit verbundenen Personalaufwendungen, welche an die Gesamtunternehmensplanung anknüpfen (Schulte, 2020, S. 4). Es werden Soll-Ist-Vergleiche erstellt, um festzustellen, ob das Unternehmen „on-track“ ist und die Zielwerte erreicht werden können. Treten Abweichungen auf, werden deren Ursachen ermittelt und anhand der Planungswerte Steuerungsmaßnahmen gesetzt (International Group of Controlling, 2015, S. 146). Weiters obliegt dem Personalcontrolling die Verantwortung, relevante Daten zusammenzutragen, auszuwerten und in geeigneter Form an die Entscheidungsträger:innen zu berichten (Sommerer, 2018, S. 473).

In der Vergangenheit haben sich Unternehmen im Rahmen des Personalcontrollings lediglich auf die essenziellen Auswertungen fokussiert. Dazu zählen etwa die Anzahl der Beschäftigten, der Personalaufwand, die Fluktuationsrate sowie die Personalausfälle (Krankenstände, Pflegetage, sonstige Dienstfreistellungen) (Christ & Ebert, 2016, S. 302). Die Daten werden häufig mithilfe von Excel in tabellarischer Form für die Berichte aufbereitet, ohne die zur Verfügung stehenden Daten genauer zu analysieren und den Mehrwert für die gesamte Unternehmensplanung wahrzunehmen. Dem Personalcontrolling liegt eine große Datengrundlage vor, die sowohl Personaldaten (d.h. Informationen über aktive und ausgetretene Mitarbeitende) als auch Unternehmensdaten umfasst. Somit können die personalwirtschaftlichen Aktivitäten unter Beachtung der Unternehmensentwicklungen gesetzt werden (Reuter, 2021, S. 1).

Um die Potenziale der zur Verfügung stehenden Daten effizient und nutzenstiftend auszuschöpfen, erweisen sich Predictive Analytics-Ansätze im Personalcontrolling als hilfreich. Die steigenden Datenmengen ermöglichen eine sinnvolle Anwendung von Predictive Analytics-Techniken und ihr Einsatz ist geeignet, um die Bedeutung des Personalcontrollings maßgeblich zu verändern. Predictive Analytics-Methoden ermöglichen schnelle, flexible und ressourcenschonende Prognosen des zukünftigen Personalbedarfs, der erforderlichen Fähigkeiten der Mitarbeitenden sowie strukturelle Personalentwicklungen (Reuter, 2021, S. 2). Mithilfe von Predictive Analytics können anhand historischer Daten Zusammenhänge zwischen Markttrends und der Personalentwicklung ermittelt und diesbezügliche Prognosen für die Zukunft erstellt werden (Strohmeier, Piazza & Neu, 2015, S. 342-343). Darüber hinaus können die Routineauswertungen erweitert werden. Zum Beispiel würden Wahrscheinlichkeitsberechnungen dahingehend, ob sich neu eingestellte Mitarbeitende erfolgreich entwickeln, eine Bereicherung für das Unternehmen darstellen. Auch eine Prognose der zukünftigen Alters- oder Genderstruktur der Mitarbeitenden wäre für eine zielgerichtete Personalsteuerung von Relevanz (Christ & Ebert, 2016, S. 303).

Zuletzt hat sich in der Wirtschaft ein massiver Fachkräftemangel bemerkbar gemacht. Nicht zuletzt kann dies auf jüngste demografische Entwicklungen zurückgeführt werden. Die Anzahl der älteren Menschen steigt, während die Anzahl der dem Arbeitsmarkt neu zur Verfügung stehenden Arbeitskräfte abnimmt. Als logische Konsequenz ist ein Arbeitskräftemangel zu beobachten (Zdrowomyslaw, 2016, S. 223). Für Unternehmen stellt sich die Herausforderung, den Personalbedarf rechtzeitig und mit geeigneten Mitarbeitenden zu decken. Hierbei ist ein effizientes Personalcontrolling von großer Bedeutung, um zeitnah zukünftige Engpässe und Veränderungen zu antizipieren und entsprechender Gegenmaßnahmen einleiten zu können. Das Personalcontrolling sollte über die Standardauswertung hinaus die Potenziale der vorhandenen Daten nutzen und mithilfe von Predictive Analytics beispielsweise die Altersstruktur der Mitarbeitenden betrachten. Weist das Unternehmen eine hohe Altersstruktur auf, sollten rasch Maßnahmen ausgearbeitet werden und von den Entscheidungstragenden die Umsetzung eingeleitet werden (Khan, Hedfeld & Bürkle, 2021, S. 88-89).

Als Beispiel für die erfolgreiche Anwendung von Predictive Analytics im Personalcontrolling, beziehen sich Christ & Ebert auf ein deutsches Produktionsunternehmen. Dieses Unternehmen führt seine Planungsprozesse bezüglich Personalbedarf und Personaleinsatz mit Unterstützung von Predictive Analytics-Methoden durch. Es werden interne sowie externe historischen Daten

als Datenbasis herangezogen. Die internen Daten werden aus dem ERP-System, dem Zeiterfassungs-Tool, der Personaldatenbank und sonstigen relevanten Systemen zusammengetragen und gemeinsam mit Daten, welche ihren Ursprung nicht im Unternehmen haben (z.B. Feriendaten, Feiertage) entsprechend den Anwendungsanforderungen aufbereitet und bereinigt. Basierend auf der Datengrundlage kann der erforderliche Personaleinsatz auf Abteilungsebene prognostiziert werden. Die Berücksichtigung der Personaldaten, wie etwa der Personenstand der Mitarbeitenden, erlauben Rückschlüsse auf die erwarteten Abwesenheitstage der Mitarbeitenden. Solche Prognosen ermöglichen eine vorausschauende Personaleinsatzplanung und eine rechtzeitige Feststellung von Engpässen (Christ & Ebert, 2016, S. 306).

### **3.3 Zuverlässigkeit von Predictive Analytics in Krisenzeiten**

In den letzten drei Jahren wurden Unternehmen wiederholt vor neue Herausforderungen gestellt, für deren Bewältigung es keine Patentlösungen gab. Im Jahr 2020 löste die Corona-Pandemie eine weltweite Unsicherheit aus und weder die Dauer noch das Ausmaß der wirtschaftlichen Folgen war vorhersehbar (Borgmeyer, 2023, S. 43). Unternehmen wurden mit drastischen Absatzzrückgängen, Personalausfällen und aus dem Takt gebrachten Lieferketten konfrontiert (Mayr, Hofer, Karrer & Winzer, 2021, S. 55). Zwei Jahre später, als die meisten Unternehmen die größten Hürden der Covid-19-Krise Großteils unter Kontrolle gebracht hatten, folgte der von Russland geführte Angriffskrieg gegen die Ukraine, der sich nicht zuletzt in Form der Energiekrise in Europa niederschlug und eine rasant ansteigende Inflation begünstigte (Schentler, Leber & Pohlner, 2022, S. 221).

Diese Krisensituationen sind systematischer Natur, d.h. sie betreffen Unternehmen aller Branchen und Unternehmen können die damit verbundenen Unsicherheiten nicht beeinflussen (Ballwieser & Weißenberger, 2023, S. 1). Speziell in solchen Zeiten ist es essenziell, dass Controller:innen ihre Rolle als Business Partner wahrnehmen und die Entscheidungstragenden aktiv unterstützen und Handlungsalternativen aufzeigen. Controller:innen müssen sich schnell an die Veränderungen anpassen und sich mit den aus der Krisensituation ergebenden Risiken befassen. Dem Controlling kommt in Krisenzeiten eine äußerst entscheidende Funktion zu (Schentler et al., 2022, S. 213). Es stellt sich jedoch die Frage, ob in derart volatilen Zeiten Predictive Analytics-Methoden im Hinblick auf ihre Vergangenheitsorientierung zuverlässige Ergebnisse liefern können und ob deren Einsatz ratsam ist.

In der Covid-19-Krise waren die Planungswerte nicht selten von einem Tag auf den anderen überholt. Bei den meisten Unternehmen hat sich rasch nach Eintritt der Pandemie gezeigt, dass die geplanten Ziele nicht erreicht werden können. Demzufolge stellte die Planung keine zuverlässige Entscheidungsgrundlage für Steuerungsmaßnahmen, beispielsweise im Hinblick auf die Liquidität, dar. Weiters konnte die Budgetierung nicht mehr als sinnvolle Koordinationsgrundlage herangezogen werden, da sich der Großteil der zugrundeliegenden Annahmen verändert hatte. Die Planungswerte nahezu aller Unternehmen wurden somit unbrauchbar. Ein klassisches Forecasting, aufbauend auf obsoleten Planungswerten, erweist sich in Krisenzeiten durch die gravierenden Veränderungen ebenfalls als nicht empfehlenswert. Hingegen könnte ein rollierender Forecast aufgrund seiner erhöhten Flexibilität in Betracht gezogen werden (Mayr et al., 2021, S. 55).

Ein rollierender Forecast („Rolling Forecast“) wird regelmäßig – rollierend – unterjährig erstellt. Dadurch kann von der starren Jahresplanung auf eine dynamischere Perspektive umgestellt werden. Häufig werden rollierende Forecasts quartalsweise durchgeführt, wobei Durchführungsintervalle und Detaillierungsgrad den Unternehmen überlassen sind. Da der rollierende Forecast regelmäßig durchgeführt wird, basiert dieser auf aktuelleren Daten und dadurch kann die Reaktionsfähigkeit hinsichtlich der Maßnahmensetzung verbessert werden (Dworski, 2005, S. 39-40). Rollierende Forecasts sind jedoch mit dem Nachteil behaftet, einen höheren Erstellungsaufwand zu verursachen. Aufgrund dessen bietet sich der Einsatz von Predictive Analytics-Methoden in Krisenzeiten an. Digitale Forecasts bilden ein Upgrade der rollierenden Forecasts, indem der hohe manuelle Aufwand bei der Erstellung von Forecasts durch die Automatisierung wegfällt (Mayr et al., 2021, S. 55-56).

Als größte Schwäche von Predictive Analytics-Techniken wird ihre Vergangenheitsorientierung genannt. Wie bereits in den vorangehenden Kapiteln näher erläutert, werden die Algorithmen mit historischen Daten trainiert. Sie identifizieren Trends und Muster und leiten darauf basierend Eintrittswahrscheinlichkeiten für zukünftige Ereignisse ab. Aus diesem Grund sind die Algorithmen nicht geeignet, unerwartete, erstmalig eintretende Ereignisse (beispielsweise die gegenwärtigen Krisen wie den russischen Angriffskrieg auf die Ukraine) zu prognostizieren (Isensee & Hüsler, 2020, S. 45).



Festzuhalten ist jedoch, dass klassische Planungen, ebenso wie algorithmenbasierte Planungen, keine unvorhergesehenen Ereignisse enthalten. Dementsprechend waren manuell erstellte Jahresplanungen von Unternehmen auch nicht in der Lage, die Krisen und deren Folgen zu berücksichtigen, wodurch diese Planungen unbrauchbar wurden. Es ist in Folge derartig unvorhersehbarer Ereignisse entscheidend, geeignete Controllinginstrumente anzuwenden, um schnellstmöglich auf die unvorhergesehenen Geschehnisse reagieren zu können (Mayr et al., 2021, S. 55). In diesem Zusammenhang wird die Anwendung von Predictive Analytics-Methoden empfohlen, da diese durch ihre Flexibilität und ihre hochwertigen Prognosen überzeugen (Ballwieser & Weißenberger, 2023, S. 3).

Anzumerken ist jedoch, dass Controller:innen bereits beispielsweise anhand allgemein zugänglicher Informationen (Massenmedien, etc.) einen Überblick über die Folgen eines unvorhergesehenen Ereignisses gewinnen, und diese Erkenntnisse bereits in ihren Forecast miteinfließen lassen können. Daher erweist sich die Kombination aus menschlichem Wissen und flexiblen Algorithmen als bester Lösungsansatz für Forecasts in Krisenzeiten. Der algorithmenbasierte Forecast sollte vom Controlling validiert werden und darüber hinaus sollte überprüft werden, ob der neueste Wissenstand berücksichtigt wurde. Falls dies nicht der Fall ist, sollte das Controllingteam entsprechende Anpassungen vornehmen, um den Forecast zu korrigieren (Isensee & Hüsler, 2020, S. 45).

## **4 Implementierungsprozess von Predictive Analytics im Controlling**

Nachfolgend wird auf den Implementierungsprozess von Predictive Analytics-Tools im Controlling eingegangen. Hierbei werden die Vorgehensweise bei Predictive Analytics-Projekten sowie die zugrundeliegenden Methoden von Predictive Analytics-Ansätzen dargestellt. Zu den grundlegenden Methoden zählen etwa die Klassifikationsanalysen, Regressionsanalysen, Cluster-Analysen und die Zeitreihenanalysen. Nach der Beschreibung der Predictive Analytics-Methoden soll anhand zweier Implementierungsprojekte aus der Praxis ein verbessertes Verständnis für die einzelnen Phasen des Implementierungsprozesses geschaffen werden. Zunächst werden die erforderlichen Schritte eines Implementierungsprozesses anhand des Vorgehensmodell CRISP-DM näher beschrieben.

### **4.1 Vorgehensweise bei der Implementierung von Predictive Analytics**

Um eine strukturierte Vorgehensweise bei der Implementierung von Predictive Analytics-Projekten sicherstellen zu können, wird das Standard-Vorgehensmodell CRISP-DM empfohlen. Wie bereits in Kapitel 2.5 beschreiben, stellt das CRISP-DM neben dem KDD-Prozess nach Fayyad und dem SEMMA-Prozess, ein beliebtes Konzept für die Anwendung von Predictive Analytics dar (Haneke et al., 2019, S. 9-11). In der Praxis werden oftmals Kombinationen aus Vorgehensmodellen angewandt. Auch die Erweiterung von Standard-Vorgehensmodelle um einzelne Schritte oder teilweise sogar um ganze Phasen, die von den Implementierungsteams auf Basis derer Erfahrungen als essenziell erachtet werden, wird vorgenommen (Iffert, 2016, S. 19).

### **4.2 Cross Industry Standard Process for Data Mining (CRISP-DM)**

CRISP-DM bezeichnet ein standardisiertes Prozessmodell zur Durchführung von Data Mining, das bei der Strukturierung von Predictive Analytics-Projekten unterstützt (Kelleher, Mac Namee & D'Arcy, 2015, S. 13). Entscheidend für das CRISP-DM ist die iterative Vorgehensweise, die eine kontinuierliche Optimierung des Ablaufes bzw. der Ergebnisse ermöglicht (Hasselmayr, 2022, S. 57). Dieses Vorgehensmodell wird nicht nur für Data Mining-Projekte verwendet. Ebenso bauen Business Analytics-Verfahren, statistische Verfahren und ähnliche Ansätze auf diesem Modell auf (Abbott, 2014, S. 20).

Dieses Vorgehensmodell erfreut sich bei Datenanalytiker:innen an Beliebtheit, da es branchen- und softwareunabhängig angewandt werden kann. Ein weiterer Vorteil von CRISP-DM stellt die Zwei-Perspektiven-Betrachtung dar. Zum einen wird der Fokus auf die anwendungsorientierte Perspektive gelegt und zum anderen auf die technische Perspektive (Kelleher et al., 2015, S. 13). Aus der technischen Perspektive werden die zu erfüllenden Aufgaben schrittweise dargestellt, um einen Leitfaden zu bilden. Die einzelnen Schritte enthalten jedoch nicht nur technische Details, sondern beinhalten ebenso Kostenschätzungen und Zeitpläne bzw. Terminübersichten. Diese Hilfestellungen unterstützen bei der Dokumentation der Projektschritte sowie bei der Berichterstattung und schaffen eine Übersicht über den Projektverlauf (Abbott, 2014, S. 20).

Insbesondere zeichnet sich das Modell dadurch aus, dass es Data Mining in sechs Phasen gliedert:

1. Business Understanding / Aufgabenverständnis
2. Data Understanding / Datenverständnis
3. Data Preparation / Datenaufbereitung
4. Modeling / Modellierung
5. Evaluation / Evaluierung
6. Deployment / Operationalisierung

(Kelleher et al., 2015, S. 15)

Jede einzelne Phase ist von großer Bedeutung für den Erfolg des Projekts. Die in Abbildung 4 ersichtlichen Phasen werden nicht einmalig, in jener Reihenfolge durchlaufen. Vielmehr wird nach manchen Phasen wieder die vorherige Phase durchgeführt (Kelleher et al., 2015, S. 15). Es gibt somit keinen starren Ablauf der Phasen und es kommt immer wieder vor, dass einzelne Phasen mehrfach durchlaufen werden. Dies kann unter anderem der Fall sein, wenn die Ergebnisse nicht den qualitativen Erwartungen entsprechen oder innerhalb des Ablaufs Probleme auftreten. Dies kann etwa der Fall sein, wenn man in der zweiten Phase beim Datenverständnis erkennt, dass die Daten quantitativ oder qualitativ nicht ausreichend sind, um die vorab in der ersten Phase definierten Ziele zu treffen bzw. vorherzusagen (Abbott, 2014, S. 21).

Wie aus Abbildung 4 ersichtlich, wird das CRISP-DM Modell als iterativer Kreislauf dargestellt.




Abbildung 4. CRISP-DM Modell. (Putler & Krider, 2012, S. 20)

Es folgt eine nähere Beschreibung der sechs Phasen des CRISP-DM Modells:

#### 4.2.1 Business Understanding

In der ersten Phase wird sichergestellt, dass von allen Projektbeteiligten, insbesondere auch von den Datenanalyt:innen und Modellexpert:innen ein Verständnis für die betriebswirtschaftliche Problemstellung aufgebaut wurde. Es ist nämlich in keinem Predictive Analytics-Projekt die ursprüngliche Zielsetzung, ein Vorhersagemodell zu erstellen. In erster Instanz wird in der Praxis immer ein unternehmerisches Ziel, wie die Effizienzsteigerung eines Prozesses, verfolgt (Kelleher et al., 2015, S. 13). Um diese Ziele zu erreichen, ist es von großer Bedeutung, die Zielsetzung gemeinsam zu definieren. Es muss das Wissen über die geschäftlichen Hintergründe und Abläufe eingebracht werden und eine Fragestellung aufgeworfen werden, dessen

Beantwortung einen Mehrwert für das Unternehmen schafft. Daten- bzw. Datenmanagement-expert:innen sind bei der Zielbestimmung relevant, um die Datenverfügbarkeit, die Datenqualität und die Grenzen der Daten bereits im ersten Schritt zu berücksichtigen.

Der dritte unabdingliche Faktor bei der Festlegung der Ziele ist das Wissen von Modellexpert:innen, die in den weiteren Schritten das zugrunde liegende Modell aufstellen, mit welchem die Vorhaben erreicht werden. Diese Bereiche sind unter allen Umständen bereits in dieser Phase abzustimmen, um ein erfolgreiches Projekt gewährleisten zu können. Nichtabstimmung mit den betriebswirtschaftlichen Expert:innen kann dazu führen, dass beispielsweise zwar sehr gute Modelle erstellt werden, diese jedoch dem Unternehmen keinen Mehrwert stiften und somit nicht angewandt werden. Eine unzulängliche Beschreibung und Abstimmung der Ziele zwischen den Projektparteien, kann unter Umständen zu falschen Erwartungshaltungen führen und ein Projekt zum Scheitern bringen (Abbott, 2014, S. 22). Zudem ist es ratsam, messbare Ziele zu definieren und entsprechende Kennzahlen zur Beurteilung zu bestimmen, um eine spätere Evaluierung der Ergebnisse zu ermöglichen (Lanquillon & Mallow, 2015a, S. 70). Weiters spielt die Definition der Rahmenbedingungen eine entscheidende Rolle für den Verlauf des Projekts. Es gilt in der ersten Phase die Verantwortlichkeiten festzulegen, zur Verfügung stehende Personal- und Softwareressourcen zu bestimmen, Risiken zu beurteilen und einen Zeitplan zu erstellen (Iffert, 2016, S. 19).

#### **4.2.2 Data Understanding**

In der zweiten Phase werden die für den Data Mining-Prozesse erforderlichen Daten beschafft und untersucht. Es ist erforderlich, dass sich die Datenexpert:innen bzw. Datenanalyt:innen ein Bewusstsein sowohl für die unterschiedlichen Datenquellen als auch für die vielfältigen Datenformate innerhalb eines Unternehmens verschaffen (Kelleher et al., 2015, S. 13). Geeignete Datenquellen werden ausgewählt und die vorhandenen Daten werden mittels explorativer Analysen erkundet. Es sollen vor allem Mängel der Daten entdeckt werden, wie mangelnde Verfügbarkeit oder nicht den Erwartungen entsprechende Datenqualität. In dieser Phase, soll entschieden werden, ob man diese identifizierten Problemfelder beispielsweise durch die Aufnahme alternativer Datenquellen oder einer Datenbereinigung beheben kann. Unter Umständen kann es erforderlich sein, in die vorherige Phase des Business Understanding zurückkehren um die Ziele anzupassen (Lanquillon & Mallow, 2015a, S. 71). Darüber hinaus muss für die Durchführung der Data Mining-Prozesse ein Verständnis für die Daten vorhanden sein, d.h. es muss

nachvollziehbar sein, woher die Daten stammen, wo die Daten aufbewahrt werden, ob die Daten transformiert werden und welche Daten berichtet werden (Kotu & Deshpande, 2015, S. 21). Bei der Datenbesichtigung wird auch festgestellt, wie viele Datensätze und darin enthaltene Variablen verfügbar sind und wie viele der festgelegten Zielvariablen in den Datensätzen umfasst sind. Häufig werden Visualisierungsmethoden eingesetzt, um die Beschaffenheit der Daten näher zu untersuchen (Abbott, 2014, S. 43).

### **4.2.3 Data Preparation**

In der dritten Phase werden die in den vorgelagerten Phasen gewonnenen Informationen über die Zielsetzung sowie die bereitstehenden Daten genutzt und technisch angewandt. Die Hauptaktivitäten in dieser Phase umfassen Datenauswahl, Zusammenführung der Daten, Datenbereinigung sowie Feature-Erstellung (Abbott, 2014, S. 83). Die Phase der Data Preparation ist die zeitaufwendigste Phase innerhalb eines Predictive Analytics-Projekts, da die Daten selten in dem für den weiterführenden Prozess benötigten Format zur Verfügung stehen (Kotu & Deshpande, 2015, S. 22). Nach Lanquillon & Mallow werden in der Praxis oft 70-80% der gesamten Projektzeit für diese Phase eingeplant (Lanquillon & Mallow, 2015a, S. 71). Unter anderem kann der erforderliche, hohe Zeitaufwand in dieser Phase darauf zurückgeführt werden, dass die Daten in diesem Schritt erstmalig in diesem Umfang untersucht werden. D.h. zuvor wurden die Daten noch nie – in einem so hohen Detailgrad – analysiert. Zusätzlich weichen die besonderen Anforderungen an Modellierungsprozesse von den Ansprüchen einer herkömmlichen Datenbankablage, die oftmals einfache Datenbereinigungen durchführt, ab (Abbott, 2014, S. 84). Die Data Preparation Phase ist zudem die iterativste Phase in einem Predictive Analytics-Projekt. Jedoch wird der Aufwand und die Notwendigkeit einer umfassenden Datenvorbereitung von vielen Projektteams unterschätzt. Es wird voreilig mit der Erstellung eines Modells sowie Algorithmus gestartet und die ersten Hypothesen werden überprüft, ohne die entsprechende Vorbereitung der Daten abzuschließen. Dies hat zur Folge, dass im späteren Verlauf festgestellt wird, dass die Daten ungeeignet für die erstellten Modelle sind und erneut die Phase der Data Preparation durchlaufen werden muss (Dietrich, Heller & Yang, 2015, S. 36).

Den ersten Schritt bei der Datenaufbereitung bildet eine vertiefende Analyse der Daten, die auch als Exploratory Data Analysis (EDA) bezeichnet wird. Hierbei werden Descriptive Statistics und Visualisierungsmethoden angewandt, um Erkenntnisse über die Datenstrukturen, die Verteilung und Verbindungen der Datenwerte sowie das Auftreten von Extremwerten (auch

sogenannte „Ausreißer“ genannt) zu erlangen. Zu den Descriptive Statistics zählen etwa die Bestimmung des Mittelwerts, des Medians und des Modalwerts (Modus) (Kotu & Deshpande, 2015, S. 23). Bei diesem Schritt kann festgestellt werden, ob weitere noch nicht zur Verfügung gestellte Datensätze von Relevanz wären und diese ebenfalls bei den Data Mining-Prozessen berücksichtigt werden sollten. Nützliche Datensätze gehen in manchen Fällen über die Grenzen des Unternehmens hinaus, und Zukäufe solcher Daten von Drittanbietern sollten in Erwägung gezogen werden (Dietrich et al., 2015, S. 39-40).

Ein weiterer Schritt in dieser Phase ist die Datenbereinigung. Speziell fehlende, falsche und falsch kodierte Werte werden korrigiert. Diese Aufgabe spielt eine entscheidende Rolle für die Erfolgswirksamkeit des Modells, denn unberücksichtigte Datenmängel können das Ergebnis maßgeblich verzerren bzw. verfälschen. Zu beachten gilt, dass in den Datensätzen enthaltene falsche Werte insofern kritisch sind, da die Algorithmen den bereitgestellten Daten eine 100%ige Richtigkeit unterstellen (Abbott, 2014, S. 84).

Darüber hinaus beinhaltet die Phase der Datenaufbereitung die Aufgaben der Datentransformation, der Integration unterschiedlicher Datenquellen und der Formatierung der Daten (Lanquillon & Mallow, 2015a, S. 71). Es werden neue Variablen gebildet, indem andere in den Datensätzen enthaltene Variablen zu neuen Variablen transformiert werden oder neue Variablen aus bereits bestehenden abgeleitet werden (auch Feature-Erstellung genannt). Beispielsweise kann eine Variable, welche die durch eine:einen Kund:in erzielten Umsätze, wiedergibt, ins Verhältnis zu der Anzahl der Monate, seit denen der:die Kund:in Geschäfte mit dem Unternehmen abschließt, gestellt werden und somit eine neue Variable definieren. In manchen Fällen werden Werte auch manuell nachgetragen. Dies kann zum Beispiel der Fall sein, wenn Kund:innen in den vergangenen Jahren keine Transaktionen mit dem Unternehmen tätigten. Dementsprechend würde es in diesen Jahren keine Transaktionsdaten geben und diese Kund:innen würden in den Predictive Analytics-Modellen außer Acht gelassen werden. Jedoch können diese Informationen – abhängig von der zu Beginn definierten Zielsetzung – für die Zielvariable von Bedeutung sein. Bei der Datenintegration werden Daten aus unterschiedlichen Datenquellen oder Tabellen zu einem Datensatz zusammengeführt. So können die Umsätze, welche durch Kund:innen generiert wurden und in der Umsatzdatentabelle zu finden sind, mit den Stammdaten des:der Kund:in, welche in der Kundendatentabelle enthalten sind, zu einem Datensatz integriert werden. Dieser Datensatz kann dann im Vorhersagemodell eingesetzt werden (Putler & Krider, 2012, S. 25).

#### 4.2.4 Modeling

In der Modellierungsphase werden unterschiedliche Machine Learning-Algorithmen verwendet, um das beste Vorhersagemodell zu erstellen (Kelleher et al., 2015, S. 13). Konkret baut die Phase der Modellierung auf den vorgelagerten Phasen auf und kann in vier Schlüsselaktivitäten unterteilt werden:

- 1) Auswahl der Modellierungstechnik
- 2) Aufbau eines Test-Designs
- 3) Erstellung des Vorhersagemodells
- 4) Bewertung des Modells

(Putler & Krider, 2012, S. 25-26).

In einem ersten Schritt wird eine geeignete Modellierungstechnik ausgewählt. Da nicht immer nur eine Modellierungstechnik die Richtige ist, sondern mehrere Techniken in Frage kommen, werden alle möglichen Ansätze angewandt. In späterer Folge wird dann die am besten geeignete Modellierungstechnik bestimmt und für die weitere Vorgehensweise herangezogen. Jedoch erweist sich eine Methode oftmals erst im Zuge der weiteren Tätigkeiten als optimal (Putler & Krider, 2012, S. 26). Modellierungstechniken werden auch als Lernverfahren bezeichnet. Bei der Auswahl des Lernverfahrens sollte die Zielsetzung (d.h. die grundlegend zu beantwortende Fragestellung), die zur Verfügung stehenden Daten und Analyse-Tools sowie das Know-how der Modellierer berücksichtigt werden. Bei Betrachtung dieser Faktoren lässt sich bereits die Anzahl der möglichen Modellieretechniken einschränken (Lanquillon & Mallow, 2015a, S. 71-72).

Bei den nächsten Schritt in der Modellierungsphase wird ein Test-Design erstellt. Die Durchführung dieser Tätigkeit sollte unbedingt vor der Anwendung eines Modells vorgenommen werden, da hierbei die Qualität und Zuverlässigkeit der Modelle untersucht wird. Dazu werden die in der bereits durchlaufenen Phase der Datenaufbereitung vorbereiteten Daten in Teilmengen oder Proben geteilt. Diese Unterteilung erfolgt, um das Modell mit einer Teilmenge der Daten anzulernen und mit den verbleibenden Teilmengen das Modell zu überprüfen und verbessern (Putler & Krider, 2012, S. 26).

Die beiden letzten Schritte der Modellierungsphase umfassen den Aufbau des Vorhersagemodells, bei welchem die zuvor ausgewählten Techniken bei den vorbereiteten Datensätzen zum



Einsatz kommen und die Bewertung des Modells vorgenommen wird. In dieser Phase wird das Modell noch nicht im Hinblick auf die übergeordnete, betriebswirtschaftliche Zielsetzung bewertet. Es wird nur die technische Perspektive berücksichtigt und auf Allgemeingültigkeit und Zuverlässigkeit geprüft. Die Evaluierung des gesamten Modells hinsichtlich Mehrwertschaffung für das Unternehmen wird in der nächsten Phase des CRISP-DM-Prozesses durchgeführt (Putler & Krider, 2012, S. 26).

In der Praxis kommt es nicht nur zwischen den einzelnen Phasen des CRISP-DM-Prozesses zu Vor- und Rücksprüngen, sondern auch bei den einzelnen Schritten der Modellierungsphase werden die Aktivitäten so lange ausgeführt und zwischen den Schritten gewechselt, bis das beste Modell geschaffen wird (Dietrich et al., 2015, S. 46).

#### **4.2.5 Evaluation**

Bevor das Vorhersagemodell eingesetzt werden kann, ist es empfehlenswert, eine umfangreiche Evaluierung durchzuführen. In dieser Phase soll geprüft werden, ob das Modell geeignet ist, die betriebswirtschaftliche Fragestellung zu beantworten und folglich die Zielsetzung zu erfüllen. Weiters wird in dieser Phase überprüft, ob das Modell nach der Inbetriebnahme bereit ist, präzise Vorhersagen zu erstellen und kein Over- oder Underfitting festgestellt wird (Kelleher et al., 2015, S. 13). Eine ausführliche Beurteilung soll dazu dienen, eine Gewissheit zu schaffen, dass die identifizierten Muster nicht nur durch Zufall erzeugt wurden. In jeder Datenmenge können Muster festgestellt werden, doch oftmals stellen sich diese nur als Abweichungen vom tatsächlichen Muster heraus und eine auf diesen fehlerhaften Erkenntnissen basierende Vorhersage wäre nicht verlässlich (Provost & Fawcett, 2017, S. 57). Eine detaillierte Erläuterung von Overfitting folgt in Kapitel 5.1.3.

In der Beurteilungsphase sollten sowohl qualitative als auch quantitative Beurteilungen durchgeführt werden. Die Ergebnisse des Vorhersagemodells sind für eine große Anzahl an Personen relevant. Daher sollten auch die Projektbeteiligten, bei der Bewertung involviert werden, um möglichst alle Interessengruppen abzudecken. Schließlich muss die Qualität der Ergebnisse für das gesamte Projektteam zufriedenstellend sein (Provost & Fawcett, 2017, S. 58). Bei der Entscheidung über die anzuwendenden Evaluierungstechniken und Beurteilungskriterien sollte die Zielsetzung sowie das zugrunde liegende Verfahren berücksichtigt werden. Wurden die Akti-

vitäten der vorgelagerten Phasen nicht hinreichend ausgeführt, wie beispielweise die Festlegung einer geeigneten Zielformulierung in der Business Understanding Phase, kann dies zu Schwierigkeiten bei der Evaluierung führen (Lanquillon & Mallow, 2015a, S. 73).

Wenn der gesamte Prozess überprüft wurde und sich herausstellt, dass das Modell richtig erstellt wurde, die Variablen zielführend bestimmt wurden, und alle Projektbeteiligten zufrieden mit den Ergebnissen sind, kann die Bewertung abgeschlossen werden. In diesem Fall würde die Entscheidung über die Einleitung der nächsten Phase – die Anwendung des ausgewählten Vorhersagemodells – den nächsten Schritt darstellen. Treten jedoch Zweifel im Hinblick auf die Gültigkeit des Modells oder die Genauigkeit der Prognosewerte auf, wird gegen eine Anwendung entschieden. Das Projekt durchläuft dann erneut jene Phasen, in denen Problemfelder erkannt wurden, um Adaptierungen durchzuführen (Putler & Krider, 2012, S. 27).

#### **4.2.6 Deployment**

In der letzten Phase werden alle erforderlichen Tätigkeiten verrichtet, um das Vorhersagemodell in Betrieb zu nehmen (Kelleher et al., 2015, S. 14). Diese Tätigkeiten können in vier Schritten zusammengefasst werden. Der erste Schritt ist die Erstellung eines Plans für die Anwendung (Abbott, 2014, S. 354). Hierbei gilt es zu berücksichtigen, welchen Nutzen der Prozess hatte. Dabei wird berücksichtigt, ob es sich um eine spezielle Fragestellung handelt und die Ergebnisse der Analyse nur einmalig benötigt werden oder ob das Modell regelmäßig automatisch angewandt werden soll (Lanquillon & Mallow, 2015a, S. 73-74). In den meisten Predictive Analytics-Projekten werden die Modelle für einen längerfristigen Zeitraum erstellt und es wird eine Integration des Modells in die Geschäftsprozesse vorgenommen (Putler & Krider, 2012, S. 27).

Der zweite Schritt umfasst die Erstellung eines Plans zur Überwachung der Funktionsweise sowie Aktualisierung des Modells. Wird das Modell in die Geschäftsprozesse integriert und automatisch eingesetzt, ist in späterer Folge eine regelmäßige Kontrolle und gegebenenfalls eine erforderliche Adaptierung durchzuführen (Abbott, 2014, S. 355). Vor allem wenn es zu Veränderungen der Umweltbedingungen kam, wie dies beispielsweise bei einem signifikanten Anstieg der Zinssätze der Fall wäre, müssten Anpassungen erfolgen. Zur Sicherstellung der Qualität der Ergebnisse, wird ein Plan für zukünftige Überprüfungen und Wartungen konzi-

piert. Es ist ratsam in diesem Plan änderungshervorrufende Ereignisse zu definieren, d.h. Ereignisse zu bestimmen, bei denen Auswirkungen auf das Vorhersagemodell zu erwarten sind (Putler & Krider, 2012, S. 28). Bei den Überprüfungen wird unter anderem untersucht, ob die Inputdaten jenen Daten entsprechen, welche zur Erstellung des Modells herangezogen wurden. Sollte es hier zu gravierenden Abweichungen kommen, ist eine Adaptierung des Modells unumgänglich, da eine ordnungsgemäße Funktionsweise des Vorhersagemodells nicht garantiert werden kann (Dietrich et al., 2015, S. 52).

Im dritten und vierten Schritt werden die Aktivitäten zur Verfassung eines finalen Berichts sowie zur Dokumentation der gewonnenen Erkenntnisse und Erfahrungen durchgeführt. Der finale Bericht sollte auf die im Rahmen des Projekts durchgeführten Aktivitäten eingehen und die Ergebnisse des Predictive Analytics-Verfahrens ausführlich beschreiben (Putler & Krider, 2012, S. 28). In manchen Fällen ist auch eine Abschlusspräsentation der Ergebnisse vorgesehen, um die Resultate an die relevanten Interessensträger:innen („Stakeholder“) zu vermitteln (Lanquillon & Mallow, 2015a, S. 73). Weiters werden die gesammelten Erfahrungen dokumentiert. Sowohl die Misserfolge und Fehlerquellen als auch die erzielten Erfolge hinsichtlich des Projekts sollen angeführt werden (Putler & Krider, 2012, S. 28).

Zu beachten gilt, dass diese Phase nicht zwangsläufig das Endstadium eines erfolgreichen Projektes darstellt. Erfolgreiche Projekte kehren häufig wieder in die bereits durchlaufenen Phasen zurück, um die im Laufe des Projekts gewonnenen Erkenntnisse zu nutzen und die Prozesse zu verbessern. Oft führt die intensive Auseinandersetzung mit den Daten und den Geschäftsprozessen dazu, dass neue Ideen aufkommen und die Ziele neu definiert werden. Die iterative Vorgehensweise führt zu Verbesserungen in den Prozessen und dadurch können bessere Lösungsmöglichkeiten erarbeitet werden (Provost & Fawcett, 2017, S. 61).

Heutzutage werden Predictive Analytics-Softwarelösungen eingesetzt, welche bereits entwickelte Data Mining-Modelle beinhalten. Es werden den Anwender:innen durch anwendungsspezifische Elemente benutzerfreundliche Bedienoberflächen zur Verfügung gestellt und die teils komplexen Data Mining-Berechnungen werden im Hintergrund ausgeführt (Iffert, 2016, S. 17).

## **4.3 Grundlegende Methoden**

Wie bereits erwähnt, können bei Data Mining-Prozessen eingesetzte Algorithmen in überwachte und unüberwachte Lernverfahren gegliedert werden. Überwachte Lernverfahren stellen dabei die meistangewandte Technik des Machine Learnings dar. Die überwachten Lernverfahren enthalten beschreibende Variablen und eine (in späterer Folge zu prognostizierende) Zielvariable. Daraus wird ein Modell angelernt, das die Verbindung zwischen den beschreibenden Variablen und der Zielvariable beschreibt (Trahasch & Felden, 2019, S 71). Anhand des Skalenniveaus der Zielvariable kann zwischen Klassifikation und Regression unterschieden werden. Bei der Klassifikation ist die Zielvariable nominal, im Gegensatz zur Regression, bei der die Zielvariable numerisch ist (Mailund, 2017, S. 126).

### **4.3.1 Klassifikationsanalysen**

Die Klassifikationsanalyse erstellt Modelle, um anhand von beobachtbaren Attributen, Daten bestimmten Klassen zuzuordnen (Lanquillon & Mallow, 2015a, S. 64). Diese Klassen weisen ein gemeinsames Klassenattribut auf; dieses könnte beispielhaft lauten „A-Kunde“ und die Ausprägungen „ja“ und „nein“ aufweisen (Seiter, 2019, S. 140). Zum Erlernen eines Klassifikationsmodells gibt es unterschiedliche Methoden, beispielsweise informationstheoretische, instanzbasierte oder wahrscheinlichkeitsbasierte Verfahren und andere algorithmenbasierte Verfahren (Trahasch & Felden, 2019, S 71).

### **Entscheidungsbaum**

Zu den informationstheoretischen Verfahren zählt der Entscheidungsbaum. Es handelt sich dabei um eine visuelle Darstellung, welche sich aus einer Wurzel, Knoten und Blättern zusammensetzt. Die Entscheidungsbaum-Algorithmen werden eingesetzt, um Daten zu kategorisieren oder in Klassen zuteilen (Trahasch & Felden, 2019, S. 75). Zu den Vorteilen des Verfahrens zählt der im Vergleich zu anderen Verfahren geringe Aufwand bei der Datenbereinigung. Die Ergebnisse der Entscheidungsbaum-Algorithmen werden nicht signifikant durch Ausreißer beeinflusst, und fehlende Daten stellen sich ebenfalls als nicht problematisch dar (Vriens, Chen & Vidden, 2019, S. 159). Das Verfahren wird gerne verwendet, da es sehr übersichtlich und einfach zu interpretieren ist. Vor allem können anhand des Entscheidungsbaumes auch Projektbeteiligte, welche bisher keine Erfahrungen mit Data Science sammeln konnten, das Verfahren

und die Ergebnisse nachvollziehen (Winters, 2017, S. 195). Jeder Knoten stellt eine Entscheidung dar, bei der die Daten in homogene Teilmengen gegliedert werden. Diese Teilmengen bilden unterschiedliche Ausprägungen der Attribute ab. Dabei wird das Ziel verfolgt, innerhalb einer Teilmenge Homogenität herzustellen. Diese homogene Teilmenge im Hinblick auf die Zielvariable wird durch das Blatt dargestellt. Herrscht keine Homogenität wird ein weiterer Knoten gebildet, der mit unterschiedlichen Ausprägungen versehen ist (Seiter, 2019, S. 141). Bei der Klassifizierung eines unbekanntes Datensatzes startet der Prozess bei der Wurzel und verläuft den Baum entlang, entsprechend der zutreffenden Ausprägungen der Attribute. Sobald ein Blatt erreicht wird, ist der Datensatz der dem Blatt zugeordneten Klasse zuzurechnen (Witten & Frank, 2005, S. 62).

### **K-Nearest-Neighbor**

Zu den instanzbasierten Lernverfahren zählt das K-Nearest-Neighbor (KNN). Hierbei stehen für die Klassifizierung nur die Trainingsdaten zur Verfügung. Es wird im Gegensatz zum Entscheidungsbaum-Algorithmus kein spezielles Modell erstellt, das anhand der Beispieldaten erlernt wurde. Aus diesem Grund wird der K-Nearest-Neighbor-Algorithmus auch als „lazy learner“ bezeichnet (Abbott, 2014, S. 254). Die Daten werden in einem Vektorraum als Punkte gespeichert. Bei der Klassifizierung neuer Datensätze wird die Basis – die Trainingsdaten – auf möglichst ähnliche Datensätze durchsucht (Bentley, 2017, S. 48). Die neuen Datensätze werden dann jenen Klassen zugeordnet, welche die ähnlichsten Trainingsdaten beinhalten (Evans, 2017, S. 347). Mit dem „k“ wird die Anzahl an Nachbarn ausgedrückt, welche sich in der Nähe des neuen Datensatzes befinden. Es werden also die sogenannten Nachbarn des neuen Datensatzes identifiziert und deren Klassen herangezogen, um die Klasse des neuen Datensatzes zu prognostizieren (Witten & Frank, 2005, S. 78). Hierbei wird aber der Einfluss der Nachbarn auf die Prognose basierend auf der Distanz zu dem neuen Datensatz gewichtet, somit werden Nachbarn mit höherer Distanz weniger bei der Klassifizierung berücksichtigt. Instanzbasierte Lernverfahren bieten den Vorteil, dass eine Erweiterung der Trainingsdaten anhand neuer Datensätze jederzeit und ohne großen Mehraufwand durchgeführt werden kann, da das Verfahren keinem antrainierten Modell zugrunde liegt. Bei Verfahren, welche auf erlernten Modellen basieren, kann sich eine Erweiterung der Trainingsdaten als aufwendig herausstellen, da das Modell angepasst werden muss (Trahasch & Felden, 2019, S. 76-77).

### **Naïve Bayes**

Das etablierteste wahrscheinlichkeitsbasierte Verfahren ist das Naïve Bayes-Verfahren. Diese Methode basiert auf den Theorien von Bayes, welche wiederum auf Wahrscheinlichkeiten und der bedingten Unabhängigkeit basieren (Kelleher et al., 2015, S. 247). Bei dem Verfahren wird den Attributen bedingte Unabhängigkeit unterstellt. Das bedeutet, die Eintrittswahrscheinlichkeit für ein Ereignis wird nicht durch den Eintritt eines anderen Ereignisses beeinflusst (Abbott, 2014, S. 268). Aus diesem Grund wird das Verfahren als „Naïve Bayes“ bezeichnet. Die naive Betrachtung stellt eine wesentliche Vereinfachung dar und ermöglicht ein einfaches Erlernen des Modells (Winters, 2017, S. 85). Der Algorithmus bestimmt auf Basis der erlernten Trainingsdaten für jeden neuen Datensatz abhängig von der auftretenden Attributkombination jene Klasse, welche die höchste Wahrscheinlichkeit für diese Kombination aufweist. Obwohl diese sehr stark vereinfachende Annahme getroffen wird, hat sich dieser Ansatz in der Vergangenheit bewährt und gute Ergebnisse erzielt (Kelleher et al., 2015, S. 267).

Darüber hinaus besteht die Möglichkeit, in einem Modell unterschiedliche Machine Learning-Algorithmen zu kombinieren. Somit können die Vorteile einzelner Algorithmen bestmöglich genutzt werden und in vielen Fällen werden die Nachteile reduziert. Diese Vorgehensweise ist auch als Ensemble-Methode bekannt, und wird gerne eingesetzt, um die Prognosegenauigkeit gegenüber Basisalgorithmen (worumter z.B. Entscheidungsbaum-Algorithmen zu zählen sind) zu erhöhen (Trahasch & Felden, 2019, S. 78).

#### **4.3.2 Regressionsanalysen**

Die Regressionsanalyse zählt zu den statistischen Analyseverfahren und dient zur Modellierung der Beziehungen zwischen der unabhängigen (auch Inputvariable genannten) Variable und der abhängigen Variable, welche vorhergesagt werden soll. Dabei wird untersucht, wie sich die Veränderung einer unabhängigen Variable auf die abhängige Variable auswirkt, wobei angenommen wird, dass die weiteren unabhängigen Variablen unverändert bleiben (Bentley, 2017, S. 101). Anhand der Anzahl der unabhängigen Variablen kann man zwischen der einfachen und der multiplen linearen Regressionsanalyse unterscheiden (Evans, 2017, S. 264). Bei der einfachen linearen Regressionsanalyse gibt es nur eine unabhängige Variable. Im Gegensatz dazu gibt es bei der zur multiplen linearen Regressionsanalyse mehrere unabhängige Variablen (Bentley, 2017, S. 105). In den meisten Fällen wird der zu prognostizierende Wert der abhängigen Variable anhand des Durchschnittswertes der unabhängigen Variable (bei gleichbleibenden Werten der unabhängigen Variablen) ermittelt. Mithilfe der Regressionsanalyse können Daten

untersucht werden, Vorhersagen getroffen und Forecasts erstellt werden. Weiters eignen sich Regressionsanalysen zur Untersuchung, ob bzw. welche unabhängigen Variablen in Verbindung zu den abhängigen Variablen stehen und in einem weiteren Schritt wird erforscht, in welcher Form von Beziehung die beiden Variablen zueinanderstehen (Bentley, 2017, S. 101-102). Da bei der Regressionsanalyse numerische Zielvariablen vorhergesagt werden, eignet sich dieses Verfahren beispielsweise zur Absatz- oder Kostenprognose (Seiter, 2019, S. 134).

### **4.3.3 Cluster-Analysen**

Die Cluster-Analyse (Clustering), wird auch als unüberwachte Segmentierung betitelt und bildet ein weit verbreitetes Konzept der unüberwachten Lernverfahren (Provost & Fawcett, 2017, S. 203). Clustering bezeichnet die Durchführung einer Segmentierung von Datensätzen anhand bestimmter Merkmale. Vor allem in den Bereichen Marketing und Vertriebscontrolling kommt diese gerne zum Einsatz (Vriens et al., 2019, S. 217). Kund:innen können nämlich mithilfe der Cluster-Analyse nach bestimmten Merkmalen, wie die Regelmäßigkeit der Einkäufe oder die Höhe der durch die:den Kund:in erzielten Umsätze, kategorisiert werden. Ein Cluster kann von beliebiger Größe sein. Für jedes Cluster wird ein „Centroid“ bestimmt, der den Durchschnitt des Clusters repräsentiert. Anhand des „Centroids“ werden die Abstände zwischen den Clustern bemessen (Winters, 2017, S. 209). Die Datensätze innerhalb eines Clusters sollen möglichst kleine Abstände zueinander aufweisen und die unterschiedlichen Cluster sollten sich durch deutliche Abstände voneinander abgrenzen. Die Cluster-Analyse unterscheidet sich von Klassifikations-Analysen durch ihre Flexibilität. Bei der Kategorisierung müssen keine Bestimmungen hinsichtlich der Cluster eingehalten werden. Hingegen müssen bei den Klassifikations-Analysen die Klassen den Vorgaben des Klassenattributs entsprechen (Seiter, 2019, S. 140).

### **4.3.4 Zeitreihenanalyse**

Das Ziel einer Zeitreihenanalyse ist es, Muster wie Trends und saisonale Abweichungen innerhalb einer Zeitreihe zu erkennen, um in späterer Folge die zukünftige Fortsetzung der Zeitreihe prognostizieren zu können. Eine Zeitreihe setzt sich aus mehreren, chronologisch angeordneten Datenpunkten zusammen (Seiter, 2019, S. 149). Es wird der Verlauf einer Variable innerhalb der Zeitreihe untersucht, die festgestellten Auffälligkeiten beschrieben und basierend auf diesen Informationen zukünftige Prognosen erstellt (Lanquillon & Mallow, 2015a, S. 65). Zeitreihenanalysen werden häufig beim Forecasting, der Budgetplanung sowie Budgetaufteilung ein-

gesetzt (Evans, 2017, S. 302). Mit Zeitreihenanalysen kann nämlich ein Unternehmen beispielsweise feststellen, dass auf dem europäischen Markt die prognostizierten Verkaufszahlen für ein Produkt einen fallenden Trend aufweisen, der asiatische Markt hingegen einen Aufwärtstrend zeigt. Dementsprechend können Maßnahmen eingeleitet werden und diese Erkenntnisse können in der Budgetplanung berücksichtigt werden. Jedoch ist ein Zeitreihenanalyse-Verfahren sehr komplex (Vriens et al., 2019, S. 243). Es können keine herkömmlichen Regressionsverfahren angewandt werden. Die Zeitreihendaten werden mit speziellen mathematischen Modellen analysiert. Zum Beispiel wird in der Praxis häufig das Box-Jenkins-Modell für Zeitreihenanalysen eingesetzt. Das Modell wird auch als ARIMA (autoregressive integrated moving average model) bezeichnet, da es eine Kombination aus autoregressiven Modellen (AR) und moving average Modellen (MA), also Modelle mit gleitendem Mittelwert, darstellt (Bentley, 2017, S. 45). Eine korrekte Anwendung setzt ein umfassendes statistisches Know-how voraus und beinhaltet eine große Anzahl an Parametern, für welche Annahmen getroffen werden müssen. Aus diesem Gründen ist die Implementierung mit einem hohen Aufwand verbunden (Vriens et al., 2019, S. 243).

Gemäß Trahasch und Felden kann zusätzlich zu den überwachten und unüberwachten Lernverfahren noch eine dritte Form des Machine Learning bestimmt werden, nämlich das Reinforcement Learning (Trahasch & Felden, 2019, S. 65). Beim Reinforcement Learning (übersetzt bestärkendes Lernen), werden, im Gegensatz zu den anderen Lernverfahren, vorab keine Daten zum Lernen zur Verfügung gestellt. Der Algorithmus lernt beim Reinforcement Learning selbstständig durch Interaktion mit der Umgebung. Es wird selbstständig ausprobiert, welche Handlungen gesetzt werden müssen. Hierbei erhält der Algorithmus nach der Durchführung einer Handlung ein positives oder negatives Feedback (Trahasch & Felden, 2019, S. 85).

#### **4.4 Implementierungsbeispiel**

Um einen besseren Überblick über die zuvor beschriebenen Schritte eines Implementierungsprojekts zu erhalten, wird ein typischer Implementierungsablauf anhand zweier Praxisbeispiele beschrieben. Es handelt sich dabei um die Bayer AG und die Deutsche Post International.

Die Bayer AG hat sich dazu entschieden, im Rahmen eines Pilotprojektes die Potenziale von Predictive Analytics für unternehmensinterne Steuerungsprozesse zu untersuchen. Das Projektteam beschloss, den Kostenstellen-Forecast zu automatisieren, da sich der Prognoseprozess



in der Vergangenheit als überaus ressourcenbeanspruchend erwies. Als Basis wurden die Daten eines zuvor festgelegten Landes herangezogen, die von etwa 3.400 Kostenstellen der letzten vier Jahre stammen. Für die Entwicklung des Predictive Analytics-Modells wurde das Vorgehensmodell CRISP-DM als Basis verwendet (Burow et al., 2017, S. 49-50). Dieses Vorgehensmodell wird häufig bei Predictive Analytics-Projekten verwendet. Hier ist etwa auf das Implementierungsprojekt für monatliche Umsatzprognosen bei der Deutschen Post International hinzuweisen (Deipenbrock et al., 2019, S. 45).

Im ersten Schritt, dem Business Understanding, stellte sich das Projektteam der Bayer AG die Frage, welche Verbesserungspotenziale Predictive Analytics für den Forecastprozess bieten und welche Chancen sich daraus für das Unternehmen im Allgemeinen ableiten lassen. Nachdem die Ziele formuliert wurden, folgte die Phase des Data Understandings. Hierbei wurden die im Data Warehouse zur Verfügung stehenden Daten analysiert, um ein Verständnis für die Daten im Hinblick auf das zuvor definierte Ziel aufbauen zu können. In der Phase der Data Preparation wurde die Datenbasis aufbereitet und bereinigt, um eine Grundlage für die Predictive Analytics Modelle zu erstellen. Einen großen Einfluss auf den anfallenden Aufwand in der Data Preparation-Phase hatte die im Bayer-Konzern bereits zuvor durchgeführte Harmonisierung der Finanzdaten. Durch diese bereits gesetzte Maßnahme des Unternehmens war der in der Regel sehr aufwändige Datenaufbereitungsprozess mit deutlich geringerem Aufwand verbunden (Burow et al., 2017, S. 50-52).

Die heranzuziehenden Datenquellen variieren bei den Implementierungsprojekten. Um einen Einblick zu bekommen, welche Datenquellen für ein Predictive Analytics-Projekt von Relevanz sein können, werden nachfolgend die von der Deutschen Post International herangezogenen Datenquellen beschrieben. Zum Beispiel wurden interne Informationsquellen wie die Umsatzen aus dem Konzernreporting-Tool eingesetzt. Hierbei wurden intern dokumentierte Sondereffekte herangezogen und die Datensätze wurden um diese Sondereffekte bereinigt. Zusätzlich wurden die historischen, manuell erstellen Umsatzprognosen im Zuge des Implementierungsprojektes verwendet, um die Validität der Predictive Analytics-Modelle im Vergleich dazu zu bewerten. Die historischen, manuell erstellten Vorhersagen wurden somit nicht zum Anlernen des Modells verwendet. Weiters wurden externe Informationsquellen wie die Informationen zu den staatlichen Feiertagen, den Schulferien, Termine zu international stattfindenden Briefwahlen und Wetterdaten herangezogen. Diese Datenquellen wurden verwendet, da

Kausalitäten zwischen Briefaufkommen und den verwendeten Daten vermutet wurden (Deipenbrock et al., 2019, S. 48).

Im Anschluss an die Datenaufbereitung folgt die Modeling Phase, in welcher passende Predictive Analytics-Modelle entworfen wurden. In einem nächsten Schritt erfolgte die Evaluation der Modelle. Es wurde die Prognosequalität der Modelle mithilfe von Ist-Vergleichen und Benchmarks bewertet. Als Benchmark kann beispielsweise die manuell erstellte Planung herangezogen werden (Burow et al., 2017, S. 50-51). Bei dem Implementierungsprojekt der Deutschen Post International wurden die KPIs MAPE (Mean Absolute Percentage Error) und MAD (Mean Absolute Deviation) bestimmt um die Prognosequalität zu bewerten. Der MAPE gibt den Mittelwert der absoluten prozentualen Differenz zwischen dem Prognosewert des Predictive Analytics-Tools und dem tatsächlichen Ist-Wert wieder und der MAD bestimmt den Durchschnitt der absoluten Differenz des Prognosewertes des Predictive Analytics-Tools und dem tatsächlichen Ist-Wert (Deipenbrock et al., 2019, S. 47). In einem letzten Schritt wurde bei dem Implementierungsprozess das erstellte Predictive Analytics-Modell in den Forecastprozess implementiert (Burow et al., 2017, S. 51).

Die Problematik bei der Auswahl einer geeigneten Prognosemethodik ist die Uneinheitlichkeit der Kostenverläufe. Einige Kostenpositionen weisen Muster und Beständigkeit auf, andere hingegen können nicht durch Muster beschrieben werden. Die statistischen Verfahren unterscheiden sich durch ihre Ansprüche an die zugrunde liegende Datenbasis. Daher sind die Muster in den Zeitreihen relevant für die Bestimmung des anzuwendenden statistischen Verfahrens. In diesem Fall konnte keine einheitliche Prognosemethodik für alle Zeitreihen bestimmt werden, da zu viele Zeitreihen mit hoher Heterogenität identifiziert wurden. Somit musste das Projektteam eine automatisierte Modellauswahl sicherstellen, was durch die Entwicklung einer Model Factory erfolgte. Model Factorys wählen automatisch die passendste Methodik für die Prognose der jeweiligen Zeitreihe aus (Burow et al., 2017, S. 51-52). Eine Model Factory setzt sich aus einer Reihe von verschiedenen Algorithmen zusammen und wendet all diese bei den jeweiligen Zeitreihen an. Im Zuge eines Backtesting wird bewertet, welches Modell für die jeweilige Zeitreihe am geeignetsten ist. Nach Evaluierung der Modelle wird das beste Modell (Champion-Verfahren) oder eine gewichtete Kombination der Modelle (Ensemble) ausgewählt und für die Prognose eingesetzt (Sanders et al., 2021, S. 39).

Das Implementierungsprojekt der Bayer AG stellte sich als erfolgreich heraus. Die Prognoseergebnisse der Predictive Analytics-Tools überzeugten mit einer höheren Planungsgenauigkeit, als bei den manuell erstellten Prognosen. Im Vergleich zu den algorithmenbasierten Prognosewerten, welche um 3% über den Ist-Werten lagen, wurden die manuell erstellten Prognosewerte sehr konservativ vorhergesagt und lagen um 13% über den Ist-Werten. Das lässt davon ausgehen, dass bei dem manuell erstellten Forecast eher konservativ geplant wird und ein Sicherheitspuffer angestrebt oder zumindest in Kauf genommen wird (Burow et al., 2017, S. 53).

Bei dem Implementierungsprojekt der Deutschen Post International konnte ebenfalls ein Erfolg erzielt werden. Im Laufe des Projekts erkannte die Deutsche Post International jedoch, dass durch die Auswahl eines Modells für alle Teilgeschäftsfelder unterschiedlich verlässliche Prognosewerte, abhängig von dem Teilgeschäftsfeld, erzielt werden. Aus diesem Grund wurden für die jeweiligen Teilgeschäftsfelder unterschiedliche Verfahren herangezogen, um die besten Ergebnisse zu erzielen. Durch die Kombination der Modelle konnte die durchschnittliche absolute Prozentabweichung zwischen den Predictive Analytics basierten Prognosewerten und den Ist-Werten auf 2,18% (zuvor über 4%) verbessert werden (Deipenbrock et al., 2019, S. 49).

## **5 Herausforderungen im Implementierungsprozess**

Durch die Einführung von Predictive Analytics-Tools erschließen sich für Unternehmen einige Chancen und Potenziale wie etwa die Effizienzerhöhung und die Verbesserung der Prognosegenauigkeit im Forecasting. Trotz der zahlreichen Vorteile wenden viele Unternehmen Predictive Analytics-Methoden noch nicht im Controlling an. Einer der mutmaßlichen Gründe hierfür dürfte der anspruchsvolle Implementierungsprozess sein. Unternehmen stoßen bei der Implementierung von Predictive Analytics im Controlling häufig auf Datenqualitätsprobleme, Algorithm Aversionen, Know-how-Mängel, fehlende Akzeptanz in der Organisation als auch im Controllingbereich und auf die Black-Box-Problematik (Holthoff & Decher, 2020, S. 53-55). Auf diese Herausforderungen wird in den nachfolgenden Kapiteln näher eingegangen.

### **5.1 Datenproblematik**

Im Hinblick auf die Digitalisierung, die Einführung von Predictive Analytics-Tools und dem damit einhergehenden Anstieg an zur Verfügung stehenden Datenmengen, treten neue Problemfelder für Controller:innen auf. Beispielsweise liegt es im Aufgabenbereich der Controller:innen, die Datenqualität zu gewährleisten und aus den großen Datenmengen die relevanten Daten auszuwählen (Losbichler et al., 2017, S. 66).

#### **5.1.1 Datenverfügbarkeit und Datenqualität**

Bereits 2017 wurde im Rahmen der WHU-Zukunftsstudie (Schäffer & Weber, 2018) festgestellt, dass das Datenmanagement zu den wesentlichen Herausforderungen bei der Digitalisierung des Controllings zählt. Bei der Studie führten zwei Drittel der 454 StudienteilnehmerInnen (CEOs, CFOs, Controllingleitende, Mitarbeiter:innen in Finanzpositionen) sowohl die Datenqualität als auch die Datenverfügbarkeit als nicht ausreichend an (Schäffer & Weber, 2018, S. 42-45).

Somit bildet die Datenaufbereitung bzw. Datenversorgung die wahrscheinlich größte Herausforderung bei der Implementierung von Predictive Analytics im Controlling (Oehler, 2019, S. 29). In einem ersten Schritt muss geklärt werden, welche Daten im Unternehmen zur Verfügung stehen und aus welchen Datentypen sich diese zusammensetzen. Wenn die vorhandene Datenbasis nicht ausreichend ist, muss analysiert werden, ob und wie die zur Implementierung erforderlichen Daten beschafft werden können. Hierbei können die Daten in externe und interne

Daten unterschieden werden. Unter externen Daten sind jene Daten zu verstehen, welche nicht aus dem Unternehmen stammen und extern beschafft bzw. zugekauft werden. Darunter würden zum Beispiel allgemeine Marktdaten zählen, die von Marktforschungsunternehmen erhoben, und an Unternehmen verkauft werden. Weiters gibt es noch öffentliche Daten, welche beispielsweise über demografische und wirtschaftliche Trends sowie staatliche Vorschriften Auskunft geben. Interne Daten stammen direkt aus den Systemen des Unternehmens und sind somit spezifische Unternehmensdaten (z.B. Informationen, dazu welche Kund:innen zu welchem Zeitpunkt welche Produkte gekauft haben). Bei Daten sollte ebenso auf das Aggregationslevel geachtet werden, also darauf, ob die Daten zusammengefasst wurden. So geht etwa aus den aggregierten Verkaufszahlen einer Filiale nicht hervor, aus welchen Kund:innen sich die Verkäufe zusammensetzen, Zudem ist es wichtig die unterschiedlichen Datentypen zu erkennen, um sie in späterer Folge sinnvoll anzuwenden (Vriens et al., 2019, S. 13-14).

Die Qualität der Datenbasis entspricht in der Regel nicht den Anforderungen der Predictive Analytics-Methoden. Es treten oftmals nicht ausgefüllte Datenfelder, Ausreißer und Dubletten (als Dublette versteht man z.B. die unterschiedliche Schreibweise von Müller und Mueller) auf. Weiters führt die fehlende Konsistenz bei der Anwendung von Schlüssel bei der Datenverarbeitung zu Schwierigkeiten mit den Daten (Oehler, 2019, S. 185). Die fehlende Konsistenz kann teilweise darauf zurückgeführt werden, dass die Daten aus verschiedenen Systemen herangezogen werden (Bley et al., 2020, S. 52). Doch es gibt eine Vielzahl an Gründen für Datenqualitätsprobleme. Zum Beispiel treten bei dem Zusammentragen von Daten internationaler Töchtergesellschaften oft Schwierigkeiten aufgrund abweichender Bewertungsansätze auf und es entstehen dadurch Inkonsistenzen. Darüber hinaus kommt es in manchen Fällen zu einer absichtlichen Beeinflussung der Datenqualität (Oehler, 2019, S. 339).

In den Daten auftretende Anomalien sorgen für Verwirrung bei den Algorithmen und müssen daher behoben werden (Oehler, 2019, S. 185). Treten Datenqualitätsprobleme auf, wird empfohlen diese sofort zu beheben. Allerdings sollen die Mängel nicht nur bei den Daten, welche für weitere Verfahren benötigt werden, bearbeitet und korrigiert werden. Die Mängel sollen vielmehr an der Stelle, an der sie auftreten, direkt an der Quelle behoben werden, um nicht in späterer Folge nochmals auf ein gleichartiges Datenqualitätsproblem zu stoßen (Vriens et al., 2019, S. 21).

In den meisten Fällen wird für die Anwendung von Business Analytics eine andere Datenbeschaffenheit benötigt, als von den üblichen Datenmanagementsysteme bereitgestellt wird. Auch sind ad-hoc Datenaufbereitungen mit einem hohen Aufwand verbunden und setzen ebenso technische Kenntnisse voraus (Oehler, 2019, S. 29). Der Caritasverband Moers/Xanten e.V. (Deutschland) sah sich bei der Einführung von Predictive Analytics im Personalcontrolling mit ähnlichen Schwierigkeiten konfrontiert (vgl. Drozdzyński, 2016). Im Bereich Finanzcontrolling wurden bei dem Caritasverband bereits erweiterte BI Lösungen (OLAP, interaktive Dashboards, etc.) eingesetzt. Dadurch sollte sich die Implementierung von Predictive Analytics bei den Finanzcontrollingprozessen nicht als schwierig erweisen. Das Hindernis stellte das autonome Personalverrechnungssystem des Verbandes dar. Die Daten aus dem Personalverrechnungssystem mussten in die Datenarchitektur des Finanzcontrollings integriert werden, um ebenfalls von den Predictive Analytics-Methoden angewandt werden zu können und um eine Konsistenz der Informationen gewährleisten zu können (Drozdzyński, 2016, S. 224).

### **5.1.2 Sensible personenbezogene Daten**

Eine weitere Herausforderung bei der Verarbeitung von Daten stellt sich vor allem im Personalcontrolling bei der Verwendung von personenbezogenen Daten. Da es sich bei Personaldaten Großteil um sensible personenbezogene Daten handelt, muss zuerst sichergestellt werden, dass diese für die Verwendung der Predictive Analytics-Tools auch herangezogen werden dürfen (Christ & Ebert, 2016, S. 307). Strohmeier & Piazza untergliedern bei derartigen Projekten den Implementierungsprozess in drei Teilprozesse, nämlich die rechtliche Implementierung, die technische Implementierung und die organisatorische Implementierung. Die Schritte der technischen und organisatorischen Implementierung gleichen denen von Standard-Predictive Analytics-Projekten (also Projekten, welche nicht personenbezogene Daten anwenden) und wurden bereits in den vorgelagerten Kapiteln behandelt. Für die rechtliche Implementierung müssen vorab Fragen des Datenschutzes und der Arbeitnehmermitbestimmung geregelt werden (Strohmeier & Piazza, 2015, S. 56). Dafür ist es erforderlich, sich mit den geltenden datenschutzrechtlichen Vorgaben in den betroffenen Ländern, vor der Einbeziehung der personenbezogenen Daten zu befassen und zu prüfen, welche Bestimmungen zu berücksichtigen sind (Reuter, 2021, S. 2). Bei der Durchführung von Predictive Analytics-Projekten, bei denen sensible Personaldaten als Datenbasis dienen, sollten daher immer die Datenschutzbeauftragten sowie der Betriebsrat des Unternehmens einbezogen werden (Strohmeier & Piazza, 2015, S. 56). Zudem müssen bei der Anwendung von Personaldaten die Zugriffsberechtigungen vorab

besprochen und festgelegt werden, um einen sicheren Umgang mit den personenbezogenen Daten gewährleisten zu können (Christ & Ebert, 2016, S. 307).

### **5.1.3 Überanpassung als Fehlerquelle**

Ein großes Risiko für ein fehlerhaftes Modell bildet die Überanpassung, die auch als „Overfitting“ bezeichnet wird. Unter Überanpassung versteht man ein inkorrektes Anlernen des Modells. Hierbei werden nicht allgemeingültige Muster der Daten erkannt und antrainiert, sondern vielmehr Zufallstreffer in den Daten gefunden und als gültig behandelt (Lanquillon & Mallow, 2015a, S. 72). Eine Überanpassung liegt vor, wenn Modelle auf jene vorhandenen Daten, welche als Trainingsdaten verwendet wurden, zugeschnitten werden und somit ihre Allgemeingültigkeit verlieren. Die Modelle werden überangepasst und sind somit unbrauchbar, um Vorhersagen für nicht antrainierte Daten zu treffen (Provost & Fawcett, 2017, S. 145). Zudem ist eine weitere Konsequenz der Überanpassung, dass eine eindeutige Interpretation des Modells nicht zulässig ist (Abbott, 2014, S. 15).

Aus diesem Grund sollten in mehreren Phasen Aktivitäten zur Erkennung und Prävention von Überanpassung erfolgen. Zum einen sind die in den Daten festgestellten Muster auf Allgemeingültigkeit hin zu überprüfen (Bentley, 2017, S. 67). Und zum anderen soll herausgefunden werden, ob das Modell verallgemeinerungsfähig im Hinblick auf neue Daten ist und wie verlässlich es sich dadurch bei neuen Daten zeigt. Neue Daten sind in diesem Fall Daten, die nicht zum Anlernen herangezogen wurden und die das Modell nun zum ersten Mal verwendet (Mailund, 2017, S. 146). Ein Modell wird dann als verallgemeinerungsfähig bezeichnet, wenn es bei unbekanntem Daten eingesetzt werden kann und zuverlässige Ergebnisse liefert. Demzufolge ist ein Modell nicht verallgemeinerungsfähig, wenn es nur bei den Trainingsdaten gültige Ergebnisse hervorbringt und somit nicht sinnvoll anwendbar ist (Provost & Fawcett, 2017, S. 145). Die Verallgemeinerungsfähigkeit der erkannten Muster ist erforderlich, da basierend auf diesen Mustern Vorhersagen getroffen werden sollen (Provost & Fawcett, 2017, S. 143).

In vielen Fällen liegt die Ursache für die Überanpassung an dem Komplexitätslevel der Modelle und Verfahren (Abbott, 2014, S. 15). Denn mit erhöhter Komplexität des Verfahrens steigt ebenso die Anzahl der zugrunde liegenden Parameter. Werden diese Parameter nicht korrekt ausgewählt, fallen die Resultate wesentlich schlechter aus (Lanquillon & Mallow, 2015a, S. 72).

## **5.2 Der menschliche Faktor**

Es zeigt sich, dass ein häufiges Problem bei der Implementierung von Predictive Analytics und bei der Implementierung anderer Digitalisierungstrends der Mensch selbst ist. Zum einen besteht keine Bereitschaft sich an die Veränderungen anzupassen und sich gemeinsam mit der Technologie weiterzuentwickeln. Zum anderen fehlen die fachlichen Kenntnisse, wobei dies teilweise eng mit dem mangelnden Willen der Mitarbeiter:innen zusammenhängt (Lausberg & Hoffmann, 2019, S.61).

### **5.2.1 Fehlendes Know-how**

Bei der Anwendung von Predictive Analytics im Controlling, treten häufig Anwendungs- bzw. Interpretationsschwierigkeiten auf. Die Controller:innen besitzen oftmals nicht das erforderliche Know-how, um die Ergebnisse sinnvoll und korrekt zu interpretieren und daraus Entscheidungen abzuleiten. In den meisten Fällen werden bei den Predictive Analytics-Forecasts mehrere abweichende Ergebnisse der jeweiligen Eintrittswahrscheinlichkeit bestimmt. Dabei stellt sich die Frage, wie man ein solches Resultat handhabt und welcher Interpretationsansatz zu wählen ist. Entweder man fährt mit dem Ergebnis fort, welches die höchste Eintrittswahrscheinlichkeit aufweist, und lässt die übrigen außer Acht, oder man entscheidet sich für die Variante des Durchschnittswerts der vorhergesagten Ergebnisse. Diesbezüglich sollte man nicht außer Acht lassen, welcher großen Aufwand die Einarbeitung und der Verständnisaufbau für die methodischen Vorgehensweisen in Anspruch nimmt. Weiters verfügen viele Controller:innen nicht über die technischen Kenntnisse, um die Predictive Analytics-Techniken nachvollziehen zu können. Hierbei besteht das Risiko, dass Controller:innen Predictive-Analytics-Methoden ohne kritische Auseinandersetzung mit den Thematiken, anwenden. Dies kann beispielsweise schnell zur Auswahl eines ungeeigneten Algorithmus führen oder zur falschen Interpretation der Resultate (Oehler, 2019, S. 27). Durch den Einfluss von Big Data und Business Analytics im Controlling hat sich das Anforderungsprofil für Controller:innen verändert. Zusätzlich zu den bisherigen Kompetenzen welche Controller:innen mitbringen mussten, wird es zunehmend wichtiger, dass sie ebenfalls statistische-Kenntnisse und ein Verständnis für Business Analytics aufweisen (Engelbergs, 2016, S. 11). Viele Controller:innen hatten bisher kaum Berührungspunkte mit Predictive Analytics. Aus diesem Grund fehlt vielen das Verständnis für die durch Predictive Analytics geschaffenen Möglichkeiten im Controlling. Zudem fehlt infolge des fehlenden Know-hows der Weitblick, um die Verbesserungspotenziale zu erkennen und die Einsatzmöglichkeiten von Predictive Analytics auszutesten (Oehler, 2019, S. 29).



### 5.2.2 Fehlende Akzeptanz

Eine nicht ausreichende Einbeziehung der betroffenen Interessensgruppen in den Projektablauf, kann beträchtliche Konsequenzen nach sich ziehen und in manchen Fällen sogar zu Fehlscheidungen führen (Oehler, 2018, S. 25). Im Evaluierungsprozess sollten ebenso die Interessensgruppen involviert werden und die Ergebnisse beurteilen. Dadurch können Fehler frühzeitig erkannt und behoben werden. Um allen Interessensgruppen eine Evaluierungsmöglichkeit bieten zu können, müssen die Data Scientists sicherstellen, dass die Ergebnisse (in Form der Modelle) verständlich aufbereitet werden, und eine geeignete Darstellungsform ausgewählt wird. Werden die Interessensgruppen nicht ausreichend eingebunden, kann dies in späterer Folge zu Akzeptanzproblemen der eingeführten Predictive Analytics-Tools führen (Provost & Fawcett, 2017, S. 58).

Bei der Implementierung von Predictive Analytics erweist sich die Algorithm Aversion der Menschen als Hindernis. Wissenschaftliche Studien zeigen, dass Menschen eine Abneigung gegen algorithmenbasierte Vorhersagen hegen. Die Erwartungen an algorithmenbasierte Prognosen sind im Gegensatz zu manuell erstellten wesentlich höher und es werden nur geringe Prognosefehler geduldet. Menschen zeigen mehr Verständnis für Prognosefehlern in manuell erstellen Vorhersagen und setzen bei der Anwendung von Algorithmen beinahe exakte Prognosen voraus. Ungeachtet dessen erzielen Predictive Analytics-Methoden eine höhere Planungsgenauigkeit als manuell erstellte Vorhersagen. In der Praxis ist jedoch die Generierung einer exakten Prognose durch den Einsatz von Algorithmen ausgeschlossen und daher entscheiden sich Menschen, trotz der Verbesserung der Planungsgenauigkeit gegenüber klassischen Prognosen, oftmals gegen die Anwendung von Predictive Analytics (Holthoff & Decher, 2020, S. 53-54).

Eine weitere Ursache für fehlende Akzeptanz stellt die Tatsache dar, dass viele Controller:innen befürchten, durch Methoden, wie Predictive Analytics ersetzt zu werden. In der bereits in Kapitel 5.1.1 erwähnten WHU-Zukunftsstudie war ein Drittel der Studienteilnehmenden davon überzeugt, dass es Änderungen in den Controllingbereichen geben wird und der Bedarf an Controller:innen zukünftig abnehmen wird (Schäffer & Weber, 2018, S. 47). Die Methoden werden daher als Bedrohung wahrgenommen und im Zuge der fortschreitenden Automatisierung wird eine Änderung des Controllingbereichs antizipiert (Holthoff & Decher, 2020, S. 56). Diese Be-

fürchtung weckt bei den Controller:innen eine gewisse Skepsis und führt teils zu einer ablehnenden Reaktion der Controllingbereiche gegenüber Predictive Analytics-Tools (Schäffer & Weber, 2018, S. 47).

Eine Herausforderung stellt jedoch nicht nur die Akzeptanzschaffung innerhalb des Controllings dar, sondern auch das Management muss überzeugt werden und Vertrauen in die Methoden von Predictive Analytics aufbauen. Ohne das erforderliche Commitment der Management-Ebene stellen die Planungsergebnisse ein theoretisch schönes Rahmenwerk dar, werden aber im Unternehmen nicht berücksichtigt und von den Mitarbeiter:innen nicht verinnerlicht. Die mitunter wichtigste Aufgabe der Planung – eine Koordinationsunterstützung zu bilden – würde somit nicht erfüllt werden (Schäffer, 2017, S. 36). Daraus ergibt sich ein weiteres Ziel der Planung, nämlich, dass die Ergebnisse seitens des Managements akzeptiert werden und dementsprechend die Befolgung und Einhaltung der definierten Ziele durch das Management sichergestellt wird (Schäffer, 2017, S. 37). In manchen Fällen werden Predictive Analytics-Tools allerdings als Black-Box aufgefasst. Controller:innen befürchten, die algorithmenbasierten Prognosen nicht vor dem Management verteidigen zu können. Da das Management oftmals Kommentierungen der Prognosewerte erwartet, stellt dies eine Herausforderung für das Controlling dar. Die Controller:innen können die prognostizierten Werte – anders als dies beispielsweise bei einer klassischen, manuell erstellten Prognose der Fall wäre – nicht von Grund auf herleiten und argumentieren. Daher sind einige Finanz-Fachexpert:innen der Ansicht, automatisierte Verfahren würden zu einer Intransparenz der Prognosewerte führen und sehen von einer Implementierung ab (Holthoff & Decher, 2020, S. 55-56).

### **5.2.3 Ressourcenproblematik**

Ein weiteres Problem, auf das viele Controllingteams bei einer Implementierung von Predictive Analytics stoßen, betrifft die Ressourcenplanung (Oehler, 2019, S. 28). Die erfolgreiche Implementierung von Predictive Analytics-Projekten im Controlling setzt einen hohen Arbeitsaufwand voraus. Weiters besteht bei Predictive Analytics-Projekten Bedarf an qualifizierten Projektmitgliedern. Diese sind in den meisten Fällen nicht einfach zu finden und mit hohen Kosten verbunden (Eckerson, 2007, S. 20). Es werden häufig Data Scientists herangezogen, um zu unterstützen (Oehler, 2019, S. 28).

In weiterer Folge erweisen sich die hohen Implementierungskosten sowie die anfallenden Kosten für den laufenden Einsatz als Hindernis bei der Implementierung (Bley et al., 2020, S. 51). Zu beachten gilt ebenso, dass vor allem für Unternehmen, die bisher den Digitalisierungstrend nicht gefolgt sind und die Setzung von Digitalisierungsmaßnahmen vernachlässigt haben, bei der Implementierung von Predictive Analytics-Lösungen jedenfalls höhere Anschaffungs- sowie Umsetzungskosten einkalkulieren sollten. Spätestens zu diesem Zeitpunkt wird sich die Nachlässigkeit bei der Systempflege und -wartung nachteilig auswirken und einen Mehraufwand erzeugen (Hoffjan & Wahrstötter, 2022, S. 24).

#### **5.2.4 Komplexitätsproblematik**

Trotz des steigenden Interesses an Predictive Analytics-Lösungen, schreckt viele Unternehmen der hohe Komplexitätsgrad der Implementierung ab (Brauchle & Hanisch, 2017, S. 220). Auch die Anwendung von Predictive Analytics im Controlling stellt sich oft als komplexer als in anderen Unternehmensbereichen heraus. Wie bereits erwähnt, findet Predictive Analytics bereits Eingang in Prozesse vieler anderer Unternehmensbereiche, wie beispielsweise im Marketing oder in der Produktion. Doch die Herausforderung, die sich im Controlling stellt, ist die Schaffung eines Gesamtbildes. Controllingprozesse umfassen in der Regel die Abstimmung verschiedener Bereiche eines Unternehmens oder sogar darüber hinaus des Konzerns. Zum Beispiel werden bei der Budgetierung sowohl konzernweite Vorgaben berücksichtigt, als auch die Inputs der Verantwortlichen für die jeweiligen Unternehmensbereiche. Je komplexer die Prozesse, bei welchen eine Integration der Predictive Analytics-Methoden stattfinden soll, desto schwieriger stellt sich die Implementierung sowie der zuverlässige Einsatz dieser Methoden dar (Oehler, 2019, S. 29).

## 6 Lösungsansätze

Unternehmen sehen sich im Rahmen des Implementierungsprozesses mit einer Vielzahl an Hindernissen konfrontiert. Im Kapitel 5 wurden häufig auftretende Herausforderungen, darunter beispielsweise fehlende Kompetenzen und Ressourcen sowie mangelnde Datenqualität, behandelt. Im Nachfolgenden werden Lösungsansätze bzw. Empfehlungen zur Überwindung der identifizierten Herausforderungen vorgestellt.

### 6.1 Datenproblematik

Bei Predictive Analytics Implementierungsprojekten im Controlling hat sich die Datenaufbereitung oftmals als Problem erwiesen (Oehler, 2018, S. 26). Vor allem die Datenverfügbarkeit und die Datenqualität stellen in der Praxis eine Herausforderung dar. Um die Hindernisse hinsichtlich der Datenverfügbarkeit zu eliminieren, wird die Verwendung eines Data Warehouses oder eines integrierten Datenmanagementsystems empfohlen (Holthoff & Decher, 2020, S. 57). In vielen Fällen sind auftretende Ausreißer und falsche bzw. fehlende Werte die Ursache für eine schlechte Datenqualität. Abbildung 5 veranschaulicht am Beispiel von Personaldaten häufig auftretende Fehlerquellen, wie beispielsweise uneinheitliche Darstellungen, Schreibfehler, unvollständige und fehlerhafte Werte (Strohmeier & Piazza, 2015, S. 67).

Mitarbeiterdaten					
ID	Name	Geschlecht	Geburtstag	Alter	Wohnort
1	Hans Maier	m	06.10.1974	16	Laxenburg
2	Josefine	w		111	Steiermark
2	Maier, Hans	z	06.10.1974	48	Laaxenburg

Die Abbildung zeigt vier Kästen oben, die auf die Tabelle zeigen:

- unvollständige Werte (auf die leere Zelle für den Geburtstag in der zweiten Zeile)
- fehlende Werte (auf die leere Zelle für den Geburtstag in der zweiten Zeile)
- widersprüchliche Werte (auf die unterschiedlichen Geschlechter 'm' und 'z' in den ersten beiden Zeilen)
- Duplikate (auf die ID '2' in den zweiten und dritten Zeilen)

Die Abbildung zeigt vier Kästen unten, die auf die Tabelle zeigen:

- nicht eindeutige Werte (auf die unterschiedlichen Namen 'Hans Maier' und 'Maier, Hans' in den ersten beiden Zeilen)
- uneinheitliche Darstellung (auf die unterschiedlichen Schreibweisen 'Laxenburg' und 'Laaxenburg' in den ersten und dritten Zeilen)
- unzulässige oder falsche Werte (auf den Alter-Werten '16', '111' und '48')
- Schreib- oder Tippfehler (auf den Wohnorten 'Steiermark' und 'Laaxenburg')

Abbildung 5. Häufig auftretende Fehler in HR-Datenquellen. (Strohmeier & Piazza, 2015, S. 67)

Doch es bestehen Möglichkeiten, diese Schwierigkeiten zu umgehen. Beispielsweise gibt es mit der sogenannten Klammertransformation eine einfache Herangehensweise, um Ausreißer

in der Datenbasis zu korrigieren. Bei der Klammertransformation gibt es einen oberen und einen unteren Schwellenwert. Alle Werte, die oberhalb des oberen Schwellenwerts liegen, werden auf den oberen Schwellenwert angepasst und für Werte die unterhalb des unteren Schwellenwerts liegen, wird der untere Schwellenwert herangezogen. Somit werden alle Werte, die außerhalb der Schwellenwerte liegen, auf die Schwellenwerte angeglichen. Auf diese Weise werden die Ausreißer aus der Datenbasis eliminiert und Verzerrungen werden vermieden (Kelleher et al., 2015, S. 73-74).

Ebenso gibt es Empfehlungen für die Handhabung von fehlenden Werten. In manchen Fällen werden fehlende Werte einer Variable durch einen Standardwert, beispielsweise „null“ oder den ermittelten Mittelwert der angeführten Werte ersetzt. Gleichzeitig wird eine neue Variable geschaffen, welche Auskunft darüber gibt, ob die besagte Variable ursprünglich einen Wert aufwies, oder durch einen Standardwert ergänzt wurde. Anzumerken ist jedoch, dass einem fehlenden Wert ebenso eine Bedeutung zukommen kann und er Informationen bereitstellen kann. Exemplarisch hierfür kann angeführt werden, dass Kund:innen eines Kreditinstituts welche einige Auskunftsfragen nicht beantworten, in der Regel eher einem Ausfallrisiko unterliegen als Kund:innen, welche dieselben Fragen beantworten. Aus der Nichtbeantwortung dieser Fragen können somit ebenfalls Schlüsse gezogen werden (Putler & Krider, 2012, S. 24). Es ist ratsam vor der Implementierung von Predictive Analytics-Tools Projekte zur Verbesserung der Datenqualität durchzuführen (Holthoff & Decher, 2020, S. 57).

## **6.2 Überanpassung**

Um die Überanpassung zu erkennen, sollten Tests mit den vorhandenen Daten durchgeführt werden (Provost & Fawcett, 2017, S. 175). Dazu sollten jene Daten, welche zum Lernen des Modells herangezogen werden, in der Modellierungsphase in drei Teilmengen gegliedert werden (Lanquillon & Mallow, 2015a, S. 72). Bei der Aufteilung der Daten in Proben, können Konzepte wie beispielsweise die k-Fold-Cross-Validation angewandt werden. Unter k-Fold-Cross-Validation versteht man die Unterteilung der Daten in gleich große Untergruppen (folds) nach dem Zufallsprinzip. Dabei steht das „k“ für die Anzahl der Untergruppen. Nach jedem Durchlauf rotieren die Untergruppen solange bis jede Untergruppe einmal zum Testen verwendet wurde (Abbott, 2014, S. 131).

Die erste der drei Teilmengen wird auch Trainingsprobe bezeichnet und mithilfe dieser Probe von Daten lernt das Modell (Trahasch & Felden, 2019, S. 72). Dadurch werden die zu testenden Modelle aufgebaut. Die zweite Teilmenge stellt die Validierungsprobe dar. Diese Probe dient zum Vergleich der erstellten Modelle und soll deren Qualität und Gültigkeit unter Beweis stellen. Auf Basis dieser Ergebnisse wird die Entscheidung für das optimale Modell getroffen (Putler & Krider, 2012, S. 26). Die dritte und somit letzte Teilmenge wird Testmenge bezeichnet und zur Analyse der Fehlerrate des Modells eingesetzt. Die Testmenge wird ausschließlich für das erlernte Modell verwendet, also niemals zum Lernen des Modells. Das erlernte Modell wird bei der Testmenge eingesetzt, da der Modellierungsmethode die in der Testmenge enthaltenen Daten noch nicht bekannt sind. Aufgrund der Neuheit der Daten kann damit getestet werden, ob das Modell die unbekanntenen Daten verarbeiten kann. Demnach wird mit der dritten Teilmenge der Daten die Allgemeingültigkeit des Modells überprüft. Ziel ist es, ein Vorhersagemodell aufzubauen, welches eine geringe Fehlerrate besitzt und sehr gut mit unbekanntenen Daten umgehen kann (Trahasch & Felden, 2019, S. 74).

Um eine Überanpassung zu vermeiden, sollten vor allem zu Beginn einfachere Verfahren gewählt werden. Dadurch wird die Wahrscheinlichkeit erhöht, dass am Ende des Prozesses ein allgemeingültiges Modell hervorgeht und es besteht die Möglichkeit das Modell im Laufe des Projekts oder nach der Evaluierungsphase, falls genügend Ressourcen vorhanden sind, zu verbessern (Abbott, 2014, S. 15). Festzuhalten ist jedoch, dass Überanpassungen bei jedem Modelltyp beobachtbar sind und man eine Überanpassung bei keinem Modelltyp vollkommen ausschließen kann (Provost & Fawcett, 2017, S. 175).

Weiters kann das Risiko der Überanpassung durch die Kombination mehrerer Modelle, auch als Model Ensembles bezeichnet, minimiert werden. Dies hat den Hintergrund, dass die Ergebnisse mehrerer Modelle im Durchschnitt genauere Ergebnisse liefern, als ein einzelnes Modell (Lanquillon & Mallow, 2015a, S. 73). Zu dieser Erkenntnis ist ebenso die Deutsche Post International gekommen. Im Zuge der Implementierung von Predictive Analytics im Controlling der Deutschen Post International hat sich herausgestellt, dass sich die Anwendung unterschiedlicher Methoden und Kombinationen in den verschiedenen Teilgeschäftsfeldern am effektivsten erweist (Deipenbrock et al., 2019, S. 59).

### 6.3 Der menschliche Faktor

Bezüglich des geänderten Anforderungsprofils für Controller:innen besteht für Unternehmen die Möglichkeit, ihre Controllingmitarbeiter:innen in den Bereichen rund um BI mehr einzubinden. Davon könnten beide Bereiche profitieren. Controller:innen könnten ein Verständnis für die angewandten Verfahren und Methoden aufbauen und durch ihr Fachwissen könnten die Prozesse verbessert werden. Beispielsweise schafft das Unternehmen Zalando aktiv Schnittstellen zwischen den Bereichen Data Science und Controlling (Engelbergs, 2016). Controller:innen dürfen sich ganze Tage in den Bereich der Data Scientists einbringen, um Erfahrungen zu sammeln. Somit können Controller:innen bei einem „On the Job“-Training Kompetenzen aufbauen und ein technisches Verständnis für die Methoden entwickeln (Engelbergs, 2016, S. 11). Die Weiterbildung in dem Bereich Data Science stellt auf jeden Fall ein Entwicklungsfeld für Controller:innen in Zukunft dar (Schäffer, 2017, S. 39). Jedoch stellt sich die Frage, in welchem Ausmaß sich Controller:innen mit den Methoden und Tools auseinandersetzen sollten. Diesbezüglich wird die Zusammenarbeit mit Data Scientists sowie eine sinnvolle Aufgabentrennung empfohlen. Aufgaben, die ein tiefgründiges Modellierungswissen und Methodenverständnis voraussetzen, sollten von Data Scientists übernommen werden (Reitzenstein & Sdahl, 2018, S. 15).

Infolgedessen ist es von großer Bedeutung, ein gut funktionierendes Team für ein Predictive Analytics-Projekt zusammenzustellen (Chamoni & Gluchowski, 2017, S. 16). Demgegenüber kann auch angedacht werden, einen Data Scientist fest in den Finanzbereich einzugliedern. Aufgrund der stetig steigenden Anforderungen bezüglich der angewandten Tools werden die Modellierungsfähigkeiten der Data Scientists in Zukunft erforderlich sein. Auf diese Weise könnten Controller:innen mehr Zeit in ihre Funktion als Unterstützung der Geschäftsführung bei der Entscheidungsfindung investieren. Im Zuge dessen können Controller:innen einen verbesserten Überblick über den gesamten Geschäftsprozess erlangen und bei Bedarf Prozessoptimierungen veranlassen (Kieninger & Schimank, 2017, S. 13).

Zur Akzeptanzschaffung von Business Analytics-Tools im Unternehmen können konkrete Use Cases bzw. Pilotprojekte herangezogen werden, anhand dessen man die Potenziale und den Nutzen derartiger Tools aufzeigt. Denn durch konkrete Use Cases direkt im Unternehmen kann Akzeptanz sowohl im Controlling als auch in der Organisation geschaffen werden. Positive

Ergebnisse sowie auch nur kleine Fortschritte zeigen eine motivierende und Vertrauen stärkende Wirkung (Schäffer, 2017, S. 37). Für die Darstellung und Behandlung von Anwendungsfällen ist die Erstellung von Rahmenkonzepten hilfreich. Diese sollten die wichtigsten Bestandteile, wie etwa nützliche Datenquellen, die Zielsetzung, erwartete Problemfelder, etc. enthalten. Mithilfe des Use Cases soll ein Verständnis für die Ansätze von Business Analytics geschaffen werden und infolgedessen das Vertrauen in innovative, neue Tools aufgebaut bzw. gestärkt werden (Brauchle & Hanisch, 2017, S. 221). Exemplarisch hierfür kann der Konzern KSB – ein internationaler Pumpen und Armaturenhersteller – angeführt werden (Mayer et al., 2017, S. 228). KSB hatte es sich zum Ziel gesetzt, digitales Forecasting einzuführen und hat diesbezüglich ein Pilotprojekt gestartet. Das Projekt verfolgte zum einen die Zielsetzung, digitale Forecasts für den Auftragseingang zu erstellen. Zum anderen sollten die Möglichkeiten von Big Data und Business Analytics aufgezeigt und anwendungsbezogen vermittelt werden, sowie die Fähigkeiten der Mitarbeitenden in diesem Bereich ausgebaut werden (Mayer et al., 2017, S. 238).

Fachexperten empfehlen ebenso das Backtesting zur Vertrauensschaffung. Beim Backtesting wird überprüft, wie hoch die Wahrscheinlichkeit des Eintreffens der jeweiligen Vorhersagen der Predictive Analytics-Ergebnisse bei in der Vergangenheit liegenden Werten gelegen wäre. D.h. es sollen Prognosen für zurückliegende Ereignisse erstellt werden, welche dann der klassischen Planung gegenübergestellt werden und auf bessere Prognosegenauigkeit überprüft und abgeglichen werden. Es wird also die Prognosegüte der Predictive Analytics Modelle bestimmt. Das Controllingteam kann bei einem Backtesting-Prozess z.B. auf Monatsbasis die Predictive Analytics Ergebnisse mit der klassischen Planung abgleichen. Die dadurch geschaffene Transparenz trägt wesentlich zum Vertrauensaufbau in Predictive Analytics-Ansätze bei (Schäffer, 2017, S. 38).

In einigen Unternehmen wurde eine Vorgehensweise geschaffen, welche vorbeugend gegen eine Algorithm Aversion eingesetzt wird. Denn wie bereits in Kapitel 5.2.2 erläutert, ist es schwierig für Menschen, algorithmenbasierte Prognosewerte unverändert in die Planung aufzunehmen. Dem Algorithmus wird nämlich häufig nicht ausreichend Vertrauen geschenkt und Menschen haben das Gefühl, dass ihre manuell erstellten Prognosen logischer sind (Holthoff & Decher, 2020, S. 52). Aus diesem Grund wäre ein passender Lösungsansatz für die Algorithm Aversion, die algorithmenbasierten Prognosewerte nicht unreflektiert und vollständig in die Planung bzw. den Forecast einzubinden. Vielmehr wird geraten, die durch Predictive Analytics



erstellten Prognosewerte als Orientierungswert einzusetzen und eine manuelle Anpassung bei Bedarf zu ermöglichen. Die automatisierten Vorhersagen können als Vorschlag betrachtet werden und Controller:innen prüfen diese auf Sinnhaftigkeit und integrieren gegebenenfalls nur einzelne Prognosewerte. Obwohl in manchen Fällen nicht alle vorhergesagten Werte übernommen werden, ermöglicht diese Vorgehensweise dennoch eine Aufwandsreduktion sowie eine Effizienzsteigerung. Es können beispielweise verhältnismäßig unbedeutende Positionen durch algorithmenbasierte Verfahren prognostiziert werden, die bei der manuellen Prognose mit einem hohen Aufwand verbunden wären. Im Zuge dessen würden Kapazitäten für größere, und eine höhere Beachtung verdienende Prognosepositionen freigesetzt werden (Holthoff & Decher, 2020, S. 55).

Um die Black-Box-Problematik in den Griff zu bekommen, wird zum einen empfohlen das Transparenzlevel bei der Erstellung der Prognosewerte durch Predictive Analytics-Tools zu erhöhen. Zum anderen wird geraten das methodenspezifische Know-how der Controller:innen zu stärken, sodass diese die Verfahren zur Generierung der Prognosewerte nachvollziehen können und ein Verständnis für die prognostizierten Werte erlangen (Holthoff & Decher, 2020, S. 56). Überdies ist es erforderlich die algorithmenbasierten Prognosewerte verständlich an die Entscheidungsträger:innen zu kommunizieren und dadurch Transparenz und Vertrauen in die Predictive Analytics-Tools zu schaffen (Chartered Institute of Management Accountants, 2016, S. 14).

Darüber hinaus gilt es festzuhalten, dass die Befürchtung von Controller:innen, durch Predictive Analytics-Tools ersetzt zu werden in den meisten Fällen in ihrem Einflussbereich liegt. Der Tätigkeitsbereich im Controlling wird sich verändern und sich an die innovativen Methoden und Techniken anpassen. Angesichts der veränderten Gegebenheiten sollte das Controlling bereit sein, sich weiterzuentwickeln und konkrete Maßnahmen zu setzen, um die zukünftigen Herausforderungen zu meistern. Diese Veränderungen stellen durchaus neue Chancen für das Controlling dar (Schäffer & Weber, 2018, S. 47). Denn schließlich dienen Predictive Analytics-Tools als Unterstützung bei den Controlling Tätigkeiten. Die Predictive Analytics-Modelle bieten eine Effizienzsteigerung und Aufwandsreduktion, aber zielgerichtetes Controlling erfordert mehr (Schäffer, 2017, S. 39). Der ersatzlose Austausch von Menschen durch algorithmenbasierte-Tools ist vor diesem Hintergrund eher unwahrscheinlich (Provost & Fawcett, 2017, S. 392). Denn für einige Tätigkeiten im Controlling als auch in anderen Unternehmensbereichen,

bedeutet der Einsatz von Predictive Analytics eine Effizienzsteigerung und bietet neue Möglichkeiten. Für andere Tätigkeiten wiederum sind computergestützte Technologien weniger geeignet, und menschliche Kreativität ist gefragt. Computergestützte Technologien erbringen beispielsweise sehr gute Ergebnisse bei der Auswertung von großen Datenmengen. Liegen jedoch nur wenige Informationen vor, fällt es Menschen einfacher die Tätigkeiten zu verrichten (Provost & Fawcett, 2017, S. 392). Durch die Zusammenarbeit des menschlichen Verstands und computergestützter Technologien haben sich in diesem Bereich neue Möglichkeiten eröffnet. Predictive Analytics-Techniken nutzen diese Kombination, um bestmögliche Ergebnisse zu liefern. Angebote von Softwarelösungsanbietern, welche versprechen den Menschen zu ersetzen, sind äußerst fragwürdig und sollten skeptisch betrachtet werden. Denn um Predictive Analytics-Tools zu implementieren, ist eine zu behandelnde Problemstellung und eine Zielsetzung festzulegen. Ein Problem wird von Menschen erkannt und es folgt eine Beurteilung, ob eine Predictive Analytics-Lösung als sinnvoll erachtet wird (Provost & Fawcett, 2017, S. 393).

Jedoch ist das menschliche Wissen nicht nur im Anfangsstadium der Implementierung gefragt. Vielmehr spiegelt sich die Bedeutung der menschlichen Interaktion in allen Phasen des Implementierungsprozesses wider. Die entscheidende Rolle der menschlichen Fähigkeiten in der Business Understanding Phase, in welcher eine Problemstellung und ein Ziel definiert wird, wurde bereits erwähnt. Beim Data Understanding ist die menschliche Beurteilung der Daten von Relevanz, denn die Daten müssen verstanden und richtig interpretiert werden, um Entscheidungen für die Auswahl der Daten zu treffen. In der Datenaufbereitung wird das Fachwissen und der Menschenverstand benötigt, um Irritationen und Anomalien in den Daten zu erkennen. Die Modellierungsphase erfordert die Auswahl eines geeigneten Verfahrens hinsichtlich der Zielsetzung und der Datengrundlage. In der Phase der Evaluierung ist es entscheidend, die Modelle zu überprüfen und die Gültigkeit zu hinterfragen – diese Aufgabe setzt ebenfalls menschliches Wissen voraus. Die letzte Phase des Implementierungsprozesses – die Phase des Deployments – erfordert gleichfalls menschliche Interaktion. Denn es sind eine Vielzahl von Entscheidungen zu treffen, welche auf subjektiven menschlichen Beurteilungen basieren (Provost & Fawcett, 2017, S. 393). Zudem weisen die Ergebnisse von Predictive Analytics-Tools eine Vergangenheitsorientierung auf. Daraus lässt sich schließen, dass erstmalig auftretende Ereignisse keine Berücksichtigung in den Ergebnissen finden. Um verfälschte Ergebnisse zu vermeiden, werden manuelle Einschätzungen mit den Predictive Analytics-Verfahren verknüpft. Menschen sollten ohnehin jederzeit in die Prozesse eingreifen und die erzeugten Daten bearbeiten können. Diese

Notwendigkeit besteht unter anderem aus dem Grund, dass Fachexpert:innen oft mehr Detailwissen besitzen und beispielsweise Kenntnisse über bevorstehende Kundenaufträge besitzen und diese dementsprechend bei den Vorhersagen Berücksichtigung finden (Oehler, 2019, S. 197-198). Darüber hinaus sollte berücksichtigt werden, dass die zugrunde liegenden Daten ebenfalls die Resultate menschlicher Entscheidungen darstellen. Die Daten basieren somit auf Erfahrungen, Meinungen und Interpretationen von Menschen (Provost & Fawcett, 2017, S. 393).

#### **6.4 Komplexitäts- und Ressourcenproblematik**

Weiters wird bezüglich der Komplexität bei der Implementierung und der Anwendung von Predictive Analytics empfohlen, einem Vorgehensmodell (wie CRISP-DM) zu folgen (Brauchle & Hanisch, 2017, S. 220). Anhand eines Vorgehensmodell kann ein strukturierter Ablauf bei der Implementierung sichergestellt werden (Azevedo & Santos, 2008, S. 184). Ferner werden im Zuge des CRISP-DM Modells Routinen zur Kontrolle der Validität erstellt, welche bei der späteren Anwendung unterstützen (Putler & Krider, 2012, S. 28).

Im Hinblick auf die hohen Implementierungskosten und den hohen zeitlichen Aufwand gilt es zu hinterfragen, wie viel Zeit und wie hohe Kosten tatsächlich im Zuge der Implementierung von Predictive Analytics anfallen. Dabei ist ein Vergleich zu dem Aufwand anzustellen, der in Planungs- und Forecastprozessen investiert werden muss (Schäffer, 2017, S. 38).

## **7 Empirische Untersuchung**

Nachfolgend wird auf die empirische Komponente dieser wissenschaftlichen Arbeit eingegangen. Neben einer ausführlichen Literaturrecherche wurden Experteninterviews durchgeführt, um zu überprüfen, ob die in der Literatur beschriebenen Herausforderungen in der Praxis tatsächlich eine Hürde für die Implementierung von Predictive Analytics darstellen. Weiters wurde hinterfragt, ob Predictive Analytics-Lösungen im Controlling Potenzial haben und die vielfältigen, in der Literatur erwähnten Anwendungsmöglichkeiten im Controlling in der Praxis zutreffen. Es wurde erforscht, wo sich Grenzen von Predictive Analytics abzeichnen, ob Predictive Analytics-Methoden in Krisenzeiten an ihre Grenzen stoßen, und ob in derartig volatilen Zeiten von einer Implementierung abgesehen werden sollte.

### **7.1 Untersuchungsdesign**

Im Rahmen der empirischen Untersuchung wurde für diese Masterarbeit ein qualitatives Forschungsdesign ausgewählt. Beim Forschungsinstrument fiel die Entscheidung auf das problemzentrierte Interview. Bei dieser Form des Interviews setzt sich die interviewende Person bereits vorab mit den theoretischen Konzepten auseinander. Somit wird schon vor der Befragung Wissen für die im Hinblick auf die zentrale Fragestellung relevanten Aspekte der Untersuchung aufgebaut. Im Laufe des Interviews überprüft die interviewende Person die theoretischen Konzepte mit den Antworten der befragten Person auf Übereinstimmung (Lamnek, 2010, S. 348).

Das problemzentrierte Interview wird als offene, halbstrukturierte Form der Befragung eingestuft. Dies hat zur Konsequenz, dass die Befragten weitgehend frei die Fragestellungen beantworten können und die Befragungsförm somit einem offenen Gespräch ähnelt. Jedoch ist das Interview auf eine konkrete Problemstellung zentriert, auf welche die interviewende Person das Gespräch bei einer Themenabweichung wieder zurücksteuert. Unterstützend wird hierfür ein Interviewleitfaden eingesetzt, der die Zentrierung des Interviews auf die Problemstellung sicherstellt (Mayring, 2016, S. 67-69). Nähere Informationen zu der Erstellung des Interviewleitfadens folgen in Kapitel 7.2.

Es wurden Interviews mit Experten geführt und deren Antworten wurden im Zuge einer Inhaltsanalyse untersucht, um neue Erkenntnisse zu gewinnen. Vor der Durchführung der Interviews wurde eine umfassende Literaturrecherche durchgeführt, um sich mit den theoretischen

Konzepten zu befassen. Es wurden neun Interviews mit Experten durchgeführt. Fünf der neun befragten Personen leben und arbeiten in Österreich, die verbleibenden vier in Deutschland. Aus diesem Grund und der zeitlichen Einschränkungen wurde entschieden, alle Interviews per Videotelefonat zu führen.

Die Interviews wurden unter Zustimmung der Interviewten aufgezeichnet und anschließend transkribiert, um die Inhalte für eine Analyse zugänglich zu machen. Die Transkription wurde in Anlehnung an das einfache Transkriptionssystem von Dresing & Pehl durchgeführt (Dresing & Pehl, 2018). Demnach wurde wörtlich transkribiert und es wurden keine Zusammenfassungen vorgenommen. Das Gesprochene wurde leicht geglättet, d.h. abgebrochene Wörter, Stottern und aufeinander folgende Wortwiederholungen (sofern diese nicht bewusst zur Verdeutlichung eingesetzt wurden) wurden nicht transkribiert. Unverständliche Stellen wurden durch die Abkürzung „unv.“ gekennzeichnet und unklare bzw. vermutete Wörter wurden mit einem Fragezeichen und einer Klammer versehen. Sätze bzw. Wörter im Dialekt wurden, insofern eine adäquate Übersetzung möglich war, ins Hochdeutsche übersetzt. Die Aussagen der Interviewpartner werden in den Transkripten durch die Abkürzung „I“ und die der Interviewführer durch den Buchstaben „B“ dargestellt (Dresing & Pehl, 2018, S. 21-22).

## **7.2 Konzeption des Interviewleitfadens**

Als unterstützende Hilfestellung wurde in allen Interviews ein Leitfaden angewandt. Dieser ist im Anhang dieser Arbeit zu finden. Leitfäden werden aus mehreren Gründen bei Interviews eingesetzt. Zum einen verschaffen sie Hilfestellung bei der Strukturierung des Interviews und unterstützen die befragende Person, falls diese im Laufe des Interviews ins Stocken gerät. Zum anderen kann anhand des Leitfadens die vollständige Behandlung der relevanten Aspekte sichergestellt werden, und am Ende des Interviews kann dieses Instrument als „Checkliste“ verwendet werden. In Abhängigkeit vom Strukturierungsgrad des Interviews kann der Leitfaden ausformulierte Fragestellungen oder lose Stichworte beinhalten (Mey, Mruck & Katja, 2007, S. 268). Ein weiterer Grund war die erleichterte Vergleichbarkeit der Interviews durch die teilweise Standardisierung mittels des Leitfadens (Mayring, 2016, S. 70). Der Interviewleitfaden wurde für alle Interviewpartner gleich gestaltet. Einem Interviewpartner wurde dieser vorab auf dessen ausdrücklichen Wunsch zur Verfügung gestellt, die verbleibenden acht Interviewpartner waren mit den Fragen vor dem Interview nicht vertraut.

Die im Rahmen der Literaturrecherche identifizierten Themenbereiche wurden bei der Erstellung des Interviewleitfadens in konkrete Fragestellungen zerlegt. Bei der Auswahl der Fragen, wurde die vorgesehene Interviewdauer von etwa 30 Minuten berücksichtigt. Der Leitfaden beinhaltet neun offene Hauptfragen und vier Zusatzfragen, welche abhängig vom Gesprächsverlauf und der Antwortgenauigkeit gestellt wurden. Es wurde bei der Konzeption des Fragebogens die offene Fragestellung gewählt, da den Interviewpartnern ein möglichst großer Spielraum bei der Beantwortung der Fragen eingeräumt und subjektive Perspektiven hervorgebracht werden sollten (Lamnek, 2010, S. 327). Die Fragen wurden im Interviewleitfaden ausformuliert und nummeriert. Bei der Gliederung des Leitfadens wurden zwei Ebenen erstellt. Die erste Ebene bilden die nummerierten Hauptfragen und auf der zweiten Ebene sind Zusatzfragen dargestellt. Fragen der zweiten Ebene wurden nur gestellt, falls die Interviewpartner auf einzelne, relevante Aspekte nicht bereits bei der Beantwortung der Hauptfragen eingegangen sind. Hinsichtlich der Nummerierung der Fragen gilt es jedoch anzumerken, dass diese nicht zwangsläufig auch in dieser Reihenfolge den Interviewpartnern gestellt wurden. Die Fragen wurden entsprechend dem Gesprächsverlauf und der individuellen Situation gestellt.

### **7.3 Auswahl der Interviewpartner**

Die Auswahl der Interviewpartner basierte auf einer ausführlichen Literatur- sowie Internetrecherche. Es wurde nach Expert:innen in den Fachgebieten Predictive Analytics, Business Analytics und BI gesucht. Dazu wurden Autor:innen, die einschlägige Fachartikel zu Predictive Analytics im Controlling publizierten, Vortragende sowie Mitarbeiter:innen und Geschäftsführer:innen renommierter BI- und Analytics-Lösungsanbieter kontaktiert. Es wurden Expert:innen sowohl aus Österreich als auch aus Deutschland kontaktiert, da die Anzahl der Anbietenden von Predictive Analytics-Lösungen ausschließlich in Österreich als nicht ausreichend betrachtet wurde. Auch werden Serviceleistungen in Zeiten der Digitalisierung und der Videotelefonie grenzüberschreitend erbracht und der Standort der Serviceanbieter ist nicht entscheidend. Die Kontaktaufnahme erfolgte per E-Mail oder via LinkedIn. Im Anschluss wurden Interviews mit neun Experten geführt. Die Interviewpartner wurden nachfolgend anonymisiert und fortlaufend nummeriert.

## Übersicht der Interviewpartner

<b>Interviewpartner 1</b>	Interviewpartner 1 ist Business Development Manager bei einem Digitalisierungsanbieter in Österreich. Das Unternehmen unterstützt Kunden unter anderem in den Bereichen Data Science, AI und Modern BI.
<b>Interviewpartner 2</b>	Interviewpartner 2 ist Leiter des Bereichs Business Data Solutions bei einem auf Analytics und Data Management spezialisierten Unternehmensberater in Deutschland. Das Unternehmen bietet unter anderem Unterstützung bei der Implementierung und Weiterentwicklung von Analytics-Lösungen an.
<b>Interviewpartner 3</b>	Interviewpartner 3 ist Geschäftsführer eines deutschen Unternehmens, welches sich auf die Bereitstellung von IT-Lösungen zur Unternehmenssteuerung fokussiert. Das Unternehmen berät Kunden bei der Anwendung und Implementierung von Planungs- und Budgetierungslösungen.
<b>Interviewpartner 4</b>	Interviewpartner 4 ist Geschäftsführer einer Unternehmensberatung in Österreich. Das Unternehmen bietet umfangreiche Lösungen für die Unternehmenssteuerung und das Controlling an und unterstützt unter anderem bei der Implementierung von Analytics-Tools.
<b>Interviewpartner 5</b>	Interviewpartner 5 ist Senior Vice President bei einem international agierenden Beratungsunternehmen an einem deutschen Standort tätig. Das Unternehmen bietet unter anderem die Integration von Advanced Analytics-Lösungen in die Geschäftsprozesse an.
<b>Interviewpartner 6</b>	Interviewpartner 6 ist Geschäftsführer eines international agierenden Unternehmens in Österreich. Das Unternehmen bietet KI-gestützte Softwarelösungen für Finanzabteilungen an.
<b>Interviewpartner 7</b>	Interviewpartner 7 ist Lehrbeauftragter an einer Fachhochschule in Österreich und steht durch seine Funktion innerhalb einer internationalen Organisation in regelmäßigen Austausch mit Unternehmen.
<b>Interviewpartner 8</b>	Interviewpartner 8 ist Geschäftsführer eines deutschen Unternehmens, dass sich auf die Erstellung und Implementierung von AI-gestützte-Software spezialisiert hat.
<b>Interviewpartner 9</b>	Interviewpartner 9 ist Geschäftsführer eines Beratungsunternehmens in Österreich. Das Unternehmen unterstützt unter anderem bei der Umsetzung von BI- und Analytics-Lösungen im Controlling.

*Tabelle 1. Übersicht der Interviewpartner. (eigene Darstellung)*

## 7.4 Auswertungsverfahren

Zur Auswertung der Interviews wurde eine qualitative Inhaltsanalyse nach den Ansätzen von Mayring durchgeführt (Mayring, 2022). Bei einer Inhaltsanalyse werden Materialien, die aus einer beliebigen Form der Kommunikation resultieren, analysiert. Forschungsgegenstand einer Inhaltsanalyse können Bilder, Musik, Texte und weitere symbolische Materialien sein (Braun-ecker, 2016, S. 19). In dieser Arbeit wurden die geführten Experteninterviews nach den in Kapitel 7.1 beschriebenen Regeln transkribiert und als Gegenstand der Inhaltsanalyse herangezogen.

Die grundlegenden Charakteristika einer Inhaltsanalyse sind die systematische Vorgehensweise, die sowohl regelgeleitet als auch theoriegeleitet getrieben ist. Dies bedeutet, dass die Inhaltsanalyse entsprechend eines Regelwerks durchgeführt wird, um sicherzustellen, dass die Analyse für Dritte nachvollziehbar und verständlich ist. Es ist essenziell, dass eine intersubjektive Nachprüfbarkeit gegeben ist, also dass die Analyseergebnisse durch Dritte überprüft werden können. Ein weiterer Anspruch an die Inhaltsanalyse ist, dass sie theoriegeleitet durchgeführt werden. Dementsprechend sollen die Durchführungsschritte an den theoretischen Überlegungen anknüpfen und bei der Auswertung sollen die theoretischen Grundlagen berücksichtigt werden. Der Theoried Hintergrund soll auf Übereinstimmungen mit den Ergebnissen der Analyse überprüft werden und um neue Erkenntnisse erweitert werden (Mayring, 2022, S. 13).

Die qualitative Inhaltsanalyse kennt drei Grundformen. Konkret handelt es sich dabei um die Zusammenfassung, die Explikation und die Strukturierung (Mayring, 1994, S. 164). Im Rahmen dieser Arbeit wurde eine zusammenfassende Inhaltsanalyse durchgeführt. Bei dieser Grundform wird das Material auf die wesentlichsten Inhalte reduziert, sodass ein überschaubarer Korpus des Materials entsteht. Diese Technik eignet sich darüber hinaus auch für eine induktive Kategorienbildung, näheres dazu in Kapitel 7.6 (Mayring, 2016, S. 115). Nach Mayring gilt es in einem ersten Schritt bei jeder Inhaltsanalyse das Ausgangsmaterial zu definieren, um ein Verständnis aufbauen zu können und Nachvollziehbarkeit gewährleisten zu können. Erst im Anschluss variiert das Vorgehen der Analyse entsprechend der jeweiligen Grundform der qualitativen Inhaltsanalyse (Mayring, 2022, S. 53-54). Bei der im Rahmen dieser Arbeit durchgeführten Inhaltsanalyse wurden die Transkripte der Experteninterviews als Ausgangsmaterial herangezogen. Bei der Durchführung einer zusammenfassenden qualitativen Inhaltsanalyse wird das Ausgangsmaterial, paraphrasiert, generalisiert und reduziert. Es werden nicht bzw.



wenig inhaltstragende Textbestandteile (z.B. wiederholende oder ausschmückende Inhalte) weggelassen (Mayring, 2022, S. 70). Die Schritte der Paraphrasierung, Generalisierung und Reduktion wurden im Rahmen dieser qualitativen Forschung zusammengefasst. Diese Vorgehensweise wurde aufgrund der spezifischen Fragestellung und der Materialmenge ausgewählt. Bei dem Auswertungsprozess wurde unterstützend eine Software für qualitative Datenanalyse verwendet. Mithilfe dieser Software wurden die Kodierung und Paraphrasierung vorgenommen.

## **7.5 Gütekriterien**

In der empirischen Forschung dienen Gütekriterien zur Messung der Qualität der Ergebnisse. Hierbei werden die Gütekriterien für die quantitative Forschung – Validität und Reliabilität – von denen der qualitativen Forschung unterschieden (Mayring, 2016, S. 140). Für die qualitative Forschung gibt es sechs Gütekriterien:

### **Verfahrensdokumentation**

Das erste Gütekriterium ist das der Verfahrensdokumentation. Um wissenschaftlich wertvolle Forschungsergebnisse zu erzielen, muss das Verfahren der qualitativen Forschung detailliert dokumentiert werden. Der gesamte Forschungsprozess muss anhand dieser Dokumentation für Dritte nachvollziehbar sein (Mayring, 2016, S. 144-145). Die Verfahrensdokumentation dieser qualitativen Forschung erfolgt in Kapitel 7. Es wird die Konzeption des Interviewleitfadens, die Auswahl der Interviewpartner sowie die Durchführung und Auswertung der Datenerhebung beschrieben.

### **Argumentative Interpretationsabsicherung**

Das zweite Gütekriterium ist die argumentative Interpretationsabsicherung. Hierbei muss sichergestellt werden, dass Interpretationen schlüssig sind und ein angebrachtes Vorverständnis aufweisen (Mayring, 2016, S. 145). Diese Anforderungen werden im Rahmen des Kapitels 8 abgedeckt.

### **Regelgeleitetheit**

Bei dem dritten Gütekriterium – der Regelgeleitetheit – soll sichergestellt werden, dass die qualitative Forschung systematisch erfolgt (Mayring, 2016, S. 145-146). Um dem Kriterium der

Regelgeleitetheit gerecht zu werden, wurde in dieser Arbeit eine systematische Literaturrecherche durchgeführt, ein Interviewleitfaden konzipiert, die Analyseschritte festgelegt, und die transkribierten Interviews entsprechend eines Ablaufmodells ausgewertet und interpretiert.

### **Nähe zum Gegenstand**

Das vierte Gütekriterium ist die Nähe zum Forschungsgegenstand. In der qualitativen Forschung soll möglichst nahe am Gegenstand geforscht werden und eine Interessensannäherung mit den zu erforschenden Subjekten erzielt werden (Mayring, 2016, S. 146). Mittels der durchgeführten Literaturrecherche und der Befragung von Experten, welche von ihren praktischen Erfahrungen berichten konnten, wurde die Gegenstandsangemessenheit erfüllt.

### **Kommunikative Validierung**

Die kommunikative Validierung stellt das fünfte Gütekriterium dar. Zur Absicherung der Gültigkeit der Ergebnisse sollen diese mit den Beforschten nochmals besprochen werden (Mayring, 2016, S. 147). Um die Gültigkeit der Ergebnisse sicherzustellen, wurden die Antworten der Befragten im Zuge des Interviews zusammengefasst und das korrekte Verständnis der Beantwortungen bestätigt.

### **Triangulation**

Das sechste Gütekriterium bildet die Triangulation. Es soll die Qualität der Forschung durch die Verknüpfung mehrerer Lösungswege sichergestellt werden. Dies kann durch das Heranziehen unterschiedlicher Datenquellen, Theorieansätze, Methoden oder Interpreten erfolgen (Mayring, 2016, S. 147). Im Rahmen dieser Arbeit wurden die Ergebnisse mit der vorhandenen Literatur verglichen, und es wurde bei der Auswahl des Experten darauf geachtet, dass die Experten spezifischen Tätigkeiten in einer Vielzahl von Unternehmen nachgehen. Es wurde besonderes Augenmerk daraufgelegt, dass die Experten aus unterschiedlichen Unternehmen stammen.

## **7.6 Kategoriensystem**

Ein zentrales Element der Inhaltsanalyse ist das Kategoriensystem (Braunecker, 2016, S. 19). Im Zuge der Inhaltsanalyse wird ein Kategoriensystem gebildet, welches die Zielsetzung der Analyse in Form von Kategorien wiedergeben soll. Anhand dieses Kategoriensystems wird der

Untersuchungsgegenstand (z.B. ein Text) ausgewertet. Die Zuordnung des zu untersuchenden Materials in das Kategoriensystem wird als Kodierung bezeichnet (Mayring, 1994, S. 162). Bei der Kategorienbildung kann zwischen der induktiven und der deduktiven Vorgehensweise unterschieden werden. Die deduktive Kategorienbildung ist charakterisiert durch Kategorien, die sich aus der Theorie ableiten und anhand diesen wird das Ausgangsmaterial strukturiert. Hingegen werden bei der induktiven Vorgehensweise Kategorien direkt aus dem Ausgangsmaterial abgeleitet (Mayring, 2022, S. 84). In der Tabelle 2 wird das Kategoriensystem dieser Arbeit dargestellt.

## Kategoriensystem

Hauptkategorie	Subkategorie
<b>Entwicklung von Predictive Analytics im Controlling</b>	
	Entwicklungen der letzten fünf Jahre
	Auswirkungen von Krisen auf die Anwendung und Zuverlässigkeit von Predictive Analytics
	Entwicklungspotenzial in den nächsten 10 Jahren
<b>Potenziale und Tipps für eine Implementierung</b>	
	Predictive Analytics – Potenzial bei Unternehmen im Controlling
	Wird Predictive Analytics im Controlling überbewertet?
	Dos and Don'ts für eine erfolgreiche Implementierung
	Zentrale Einsatzbereiche
<b>Herausforderungen bei der Implementierung</b>	
	Datenproblematik
	Know-how und Skillset der Controller:innen
	Expectation-Management im Zuge der Implementierung
	Predictive Analytics als vermeintliche Bedrohung für Controller:innen
	Sonstige Herausforderungen bei der Implementierung

Tabelle 2. Kategoriensystem. (eigene Darstellung)

Das Kategoriensystem dieser qualitativen Forschung setzt sich aus drei Hauptkategorien zusammen, welche in 12 Subkategorien aufgegliedert werden. Die Kategorienbildung erfolgte induktiv, sodass die Kategorien bei der Analyse der Interviews gebildet wurden. Dabei wurde mit einem Interview begonnen und das gesamte Interview-Transkript wurde auf inhaltstragende

Passagen geprüft. Bei Feststellung einer inhaltstragenden Passage wurde anhand dieser Textpassage eine Kategorie gebildet. Bei der nächsten inhaltstragenden Passage wurde zuerst überprüft, ob diese einer bereits gebildeten Kategorie zuzuordnen ist, oder eine neue gebildet werden muss. Somit wurden die Kategorien laufend erweitert, wenn eine inhaltstragende Passage nicht in eine bereits vorhandene Kategorie aufzunehmen war. Alle neun Experteninterviews wurden auf diese Weise kategorisiert und unterliegen somit demselben Kodierungssystem. In einem ersten Durchgang wurden in etwa 20% des Ausgangsmaterials kodiert und anschließend wurde eine Revision der Kategorien durchgeführt. Es wurde geprüft, ob die Kategorien die zugeordneten Inhalte angemessen widerspiegeln und ob Kategorien zusammengefasst werden können. Da Änderungen an den Kategorien vorgenommen wurden, musste die Analyse nochmals neu gestartet werden mit den angepassten Kategorien.

## **8 Interpretation der Ergebnisse**

In dem nachfolgenden Kapitel werden die Ergebnisse der empirischen Forschung behandelt und interpretiert. Die Aussagen der Interviewpartner werden verglichen und abweichende Sichtweisen werden dargelegt.

### **8.1 Entwicklung von Predictive Analytics im Controlling**

#### **Entwicklungen der letzten fünf Jahre**

Die Experten wurden zu den Entwicklungen der letzten fünf Jahre im Bereich Predictive Analytics im Controlling befragt. Als interessant hat sich hierbei herausgestellt, dass drei der neun Interviewpartner keine aktive Nachfrage nach Predictive Analytics-Lösungen im Finanzbereich am Markt vernehmen konnten (IP06, 2022, Z. 20-24; IP04, 2022, Z. 324-328; IP01, 2022, Z. 55-65). Ein Experte wies darauf hin, dass Predictive Analytics immer noch ein Entwicklungsthema ist und dieses in den vergangenen zwei Jahren nicht mehr präsent am Markt war (IP01, 2022, 55-6). Einer der Gründe hierfür könnten die von einer Vielzahl von Unternehmen derzeit durchgeführten großen ERP-Umstellungen (Großteils SAP S4/HANA) sein. Diese legen Controllingabteilungen teils über Jahre hinweg lahm und blockieren Ressourcen (IP06, 2022, Z. 76-82).

Im Gegensatz dazu konnten von den meisten Experten wesentliche Entwicklungen in diesem Bereich festgestellt werden. Vor fünf Jahren war Predictive Analytics noch ein Randthema. Jetzt kommt das Thema mehr und mehr bei den Unternehmen an. Unternehmen testen Predictive Analytics-Ansätze, bauen Prototypen oder haben bereits automatisiert oder teilautomatisierte Forecasts in Verwendung (IP09, 2022, Z. 206-210). Den vermehrten Einsatz von Predictive Analytics im Controlling konnte auch Interviewpartner 5 feststellen. Viele Unternehmen konnten in den vergangenen fünf Jahren erste Erfahrungen mit Predictive Analytics sammeln. Die Techniken und Tools stehen derzeit bei einer Vielzahl von Unternehmen auf der Agenda (IP05, 2022, Z. 75-85). Es wurde im Rahmen einer Studie vor drei Jahren erhoben, dass nur 4% der Studienteilnehmer:innen Predictive Analytics-Ansätze nutzen. Im Jahr 2022 gaben bereits knapp über 40% der Befragten an Predictive Analytics-Ansätze einzusetzen (IP09, 2022, Z. 187-190). Es handelt sich dabei um eine Verzehnfachung.

Dies hat verschiedene Gründe. Zum einen wurden Predictive Analytics-Lösungen in den letzten fünf Jahren greifbarer und kostengünstiger für Unternehmen. Große Software-Hersteller wie beispielsweise SAP und Microsoft Dynamics bieten bereits integrierte Predictive Analytics-Funktionen an (IP07, 2022, Z. 98-105; IP08, 2022, Z. 96-107). Dadurch konnte die Anzahl an Unternehmen, welche sich mit diesem Thema beschäftigen, wesentlich gesteigert werden. Anfangs waren Predictive Analytics-Tools nur für größere Unternehmen finanzierbar, aber inzwischen sind die Techniken ebenso für mittelständische Unternehmen leistbar (IP05, 2022, Z. 93-101). Zum anderen kann der vermehrte Einsatz auf die Volatilität am Markt zurückgeführt werden. Die Volatilität war schon immer vorhanden und kann nach den Krisen der letzten Jahre nicht mehr geleugnet werden (IP09, 2022, Z. 210-213).

### **Auswirkungen von Krisen auf die Anwendung und Zuverlässigkeit von Predictive Analytics**

Im Zuge der Interviews wurden die Experten befragt, ob die gegenwärtigen Krisen (Covid-19-Krise, Angriffskrieg gegen die Ukraine, Energiekrise, etc.) Auswirkungen auf die Anwendung und die Zuverlässigkeit von Predictive Analytics haben. Es sollte erforscht werden, ob sich in Krisenzeiten Grenzen und Restriktionen von Predictive Analytics im Controlling zeigen, oder ob Predictive Analytics-Ansätze auch in volatilen Zeiten Potenziale bieten.

In derart volatilen Zeiten ist die Zuverlässigkeit der Predictive Analytics-Modelle nicht gegeben (IP01, 2022, Z. 162-170; IP05, 2022, Z. 210-214; IP06, 2022, Z. 178-182; IP07, 2022, Z. 199-200). Es sollte immer berücksichtigt werden, dass Predictive Analytics nur eine Reproduktion der Vergangenheit für die Zukunft ist (IP04, 2022, Z. 13-15). Predictive Analytics-Methoden gleichen einer statistischen Fortschreibung von Zeitreihen, daher können Umbruchwellen, wie beispielsweise die Covid-19-Krise oder der Angriffskrieg auf die Ukraine nicht durch derartige Methoden prognostiziert werden (IP05, 2022, Z. 183-187). Kommt es zu größeren Zeitreihenbrüchen, funktionieren Predictive Analytics-Lösungen kaum mehr (IP07, 2022, Z. 200-206). Die aus der Covid-19-Krise resultierenden Zeitreihenbrüche stellen für Unternehmen eine Herausforderung dar. Denn die Datenhistorie der letzten drei Jahre wurde durch Lockdowns zerstört (IP09, 2022, Z. 241-245). Ein führender Kommunikationsanbieter hat vor der Covid-19-Krise anhand des Telefon- und Streamingverhaltens relativ einfach automatisierte Umsatzforecasts eingesetzt. Doch durch den Ausbruch von Covid-19 wurden diese mehr oder weniger über Nacht unbrauchbar (IP07, 2022, Z. 200-206).

Es ist wichtig, bei großen Trendbrüchen (wie etwa der Covid-19-Krise) die Validität von Predictive Analytics-Modellen zu überprüfen (IP07, 2022, Z. 206-208). In vielen Branchen resultieren aus der Störung der saisonalen Zyklen Planungsschwierigkeiten. Einige Unternehmen planen aus diesem Grund aufbauend auf saisonale Verläufe der Jahre vor Covid-19. Dementsprechend werden beispielsweise für ihre Planung die Ergebnisse aus dem Jahr 2019 herangezogen (IP04, 2022, Z. 269-279).

Interviewpartner 1 führte an, dass man sich vor der Pandemie sehr intensiv mit dem Thema Predictive Analytics auseinandersetzte, sich jedoch in der Krise gezeigt hat, dass Unternehmen andere Prioritäten hatten. Für Unternehmen waren beispielsweise die Liquiditätssicherung sowie kurzfristige Ansätze für Planung und Forecasting wichtiger. In dieser Zeit wurden Predictive Analytics-Ansätze unterpriorisiert (IP01, 2022, Z. 43-54). Diesbezüglich wies ein Experte darauf hin, dass manche Branchen mit Umsatzeinbußen bis zu 90% konfrontiert waren. In diesen Fällen waren Implementierungen von KI-Tools nicht relevant. Der Fokus lag klar auf anderen Themen wie Kosteneinsparprogrammen, usw. (IP06, 2022, Z. 186-194). Weiters wies Interviewpartner 1 darauf hin, dass in Krisenzeiten keine neuen Projekte gestartet und keine neuen Tools implementiert werden. Der Fokus liegt in derartigen Zeiten auf der Krisenbewältigung mit bekannten, einfachen Hilfsmitteln, wie beispielsweise Excel (IP01, 2022, Z. 254-257).

Interviewpartner 7 hingegen erklärte, dass die Umsetzung von Implementierungsprojekten möglicherweise durch die Krisen verzögert wurde. Dies trifft vor allem bei Unternehmen zu, die mit „Firefighting“ beschäftigt waren und den Fokus auf wesentlichere Themen (z.B. die Liquiditätssicherstellung) gerichtet hatten. Dennoch waren dem Experten keine Fälle bekannt, in denen Unternehmen die Implementierungsprojekte aufgrund der Krisen abgesagt hätten (IP07, 2022, Z. 211-217).

Doch der Großteil der befragten Experten war der Ansicht, dass die Krisen Auswirkungen auf die Anwendung von Predictive Analytics im Controlling haben und trotz fehlender Zuverlässigkeit in den Krisenzeiten der Trend zur Anwendung von Predictive Analytics weiterhin steigt (IP02, 2022, Z. 39-40; IP04, 2022, Z. 258-259; IP05, 2022, Z. 215-221; IP07, 2022, Z. 211-217; IP08, 2022, Z. 355-361; IP09, 2022, Z. 247-252). Um trotz der Krise weiterhin für die Steuerung relevante Informationen liefern zu können, müssen diese zeitnah zur Verfügung gestellt werden. Dies wird durch einen erhöhten Automatisierungsgrad ermöglicht (IP09, 2022,

Z. 255-260). Die Dringlichkeit und die Bedeutung von zeitnahen Prognosen, wurde unter anderem durch Covid-19 aufgezeigt (IP08, 2022, Z. 355-361). Während der Covid-19-Krise mussten viele Unternehmen ihre Planungslösungen modernisieren. Denn ihre Ressourcen waren nicht mehr ausreichend, um die ständig ändernden Bedingungen berücksichtigen zu können. Automatisierte Hochrechnungen stellen hierbei einen wichtigen Schlüssel dar. Zum einen sinkt der Aufwand für die Erstellung, somit können Forecasts häufiger erstellt werden und zum anderen, lässt sich durch digitale Forecasts die Qualität verbessern (IP09, 2022, Z. 220-234). Als weiteres Potenzial von auf Predictive Analytics basierenden Hochrechnungen in Krisenzeiten wird die Simulation abweichender Szenarien betrachtet, da diese Möglichkeit vor allem in volatilen Zeiten eine entscheidende Rolle spielt (IP09, 2022, Z. 67-72).

### **Entwicklungspotenzial in den nächsten 10 Jahren**

Die Experten wurden befragt, welche Entwicklungen in den nächsten 10 Jahren im Bereich Predictive Analytics im Controlling zu erwarten sind und welche Entwicklungspotenziale sich abzeichnen. Diese Fragestellung erweist sich als relevant, da hierbei geprüft wurde, ob die bestehenden Grenzen bei der Implementierung einem Durchbruch von Predictive Analytics im Controlling entgegenstehen.

Die Experten gehen davon aus, dass sich in den nächsten 10 Jahren eine Vielzahl an Änderungen in diesem Bereich ergeben werden. Es wird ein Anstieg der Nachfrage nach Predictive Analytics-Lösungen antizipiert (IP01, 2022, Z. 297-300; IP02, 2022, Z. 195-196; IP03, 2022, Z. 319-327; IP04, 2022, Z. 417-422; IP06, 2022, Z. 263-269). Viele Unternehmen stehen bei dem Einsatz von Predictive Analytics-Lösungen noch ganz am Anfang. Für die nächsten Jahre besteht hier erhebliches Potenzial (IP03, 2022, Z. 315-319). Vor allem der Einsatz von Predictive Analytics-Tools im Forecasting und in der Planung sollte gesteigert werden. Denn der Blick in die Zukunft ist wichtiger als der Blick in die Vergangenheit (IP02, 2022, 27-28). Unternehmen sollten daher dem Reporting weniger Bedeutung im Hinblick auf die Unternehmenssteuerung beimessen und sich auf die Planungs- und Forecastingprozesse fokussieren. Interviewpartner 9 betrachtet die Planung als überschätzt und hofft, dass diese in Zukunft deutlich unbedeutender wird, und der Fokus verstärkt auf Forecasts und die Simulation von Szenarien gelegt wird. Nur auf diese Weise kann sichergestellt werden, dass zukünftig zeitnah relevante Informationen geliefert werden (IP09, 2022, Z. 472-475).



Als ein Treiber für die stärkere Priorisierung von Predictive Analytics im Controlling könnte sich der derzeit vorherrschende Ressourcenengpass auf dem Arbeitsmarkt herausstellen (IP01, 2022, Z. 421-423). Man stellt häufig fest, dass den Unternehmen Ressourcen im Controlling fehlen, um die allfälligen Tätigkeiten in entsprechender Qualität zu erfüllen. Eine Automatisierung der Standardprozesse würde Abhilfe verschaffen und die Controller:innen könnten sich den Spezialthemen widmen. Dies spricht sehr stark für den zukünftigen Einsatz von Predictive Analytics im Controlling (IP01, 2022, Z. 257-263).

In den nächsten 10 Jahren wird erwartet, dass sich der Automatisierungs- und Standardisierungsgrad erhöht. Derzeit müssen Unternehmen noch selbst viel programmieren und entwickeln und in Zukunft wird es dafür Branchenlösungen geben (IP02, 2022, Z. 177-180). Die Planungs- und Forecasting-Tools werden künftig mit zusätzlichen Funktionen ausgestattet sein. Somit werden die Predictive Analytics-Lösungen für Unternehmen einfacher zugänglich, sowie in der Anwendung einfacher gestaltet sein. Es werden keine spezialisierten Abteilungen benötigt, um spezielle Modelle zu bauen (IP09, 2022, Z. 475-483). Predictive Analytics könnte dann beispielsweise eine Funktion in Excel oder im ERP-System bilden. Somit wäre die Implementierung für Unternehmen einfacher und statistisches Wissen sowie Programmierkenntnisse der Controller:innen wären dadurch nicht mehr zwingend erforderlich. Predictive Analytics-Ansätze werden sich zu einem Standardprozess entwickeln. Die Funktionen werden in den Tools integriert werden und die Anwendenden würden das Vorgehen voraussichtlich nicht einmal als Predictive Analytics bezeichnen (IP05, 2022, Z. 337-348).

Zukünftig werden mehr und mehr Teilaufgaben durch Softwarelösungen übernommen und automatisiert. Dies bedeutet jedoch nicht, dass die Controllingabteilungen in den „Autopilot“ schalten und die Tätigkeiten zur Gänze automatisiert werden können (IP06; 2022; Z. 279-283). Viel mehr wird es zu einem hybriden Ablauf der Prozesse führen. Systeme und Plattformen werden eingesetzt, um den Menschen zu unterstützen und die menschlichen Fähigkeiten werden an diesen Tätigkeiten anknüpfen (IP08, 2022, Z. 372-377).

Fünf der befragten Experten sind davon überzeugt, dass die Anwendung von Predictive Analytics im Controlling in Zukunft zur Norm werden wird (IP02, 2022, Z. 190-191; IP05, 2022, Z. 362-369; IP06, 2022, Z. 273-276; IP07, 2022, Z. 105-107; IP09, 2022, Z. 490-493). Es wird der Zeitpunkt kommen, zu dem man argumentieren muss, warum man beispielsweise eine Sales-Planung manuell erstellt und die Ressourcen der Salesverantwortlichen damit beansprucht,

wenn die Daten bereits im CRM-System vorhanden sind und aus dem System hochgerechnet werden könnten (IP09, 2022, Z. 493-497). Ein Experte erwartet, dass die Anwendung von Predictive Analytics im Controlling lediglich in jenen Branchen und Bereichen zur Norm wird, in denen der Einsatz sinnvoll ist und eine Vielzahl an Vorteilen mit sich bringt (IP08, 2022, Z. 399-401). Im Gegensatz dazu geht Interviewpartner 4 davon aus, dass Predictive Analytics im Controlling in den nächsten 10 Jahren nicht zur Norm werden. Es gibt seiner Ansicht nach viele dringendere, grundlegendere Problemfelder (z.B. integrierte Planung), welche Unternehmen priorisieren werden (IP04, 2022, Z. 432-435).

## **8.2 Potenziale und Tipps für eine Implementierung von Predictive Analytics**

Im Folgenden wurden die Experten befragt, welche Potenziale und Grenzen sie bei der Implementierung von Predictive Analytics im Controlling sehen und ob es sich um einen bloß vorübergehenden „Hype“ handelt. Darüber hinaus wurden Ratschläge für eine erfolgreiche Implementierung erteilt und die in der Praxis relevanten Einsatzbereiche erläutert.

### **Predictive Analytics – Potenzial bei Unternehmen im Controlling**

Wie bereits in Kapitel 3 erläutert, bieten Predictive Analytics zahlreiche Möglichkeiten zur Unterstützung bei Controllingprozessen. Es stellt sich jedoch hierbei die Frage, bei welchen Unternehmen Potenziale gesehen werden, ob diese in Zusammenhang mit der Unternehmensgröße oder der zugehörigen Branche stehen und welchen Unternehmen von einer Implementierung abzuraten ist.

Interviewpartner 2 betrachtet die Implementierung von Predictive Analytics im Controlling in allen Branchen als relevant. Jedoch gibt es sehr wohl Unterschiede bei den jeweiligen Branchen. Es wird auch bei der Implementierung von Predictive Analytics Vorreiter geben. Bei dem Thema Digitalisierung hat beispielsweise die Telekommunikationsbranche in den letzten 20-30 Jahren diese Rolle übernommen (IP02, 2022, Z. 49-58). Es sollte jedoch immer das Kosten-Nutzen-Verhältnis betrachtet werden. Bei gewissen Unternehmen wäre der Nutzen einer Implementierung nicht ausreichend, um die Implementierungskosten zu rechtfertigen, z.B. ein Unternehmen, welches pro Jahr eine Anlage im Wert von zehn Million Euro verkauft, wird nicht den Bedarf sehen, Predictive Analytics im Vertriebscontrolling zu implementieren. Hier ist kein Potenzial vorhanden und ein großes Implementierungsprojekt für diesen konkreten Fall würde sich nicht rentieren (IP08, 2022, Z. 147-161). Ebenso argumentierte Interviewpartner 6, dass

die Geschäftsmodelle der Unternehmen z.B. Forecasts auf Basis der vorhandenen Daten erlauben müssen (IP06, 2022, Z. 58-59).

In Branchen, in denen täglich eine Vielzahl an Transaktionen erfolgen, wird ein großes Potenzial für Predictive Analytics gesehen. In jenen Branchen können Predictive Analytics-Lösungen sinnvoller angewandt werden und einen größeren Nutzen stiften (IP08, 2022, Z. 161-166). Bei einem Unternehmen wie Microsoft bietet sich beispielsweise die Anwendung von Predictive Analytics-Tools an. Die große Anzahl an MS-Office Subscriptions stellen viele Transaktionen dar, und diese lassen sich sehr gut vorhersagen. Denn in der Regel können Kund:innen nicht auf ihre Office-Pakete verzichten und nutzen diese weiter (IP06, 2022, Z. 65-68; IP06, 2022, Z. 199-206). Bei Unternehmen, welchen Massendaten oder Kundendaten zur Verfügung stehen, zeichnet sich bereits ein Vorsprung bei dem Thema Predictive Analytics ab (IP02, 2022, Z. 58-59). In der Praxis nutzen Industrieunternehmen Predictive Analytics-Lösungen sehr gerne im Controlling (IP09, 2022, Z. 142-143). Dies könnte darauf zurückzuführen sein, dass derartige Tools ebenfalls in anderen Bereichen eingesetzt werden und sich hieraus Synergieeffekte ergeben. In diesem Zusammenhang führte Interviewpartner 1 an, dass Unternehmen, die ihre Finanzplanung mit der operativen Planung verknüpft haben, mehr Interesse an Predictive Analytics-Lösungen zeigen (IP01, 2022, Z. 123-130).

Die Implementierung von Predictive Analytics lohnt sich für Unternehmen unabhängig von der Unternehmensgröße. Die Methoden sind für kleinere und mittelständische Unternehmen ebenso von Bedeutung. Jedoch fehlt bei kleineren Unternehmen häufig das erforderliche Budget für Implementierungsprojekte. Gerade in den derzeitigen Krisen, z.B. bei den steigenden Energiekosten wird oftmals das Budget für solche Vorhaben gekürzt (IP02, 2022, Z. 64-69). Tendenziell werden größere Unternehmen einfacher die anfallenden Kosten eines Implementierungsprojektes in Kauf nehmen, beispielsweise als Unterstützung für die Wechselkursplanung im Rahmen der Konzernplanung (IP04, 2022, Z. 91-98). Es besteht mehr Effizienzsteigerungspotenzial bei größeren Unternehmen. Allerdings können auch im Mittelstand und bei Kleinstunternehmen Effizienzsteigerungen durch Predictive Analytics-Lösungen erzielt werden (IP05, 2022, Z. 43-44).

Für Unternehmen mit kleinen BI-Budgets sind die hohen Implementierungskosten eine Hemmschwelle. Diese Unternehmen würden stark von Standardlösungen bzw. Branchenlösungen pro-

fitieren, welche mit geringeren Implementierungskosten verbunden und somit einfacher zugänglich wären (IP02, 2022, Z. 205-208). Laut Interviewpartner 7 werden zukünftig die Kosten für eine Implementierung nicht im Vordergrund stehen. Denn in Zukunft werden am Markt auch kostengünstige Lösungen angeboten werden. Die ausschlaggebenden Faktoren dafür, ob sich eine Implementierung für Unternehmen lohnt, sind das erforderliche Know-how und die personelle Ressourcenausstattung (IP07, 2022, Z. 69-73). Dementsprechend kommt größeren Unternehmen ein Vorteil zu, da diesen zum einen mehr Ressourcen zur Verfügung stehen und zum anderen ergeben sich hier mehr Anwendungsfälle (IP09, 2022, Z. 136-139). Große Unternehmen sind häufig besser ausgestattet in Bezug auf vorhandenes Know-how, Datenstruktur, Prozesse, etc. Viele DAX-Unternehmen nutzen bereits KI-basierte maschinelle Forecasts parallel zu den manuellen Forecasts (IP07, 2022, Z. 86-92). Die hierfür erforderlichen personellen Ressourcen sind für kleinere Unternehmen schwieriger aufzubringen. Daraus lässt sich ableiten, dass es Unternehmensmindestgrößen gibt, ab denen sich Investitionen in Predictive Analytics lohnen. Erst ab diesem Punkt ist das erforderliche Know-how vorhanden und eine Implementierung lohnt sich (IP07, 2022, Z. 68-69).

Vor allem bei Unternehmen mit großen Datenmengen werden Potenziale für Predictive Analytics im Controlling gesehen (IP06, 2022, Z. 54-55). Weiters ist eine Implementierung von Predictive Analytics nur empfehlenswert, wenn die erforderlichen Datenmengen verfügbar sind und diese auch sinnvoll durch KI-Systeme interpretiert werden können (IP03, 2022, Z. 63-67). Unternehmen denen die erforderlichen Daten nicht oder nicht in entsprechender Qualität zur Verfügung stehen, sollte vorerst von einer Implementierung abgeraten werden (IP05, 2022, Z. 303-306; IP08, 2022, Z. 168-174; IP09, 2022, Z. 156-160). Dies wäre z.B. der Fall, wenn nur Daten über sehr kurze Zeitreihen hinweg vorliegen. Die Daten würden zu unzuverlässigen und schlechten Ergebnissen führen (IP05, 2022, Z. 303-306).

Interviewpartner 4 weist darauf hin, dass es teilweise schwierig ist, Unternehmen von einer Predictive Analytics-Implementierung zu überzeugen, da eine gewisse Ergebnisoffenheit herrscht. Viele Unternehmen scheuen vor der Finanzierung ergebnisoffener Projekte zurück. Aus diesem Grund werden in Deutschland Förderungen angeboten, die Investitionen in Predictive Analytics-Implementierungsprojekte incentivieren. Dies stellt für Unternehmen einen Anreiz dar, da ein Teil der Kosten für das Projekt übernommen wird (IP04, 2022, 80-85).

## **Wird Predictive Analytics im Controlling überbewertet?**

Im Zuge der Interviews wurden jedoch nicht nur die Potenziale bei der Implementierung von Predictive Analytics im Controlling aufgezeigt. Einige Experten äußerten ebenso ihre Bedenken und brachten ihre teilweise Skepsis zum Ausdruck.

Es wurde angemerkt, dass im Allgemeinen Predictive Analytics-Lösungen in anderen Unternehmensbereichen weiterverbreitet sind, z.B. in der Produktion, wo durchaus sehr repetitive Prozesse zu finden sind. Bei solchen Prozessen gibt es ein sehr limitiertes Anwendungsfeld und nur eine gewisse Anzahl an Einflussfaktoren und hierfür eignen sich derartige Techniken besonders gut (IP07, 2022, Z. 132-137). Weiters sieht einer der Experten keinen Markt für Implementierungen von Predictive Analytics im Controlling. In anderen Unternehmensbereichen wie beispielsweise im Marketing oder in der Produktion zeigt sich größeres Potenzial (IP04, 2022, Z. 64-67).

Einer der befragten Experten hat den Eindruck, dass 60-70% der Unternehmen im Controlling noch nicht bereit sind, um sich mit einer Implementierung zu beschäftigen. Predictive Analytics ist doch noch ein sehr fortgeschrittenes Thema und die meisten Unternehmen stehen noch vor viel essenzielleren Problemen. Unternehmen stehen vor vielen operativen Herausforderungen, z.B. vor der Frage, zu welchen Preisen die Produkte angeboten und welche Kosten einkalkuliert werden müssen, wenn die Rohstoffpreise derart hohen Schwankungen ausgesetzt sind. Solche Unternehmen sollten ihren Fokus im Controlling auf diese essenziellen Themen lenken (IP04, 2022, Z. 103-111). Im Einklang damit argumentierte ein weiterer Experte, dass Unternehmen ihre Ressourcen nicht für Implementierungsprojekte neuer Technologien einsetzen, sondern sich auf unmittelbar drängende Geschäftsprobleme im Controlling fokussieren sollten (IP06, 2022, Z. 235-240).

In den Interviews wurde die Frage aufgeworfen, ob durch die Implementierung von Predictive Analytics tatsächlich ein Mehrwert im Controlling geschaffen werden kann. Der Anwendbarkeit von algorithmenbasierten Methoden im betriebswirtschaftlichen Umfeld sind laut Interviewpartner 4 Grenzen gesetzt. Dies liegt jedoch in vielen Fällen nicht am fehlenden Know-how, sondern viel mehr daran, dass Predictive Analytics-Ansätze für viele Fragestellungen in diesem Kontext nicht geeignet sind. Die Projektion der Vergangenheit in die Zukunft ist nicht

für alle Fragestellungen eine geeignete Methode (IP04, 2022, Z. 40-44). Möchte man beispielsweise Predictive Analytics-Lösungen nutzen, um den Aktienkurs vorherzusagen, sind unzählige Faktoren zu berücksichtigen und die Tools würden daran scheitern (IP07, 2022, Z. 137-140). Hingegen wäre Predictive Analytics für Fragestellungen, wie z.B. wie stark werden die Lohnkosten unter Berücksichtigung der gegebenen Konjunktur steigen, geeignet (IP04, 2022, Z. 15-20).

Ein Experte führte an, dass bei vielen Projekten die Erfahrung gemacht wurde, dass am Ende des Projekts kein unternehmerischer Mehrwert erzielt werden konnte – es kam nichts Verwertbares bei dem Projekt heraus (IP04, 2022, Z. 48-51). Diesbezüglich argumentierte ein weiterer Experte, dass Predictive Analytics zwar ein Zukunftsthema ist, jedoch aber überbewertet wird. Anbieter nutzen den „Hype“ rund um dieses Thema, um ihre Lösungen zu vermarkten, obwohl sich diese oftmals nicht ausreichend am Nutzen der Anwender:innen orientieren (IP06, 2022, Z. 91-94). Hier ist beispielsweise an ein Unternehmen zu denken, das ein großes Predictive Analytics-Projekt startet, welches um die 40.000-50.000 EUR kostet, beispielsweise um Tarif-erhöhungen zu prognostizieren. Wenn das Ergebnis der Predictive Analytics-Modelle 4,8% ist und im Rahmen der manuell erstellten Prognose eine Erhöhung von 4,6% geschätzt wird, stellt sich die Frage, ob durch die Implementierung ein Mehrwert geschaffen werden konnte (IP04, 2022, Z. 148-151). Im Budgetierungsprozess kommt es oftmals vor, dass Vertriebsmitarbeitende Produkte und Regionen, die unter ihren Zuständigkeitsbereich fallen, selbstständig planen. Daher ist häufig keine automatisierte Lösung erforderlich, um die Kosten auf Kostenstellenebene zu planen (IP06, 2022, Z. 46-51).

### **Dos and Don'ts für eine erfolgreiche Implementierung**

Die Interviewpartner wurden nach Dos and Don'ts bei einer Implementierung von Predictive Analytics im Controlling befragt.

Vor einer Implementierung ist dringend anzuraten, die Ausgangssituation ausführlich zu erheben (IP01, 2022, Z. 202-205; IP02, 2022, Z. 117-120; IP06, 2022, Z. 216-222; IP07, 2022, Z. 147-153; IP08, 2022, Z. 315-318). Zu Beginn wird die Abhaltung eines Discovery-Workshops empfohlen, um intern abzuklären, worauf man aufbauen kann, was man beachten muss, etc. (IP08, 2022, Z. 315-318). Um eine möglichst effiziente Implementierung gewährleisten zu können, sollte man schon vorab eine Idee haben, was man mit den Predictive Analytics-Methoden

erreichen möchte (IP05, 2022, Z. 156-159). Zudem sollte erhoben werden, welche Quellsysteme zur Verfügung stehen und wo die Verantwortlichkeit für die Datenhaltung liegt (IP01, 2022, Z. 202-205).

Vor der Implementierung wird empfohlen, die Datenverfügbarkeit und die Datenqualität zu prüfen und sicherzustellen (IP05, 2022, Z. 137-140; IP06, 2022, Z. 213-216, IP09, 2022, Z. 438-446). Es sollte berücksichtigt werden, dass die Altdaten eines Unternehmens, vor allem wenn diese möglicherweise nur in begrenztem Umfang vorhanden sind, keine ausreichende Datengrundlage für die Implementierung von Predictive Analytics darstellen. Es wäre in jedem Fall ratsam, externe Faktoren – wie geopolitische Informationen oder Daten über die Konkurrenz – in die Datenbasis mitaufzunehmen (IP03, 2022, Z. 145-156; IP09, 2022, Z. 286-288). Ein weiterer Tipp ist, dass in den meisten Unternehmen jene Daten, die für das Reporting genutzt werden, die wertvollsten Daten sind. Denn hier wird sehr genau auf die Datenqualität geachtet. Basierend darauf sollte ein Anwendungsfall überlegt werden (IP09, 2022, Z. 279-280).

Entscheidend ist, vor einer Umsetzung eine ganz klare Zielsetzung zu definieren (IP02, 2022, Z. 87-88; IP07, 2022, Z. 128-132; IP09, 2022, Z. 306-307). Predictive Analytics-Tools funktionieren bei ausgewählten Problemstellungen, welche sich auf ein kleines Segment beziehen, wesentlich besser (IP07, 2022, Z. 128-132). Aus diesem Grund ist es essenziell, sich vor der Implementierung intensiv mit den Problemfeldern auseinander zu setzen und die Aufgabenstellung eindeutig zu formulieren. Sowohl bei internen als auch bei externen Projekten mit Beratern ist es wichtig, die Ziele klar zu definieren als auch zu kommunizieren. Die Zielsetzung sowie der Nutzen muss allen Projektbeteiligten deutlich gemacht werden (IP02, 2022, Z. 130-136). Es ist wichtig, bei einer Implementierung die Stakeholder von Beginn an in das Projekt zu involvieren und ihnen die Potenziale aufzuzeigen. Das Team soll die Implementierung von Predictive-Analytics-Tools als eine Chance zur Arbeitserleichterung wahrnehmen. Somit können die Herausforderungen möglichst früh in Angriff genommen werden (IP01, 2022, Z. 186-193; IP08, 2022, Z. 288-292).

Jedoch ist die frühzeitige Involvierung durchaus nicht nur für die Bindung der Mitarbeitenden an das Projekt wesentlich. Ebenso ist das Know-how der Mitarbeitenden für das Projekt von Bedeutung. Hierbei ist es wichtig zu beachten, dass Implementierungsprojekte nicht gänzlich ausgelagert werden können. Eine erfolgreiche Implementierung kann nicht durchgeführt werden,

wenn ein Unternehmen nur die Produktionsdaten an externe Anbieter zur Verfügung stellt. Vor allem bei Implementierungsprojekten mit externen Anbietern sind jene Mitarbeiter:innen, die ein sehr gutes Wissen über die Prozesse besitzen, äußerst wertvoll für das Projekt und müssen eingebunden werden. Externe Anbieter die nicht mit den Prozessen des Unternehmens, den hergestellten Produkten, den verwendeten Maschinen, etc. vertraut sind, können alleine – ohne das Mitwirken des Unternehmens – kein Implementierungsprojekt durchführen (IP09, 2022, Z. 176-184).

Empfehlenswert ist ebenso die Bestimmung eines konkreten Use Cases, bei welchen mit überschaubarem Ressourceneinsatz realistische Ergebnisse zu erwarten sind (IP01, 2022, Z. 209-213; IP05, 2022, Z. 147-151). Durch Use Cases kann Akzeptanz geschaffen und das Vertrauen der Mitarbeitenden in Predictive Analytics-Tools gestärkt werden. Weiters rät einer der Experten, manuelle Forecasts parallel zu den digitalen Forecasts zu erstellen, um der Skepsis gegenüber den Modellen entgegenzuwirken (IP09, 2022, Z. 173-175).

Unternehmen wird geraten, bereits vor der Umsetzung der Predictive Analytics-Lösungen abzuklären, wo diese im Unternehmen verankert werden sollen, d.h. welche Abteilungen die Verantwortlichkeiten nach der Implementierung übernehmen (IP05, 2022, Z. 142-146). Es besteht die Möglichkeit, Predictive Analytics-Implementierungsprojekte direkt auf CFO-Ebene anzusiedeln. CFOs verfügen über den Weitblick und können anhand konkreter Use Cases die Einsatzmöglichkeiten austesten (IP01, 2022, Z. 407-414). Die Etablierung von Ansprechpartner:innen oder eines selbstständigen Kompetenzcenters für BI-Themen im Unternehmen birgt jedoch noch größere Vorteile (IP02, 2022, Z. 163-167; IP05, 2022, Z. 261-269). Dadurch werden Implementierungen zentral gesteuert und die einzelnen Fachbereiche tragen nicht selbständig die Verantwortung hierfür. Durch die Schaffung eines BI-Kompetenzcenters könnten einheitliche Methoden und Umsetzungsvorgehensweisen sichergestellt werden. Auf diese Weise würden Insellösungen der jeweiligen Fachbereiche vermieden und ein einheitliches Gesamtkonstrukt geschaffen werden (IP02, 2022, Z. 163-170).

Ein weiterer Schlüsselfaktor für eine erfolgreiche Implementierung ist eine strukturierte Vorgehensweise (IP02, 2022, Z. 120-121). Diesbezüglich gibt es bereits standardisierte Vorgehensmodelle für Implementierungsprojekte (IP07, 2022, Z. 162-163). Darüber hinaus ist es empfehlenswert, mit einfachen Predictive Analytics-Modellen zu starten (IP07, 2022, Z. 230-234; IP08, 2022, Z. 276-279). Wichtig ist eine schrittweise Annäherung an das Thema. In einem



ersten Schritt könnte man beispielsweise unterstützende Tools bei der Forderungsentwicklung für die Finanzplanung einsetzen. Dies könnte einfacher abgewickelt werden, als eine Automatisierung der gesamten Cashflow-Planung und ist für den Einstieg in Predictive Analytics daher besser geeignet (IP07, 2022, Z. 230-234). Daran anknüpfend gab einer der Experten den Tipp, dass es bereits viele Modelle gibt und es nicht erforderlich ist, immer alles neu zu erfinden. Es ist nur erforderlich, das passende Modell für das Unternehmen und den konkreten Use Case zu finden und die richtige Anwendung zu kennen (IP08, 2022, Z. 293-302). Bei der Auswahl eines geeigneten Modells ist entscheidend, dass sich das Modell an den Zielen und den bestehenden Prozessen orientiert. Viele Unternehmen führen Tools ein, ohne zu wissen, welchen Mehrwert diese dem Unternehmen schaffen und ob sie für die Prozesse geeignet sind (IP02, 2022, Z. 92-94). Einer der Experten empfiehlt, sich immer für jene Anbieter und Tools zu entscheiden, die am geeignetsten für das Team sind, d.h. mit denen sich das Team wohlfühlt und die Controllingprozesse verstanden werden (IP06, 2022, Z. 258-260).

### **Zentrale Einsatzbereiche**

Nachfolgend werden jene Einsatzbereiche behandelt, die sich in der Praxis als relevant erweisen. Weiters berichteten die Experten von den Anwendungsmöglichkeiten, welche sich durch Predictive Analytics im Controlling ergeben.

Der größte Anwendungsbereich ist das Forecasting (IP05, 2022, Z. 16-24; IP07, 2022, Z. 48-50; IP09, 2022, Z. 30-31). Es können z.B. Absatzzahlen für einzelne Produkte oder das EBIT einer Tochtergesellschaft prognostiziert werden (IP05, 2022, Z. 16-24). Eine klassische Variante für das Forecasting wäre die Zeitreihen-Hochrechnung (IP09, 2022, Z. 30-31). Dem Controlling obliegt die Aufgabe, die Budgetwerte, welche häufig von anderen Abteilungen vorgeschlagen werden, zu challengen. Hierfür bieten sich Predictive Analytics-Lösungen beispielsweise für das Sales Forecasting an (IP01, 2022, Z. 75-81). Ein Experte merkte an, dass sich Bereiche wie das Vertriebscontrolling sehr gut für Predictive Analytics anbieten, da die intern verfügbaren Daten im Vertriebscontrolling eine geeignete Basis für Prognosen darstellen (IP03, 2022, Z. 121-127). Bei dem Forecasting wird ebenso viel Potenzial in der Cashflow-Prediction mittels Predictive Analytics-Ansätze gesehen. Jedoch besteht laut Interviewpartner 1 bei den Kund:innen bisher kein Interesse, an solchen algorithmenbasierten Lösungen für die Cashflow Vorhersage (IP01, 2022, Z. 88-90).

Eine weitere Möglichkeit besteht darin, anhand der Hochrechnungen Simulationen für die Zukunft zu erstellen. Denn den Unternehmen ist bewusst, dass in einem schnell ändernden Marktumfeld Planungswerte nicht eintreten können. Daher ist es sinnvoll, sich mit unterschiedlichen Szenarien für die Zukunft zu befassen (IP09, 2022, Z. 67-77). Zudem ist die Anomalie-Erkennung ein vielversprechender Einsatzbereich von Predictive Analytics im Controlling. Durch Algorithmen wird eine schnelle Identifizierung von Ausreißern ermöglicht (IP01, 2022, Z. 70-73).

Mithilfe von Predictive Analytics können Bandbreiten vorgegeben werden. Diese Bandbreiten können zum Abgleich mit den Planungsergebnisse der manuellen Planung herangezogen werden. Bei den Bandbreiten prüft das Predictive Analytics-Tool die Ist-Werte der vergangenen drei bis vier Jahre und hinterlegt diese Werte als Bandbreite. Es wird festgelegt, dass der neue Planungswert innerhalb dieser Bandbreite liegen sollte (IP09, 2022, Z. 33-39).

Für Unternehmen bestehen unterschiedliche Möglichkeiten die Predictive Analytics-Prognosewerte zu nutzen. Unternehmen setzen unter anderem Predictive Analytics-Prognosewerte als Vorgabewerte für die Planer:innen ein. Somit muss bei der Planung nicht bei Null gestartet werden, sondern die Werte sind schon vorgegeben und es wird mit einer einheitlichen Prämisse ins Rennen gegangen. Die Prognosewerte können jedoch manuell überplant werden (IP09, 2022, Z. 43-49). Andere Unternehmen verwenden den automatisierten Forecast und überprüfen diesen lediglich, um somit Arbeitszeit freizusetzen (IP07, 2022, Z. 178-180).

In der Praxis gibt es Fälle, bei denen das Controlling die automatisierte Planung mit den jeweiligen Bereichsverantwortlichen bespricht und diese zu den bedeutenden Werten noch Anmerkungen machen und gegebenenfalls Anpassungen vornehmen (IP09, 2022, Z. 55-67).

Eine interessante Herangehensweise verfolgt das Unternehmen SAP. SAP erstellt permanent zusätzlich zu dem manuellen Forecast einen automatisierten Forecast. Weicht der manuelle zu sehr von dem digitalen Forecast ab, müssen die Controller:innen argumentieren, warum der manuelle Forecast stimmt und worauf sich die Unterschiede zurückführen lassen. Der automatisierte Forecast dient somit als objektive zweite Meinung (IP07, 2022, Z. 167-172). Diesbezüglich führte ein Experte an, dass eine Vertriebsplanung in der Regel auf dem Wissenstand der Vertriebsmitarbeitende über Kunden, Produkte und Märkte basiert. Bei einer automatisierten Planung werden andere Einflussfaktoren, wie z.B. die demografische Entwicklung

berücksichtigt (IP06, 2022, Z. 116-121). Daher bietet sich die Nutzung der Predictive Analytics-Prognosewerte als unabhängige zweite Meinung an, um die Objektivität zu erhöhen.

Unternehmen nutzen Predictive Analytics um ihren Planungsaufwand zu reduzieren und die diesbezüglichen Ergebnisse überzeugen. Die Planungsverantwortlichen können die eingesparte Zeit sinnvoller nutzen und sich auf einzelne, wichtige Planungsgrößen fokussieren (IP09, 2022, Z. 49-55). Controller:innen können nach wie vor Forecasts anpassen und verfügen über die Entscheidungsgewalt. Die automatisierten Forecasts unterstützen lediglich und führen zu einer Verbesserung der Qualität und Objektivität (IP07, 2022, Z. 172-176). Die Effizienzsteigerung und die Erhöhung der Planungsgenauigkeit sind die Haupthebel bei der Anwendung von Predictive Analytics (IP05, 2022, Z. 32-40). In der Praxis haben Projekte bereits gezeigt, dass digitale Forecasts die Planungsgenauigkeit manueller Forecasts aufweisen und oftmals sogar übertreffen (IP05, 2022, Z. 62-64).

### **8.3 Herausforderungen bei der Implementierung von Predictive Analytics im Controlling**

Im Rahmen der Interviews wurden die Experten befragt, welche Herausforderungen sich bei der Implementierung von Predictive Analytics im Controlling stellen. Den Erfahrungen der Experten entsprechend, erweisen sich die Datenproblematik, das fehlende Know-how, die zu hohe Erwartungshaltung und die Befürchtung der Controller:innen, durch Predictive Analytics ersetzt zu werden, als die großen Hürden, die es bei der Implementierung zu bewältigen gilt.

#### **Datenproblematik**

Die größte Herausforderung bei der Implementierung von Predictive Analytics stellen die Daten dar (IP01, 2022, Z. 152-154; IP03, 2022, Z. 208-210; IP05, 2022, Z. 104-108; IP07, 2022, Z. 112-113; IP09, 2022, Z. 390). Im Zusammenhang mit den Daten treten diverse Problematiken auf. Eine Problematik, welcher man sich von Beginn an bewusst sein sollte, ist dass die vorhandene Datenbasis geeignet sein muss, um die Fragestellung zu beantworten. Es müssen Zusammenhänge zwischen den Daten und der Fragestellung festgestellt werden (IP04, 2022, Z. 217-219; IP09, 2022, Z. 283-286). Darüber hinaus hat sich in der Vergangenheit gezeigt, dass die Datenlage bei Predictive Analytics-Projekten im Controlling häufig nicht ausreichend ist. Denn die reinen Finanzzahlen bilden nicht die erforderliche Basis, die Finanzzahlen müssen mit operativen Daten kombiniert werden (IP01, 2022, Z. 81-88).

Die Datenproblematik auf welche man bei Finanzdaten trifft, besteht darin, dass diese meist nur in monatlichen Intervallen vorliegen und nicht auf täglicher Basis, wie dies in anderen Bereichen der Fall ist (IP01, 2022, Z. 370-373). Als Basis für eine Hochrechnung wird eine ausreichend lang zurückreichende Datenhistorie benötigt. Bei Planungen auf Monatsebene benötigt man in etwa Daten über einen Zeitraum von zwei bis vier Jahren. Jedoch variiert die erforderliche Datenhistorie abhängig von dem konkreten Anwendungsfall. In manchen Fällen benötigt man einen längeren Historienhorizont der Daten, beispielsweise wenn lange Saisonalitäten erforderlich sind (IP09, 2022, Z. 148-156). Oftmals liegen z.B. im Budgetierungsprozess nicht jene großen Datenmengen vor, welche für die Anwendung von Predictive Analytics-Lösungen erforderlich sind (IP06, 2022, Z. 42-45). Beispielsweise wenn die Sales-Planung hochgerechnet werden soll, müssen ebenso ausreichend Informationen über Kund:innen zur Verfügung stehen (IP09, 2022, Z. 361-368).

Die Datenbeschaffung ist eine zentrale Herausforderung bei der Implementierung von Predictive Analytics im Controlling (IP03, 2022, Z. 160-169). Oftmals ist es schwierig im Finanzbereich Predictive Analytics-Ansätze zu integrieren, wenn nur Altdaten des Unternehmens zur Verfügung stehen und keine zusätzlichen Informationen über den Wettbewerb oder sonstige Daten über die Marktentwicklungen bereitstehen (IP03, 2022, Z. 73-85). Die Miteinbeziehung externer Daten ist äußerst relevant bei Predictive Analytics-Ansätzen (IP02, 2022, Z. 28-35). Jedoch erweist sich die Beschaffung externer Daten, beispielsweise über Mitbewerber:innen und Kund:innen, häufig als problematisch, da diese Informationen nicht in der erforderlichen Dichte beschafft werden können (IP03, 2022, Z.160-169). Zudem sollte beachtet werden, dass nicht nur die vergangenheitsbezogenen Informationen die Zukunft treiben. Daher müssen auch Informationen über zukünftige Ereignisse – bei der zuvor erwähnten Sales-Planung wären das etwa zukünftige Abnahmeverträge –in die automatisierte Planung miteinfließen (IP09, 2022, Z. 368-375). Darüber hinaus sollte die Bedeutung nichtfinanzieller Daten für das Controlling nicht unterschätzt werden (IP07, 2022, Z. 257-258).

Zu den Herausforderungen im Zusammenhang mit den Daten zählt unter anderem die Data Silo-Problematik. Wertvolle Unternehmensdaten sind in unterschiedlichen Unternehmensbereichen und Systemen angesiedelt. Diese zu analysieren stellt in der Praxis häufig ein Problem dar. Für die Prognose einer Kundenabwanderung, also z.B. wie viele Kunden das Unternehmen im nächsten Quartal verlieren wird, werden teilweise Informationen aus unterschiedlichen Sys-

temen wie dem ERP- und Quality-System benötigt (IP08, 2022, Z. 193-203). Eine weitere Problematik bei den Daten ist, dass bereits vorab bewertet wird, welche Daten relevant sein könnten und nur jene Daten in den späteren Prozessen berücksichtigt werden. So können unerwartete Zusammenhänge oftmals nicht festgestellt werden, weil die Datengrundlage dafür nicht zur Verfügung gestellt wird (IP03, 2022, Z. 171-177). Hierbei spielt die Data Silo-Problematik ebenfalls eine entscheidende Rolle. Denn aus unterschiedlichen Systemen stammende Daten erschweren die Bewertung der Zusammenhänge zwischen den Daten und der Fragestellung.

Für eine Implementierung ist nicht nur eine große Datenverfügbarkeit erforderlich, sondern es ist ebenso wichtig, dass die Daten strukturiert und bereinigt wurden (IP06, 2022, Z. 55-58). Die Datenbesorgung und Datenaufbereitung stellt häufig eine große Herausforderung für Unternehmen dar, und verursacht in etwa 80% des Gesamtaufwandes eines Predictive Analytics-Projekts (IP05, 2022, Z. 104-108). Oftmals wird der Implementierungsaufwand stark unterschätzt. So kam es beispielsweise bei einem bekannten Automobilhersteller zu massiven Projektverzögerungen, da bereits der Prozess der Datenbereinigung ein Jahr lang gedauert hat (IP07, 2022, Z. 185-191).

Die Datenqualität ist für die meisten Unternehmen die größte Herausforderung (IP07, 2022, Z. 112-113). Je besser die Datenqualität ist, desto besser werden die daraus resultierenden Prognosen (IP06, 2022, Z. 175-177). Doch oftmals bemerkt man erst die unzulängliche Qualität der Daten, wenn man diese nutzt (IP09, 2022, Z. 165-169). Die Datenqualität wird in der Regel völlig überschätzt. Fast alle Kunden sind der Meinung, dass die Datenqualität gut ist und bei einem genaueren Blick darauf stellt man fest, dass dies meistens nicht der Fall ist. Es wird sowohl die Datenqualität überschätzt als auch der Datenbereinigungsaufwand, der durch die unzureichende Datenqualität zwingend erforderlich ist, unterschätzt (IP09, 2022, Z. 398-403).

Darüber hinaus stellte ein Experte fest, dass Schwierigkeiten bei der Koordination der Zugriffsrechte, Datenpflege und Datenverantwortlichkeiten mit anderen Bereichen auftreten. Jedoch ist dies meist abhängig davon welche Daten benötigt werden und welche Abteilungen involviert sind (IP05, 2022, Z. 280-289). Nur ein Experte erkennt bei der technischen Implementierung kein Risiko. Da sich die technischen Themen gut managen lassen, beispielsweise die Datenmenge, stellt dies aus der Perspektive des Experten heutzutage keine Herausforderung mehr dar (IP02, 2022, Z. 103-105).

## **Know-how und Skillset der Controller:innen**

Die zweite große Herausforderung, auf die Unternehmen bei der Implementierung von Predictive Analytics stoßen, ist das fehlende Know-how (IP01, 2022, Z. 171-174; IP07, 2022, Z. 113-117; IP08, 2022, Z. 182-185; IP09, 2022, Z. 288-289). Bedarf an Predictive Analytics-Lösungen kann nicht identifiziert werden, wenn kein Wissen über die Anwendungsmöglichkeiten vorhanden ist. Vor allem im Finanzbereich besteht hier Aufholbedarf (IP01, 2022, Z. 193-198). Controller:innen stellen sich insofern als Hemmnis heraus, weil unter anderem oftmals das notwendige Verständnis für Predictive Analytics-Methoden fehlt, die Möglichkeiten nicht bekannt sind und keine konkreten Use Cases ausgearbeitet werden (IP08, 2022, Z. 185-188). Unklare Use Cases führen häufig zu einer Abneigung von Predictive Analytics-Lösungen (IP06, 2022, Z. 36-37).

Der Einstieg in das Thema Predictive Analytics gestaltet sich für viele Controller:innen als schwierig. Die Möglichkeiten, welche durch derartige Technologien und den vorhandenen Daten bereitstehen, werden häufig noch nicht wahrgenommen (IP01, 2022, Z. 282-287; IP09, 2022, Z. 316-318). Vielen Controllingmitarbeitenden sind die Auswirkungen und die Vorteile von Predictive Analytics-Tools nicht bewusst. Ihnen ist nicht bekannt, welche Änderungen durch die Implementierung in ihrem persönlichen Tätigkeitsbereich hervorgerufen würden (IP08, 2022, Z. 188-190).

Die Möglichkeiten von Predictive Analytics sind für Controller:innen häufig nicht nachvollziehbar, da das Verständnis für die Prognosemodelle fehlt (IP08, 2022, Z. 265-267). Dies kann unter anderem auf das Skillset der Controller:innen zurückgeführt werden. Denn Predictive Analytics-Methoden erfordern ein gewisses statistisches Verständnis und Programmier-Know-how. Dieses ist häufig vor allem bei den älteren Controller-Generationen nicht gegeben (IP05, 2022, Z. 108-117). Allerdings werden bei der Implementierung von Predictive Analytics im Controlling die Fähigkeiten eines Data Scientists sowie Decision Scientists benötigt. Decision Scientists haben die Rolle, die Umsetzung ausgearbeiteter Entscheidungen zu begleiten und sicherzustellen (IP06, 2022, Z. 153-156). Auf der einen Seite haben Controller:innen nicht die erforderlichen Kenntnisse, um ein Predictive Analytics-Modell aufbauen zu können und auf der anderen Seite sind Data Scientists Mangelware (IP07, 2022, Z. 113-117). Es ist jedoch unerlässlich, dass Controller:innen ihre Tools kennen und diese nachvollziehen können. Predictive

Analytics-Modelle stiften nur dann einen Mehrwert, wenn sie nicht als Blackbox wahrgenommen werden und die Wirkungen der Input-Parameter verstanden werden (IP01, 2022, Z. 308-312).

Oftmals erweist sich der Schritt hin zur vollumfänglichen Integration der Predictive Analytics-Ansätze in die Prozesse des Unternehmens als Hürde. Hierbei müssen nochmals viele Ressourcen in den Know-how-Aufbau des Teams und in die Systeme investiert werden (IP01, 2022, Z. 213-220). Eine weitere Herausforderung stellt das Wissensmanagement dar. Externe Berater:innen übergeben Predictive Analytics-Lösungen nicht ordnungsgemäß und als Konsequenz werden die Tools in späterer Folge nicht eingesetzt. Somit handelt es sich um ein teures Pilotprojekt, ohne einen nachhaltigen Mehrwert zu schaffen (IP05, 2022, Z. 191-196). Es kommt jedoch auch vor, dass manche Projekte nach einigen Jahren letztlich scheitern, da das Wissen im Unternehmen abhandengekommen ist. Dies kann beispielweise der Fall sein, wenn jene Kolleg:innen, die bei der Implementierung mitwirkten, das Unternehmen verlassen haben, oder ein Geschäftsführungswechsel stattgefunden hat, und kein ausreichender Wissenstransfer sichergestellt wurde (IP08, 2022, Z. 261-265).

### **Expectation-Management im Zuge der Implementierung**

Die Experten verwiesen darauf, dass die Erwartungshaltung eine weitere große Herausforderung darstellt (IP01, 2022, Z. 156-160; IP05, 2022, Z. 181-183; IP07, 2022, Z. 78-83; IP09, 2022, Z. 411-414). In der Praxis hat sich gezeigt, dass die Erwartungen der Unternehmen an Predictive Analytics-Lösungen zu hoch sind. Predictive Analytics ist keine magische Glaskugel (IP05, 2022, Z. 181-183). Die Vorstellung, dass man sich ein Predictive Analytics-Tool beschafft und dieses dann alle Fragen beantwortet, ist realitätsfremd. Ein Modell für eine ausgewählte Fragestellung aufzubauen ist mit sehr viel harter Arbeit verbunden (IP07, 2022, Z. 78-83). Interviewpartner 6 stellte fest, dass Implementierungsprojekte häufig daran scheitern, dass Unternehmen den unrealistischen Versprechen einiger Anbieter zu viel Vertrauen schenken (IP06, 2022, Z. 249-251).

Die Erwartungen an Predictive Analytics-Lösungen einerseits und die bestehenden Möglichkeiten von algorithmenbasierten Tools andererseits, müssen zu Beginn geklärt werden (IP01, 2022, Z. 156-160). Unrealistische Zielsetzungen stellen eine Hürde bei der Implementierung

dar (IP09, 2022, Z. 403-409). Werden die Ziele und Anforderungen eines Implementierungsprojektes nicht klar definiert und im Unternehmen kommuniziert, führt dies oftmals zum Scheitern der Projekte (IP02, 2022, Z. 105-108).

Bei Unternehmen, welche sehr intensiv und detailliert manuell planen (z.B. wenn auch unbedeutende Werte sehr ausführlich geplant und alle Planwerte mit Kommentaren versehen werden), werden bei der Implementierung von Predictive Analytics-Lösungen auf Schwierigkeiten stoßen (IP03, 2022, Z. 279-284). Denn es herrscht eine gewisse Skepsis gegenüber Predictive Analytics-Modellen, da das Zustandekommen der Prognosewerte nicht gänzlich nachvollzogen werden kann und die Werte somit nicht einzeln hergeleitet werden können (IP06, 2022, Z. 24-32; IP09, 2022, Z. 170-173). Dementsprechend können die Controller:innen nicht die einzelnen Werte gegenüber der Geschäftsführung argumentieren (IP03, 2022, Z. 225-234). Werden die Prognosen jedoch manuell erstellt, können die Planungswerte anhand der dahinterstehenden Gedankengänge und der berücksichtigten Daten (welche die Basis für die getroffenen Entscheidungen darstellen) verteidigt werden (IP03, 2022, Z. 242-251). Aus diesem Grund wird von Vorgesetzten oftmals eine detaillierte Planung vorausgesetzt. Möglicherweise soll dies auch zur Absicherung dienen (IP09, 2022, Z. 327-330). Bei der Implementierung von Predictive Analytics müssen Unternehmen in diesem Bereich ihre Erwartungshaltung anpassen und akzeptieren, dass Prognosewerte nicht gänzlich hergeleitet bzw. nachgerechnet werden können.

Akzeptanz von Menschen für Predictive Analytics-Lösungen zu schaffen, gestaltet sich schwierig, da nicht nachvollzogen werden kann, wie die Prognosewerte im Detail zustande kommen (IP03, 2022, Z. 251-256). Es zeigt sich jedoch, dass sich zur Akzeptanzschaffung der Controller:innen Predictive Analytics in der Vertriebsplanung gut eignet. Hierbei werden Daten über Feiertrage, lokale Festivitäten und sonstige externe Daten optimal in die Planung miteinbezogen und Menschen akzeptieren in diesem Bereich eher die Planwerte als in anderen Bereichen (IP03, 2022, Z. 429-440). Fehlende Akzeptanz der Controller:innen führt in der Praxis öfter dazu, dass neu implementierte Tools nicht eingesetzt werden und weiterhin die gewohnten Tools – beispielsweise Excel – verwenden, um ihre eigenen Lösungsansätze zu verfolgen (IP02, 2022, Z. 142-147).

### **Predictive Analytics als vermeintliche Bedrohung für Controller:innen**

Controller:innen selbst stellen oftmals ein Hemmnis dar, da sie sich durch Predictive Analytics-Tools bedroht fühlen und fürchten, im Zuge der zunehmenden Automatisierung überflüssig zu



werden (IP01, 2022, Z. 406-407). Doch Predictive Analytics wird niemals den Menschen ersetzen können (IP01, 2022, Z. 160-162; IP08, 2022, Z. 74-82; IP09, 2022, 484-487). Das Ziel von Predictive Analytics ist es, die Aufgaben der Controller:innen interessanter zu gestalten und Standardprozesse zu automatisieren, um so freie Kapazitäten für die eigentliche Aufgabe des Controllings zu schaffen – die Analyse und Interpretation der Ergebnisse (IP01, 2022, Z. 438-446). Ein Experte berichtete von einem Predictive Analytics-Projekt, bei dem es das Ziel war, einen digitalen Forecast zu erstellen, der genauso präzise ist, wie der manuell erstellten Forecasts, um den Menschen dadurch zu ersetzen (IP05, 2022, Z. 59-62). Dieses Projekt wurde jedoch im Supply-Chain-Umfeld durchgeführt und hierbei wurden im Zuge der Automatisierung bis zu 75% der Mitarbeitenden abgebaut. Das betraf weit mehr als 100 Mitarbeitende (IP05, 2022, Z. 45-49). Einige Mitarbeitende wurden weiterhin beschäftigt, um die digitalen Forecasts zu validieren. Die Funktion des Menschen ging dann von der Erstellung auf die Kontrolle der Forecasts über. Auf diese Weise konnten wesentliche Zeiteinsparungen erzielt werden (IP05, 2022, Z. 67-72). Im Gegensatz dazu erwähnte Interviewpartner 1, dass sich Controller:innen oft sorgen, dass Predictive Analytics-Projekte einen Stellenabbau mit sich ziehen könnten, aber das noch in keinem seiner Projekte der Fall war (IP01, 2022, Z. 434-438). Ebenso wurde argumentiert, dass die menschliche Imagination auch in Zukunft nicht obsolet wird. Eine Maschine wird die bedeutenden Fragen, wie z.B. was man erreichen möchte, nicht beantworten können (IP09, 2022, Z. 484-487). Mittlerweile sind die Bedenken, dass durch Predictive Analytics-Lösungen Menschen ersetzt werden können, zurückgegangen. Die Menschen erkennen, dass Predictive Analytics-Tools sie unterstützen und ihnen Freiräume in ihrem täglichen Tätigkeitsbereich verschaffen (IP07, 2022, Z.118-125).

In Zukunft wird eine Kombination der menschlichen und maschinellen Fähigkeiten gefragt sein (IP01, 2022, Z. 160-162). Hybride Lösungen bieten sich für die Zukunft sehr gut an. Der Mensch würde die führende Rolle übernehmen und Predictive Analytics-Tools werden zur Verbesserung der Datenqualität und Prozessqualität eingesetzt. Infolgedessen kann auch beim Forecasting Zeit eingespart werden (IP06, 2022, Z. 123-129).

### **Sonstige Herausforderungen bei der Implementierung**

Bei vielen Unternehmen besteht das Problem, Prozesse an Technologien und neue Tools anzupassen. Dies ist ein fataler Fehler. Unternehmen müssen zu Beginn ihre Ziele und Prozesse definieren und dementsprechend passende Tools implementieren. Hier besteht ein hohes Risiko

für Unternehmen (IP02, 2022, Z. 94-99). Darüber hinaus stellt in manchen Fällen die Software eine Herausforderung dar (IP05, 2022, Z. 117-120). Viele Unternehmen steigen im Zuge der Implementierung von Predictive Analytics auf eine neue Planungssoftware um, da die bestehende das erforderliche Modell nicht abdeckt. Dies ist beispielsweise der Fall, wenn bestehende Planungssoftwares für eine Bottom-up Planung gedacht sind oder die Interfaces zu den Data-Science-Tools nicht gegeben sind (IP09, 2022, Z. 339-345). Jedoch sind bei einem Softwarekauf häufig nicht die Kosten das zentrale Problem, denn es gibt viele Open-Source Programme wie Python und R. Die Schwierigkeit besteht in der schnellen Anschaffung. Häufig muss die Software zuerst einen Validierungsprozess im Unternehmen durchlaufen, d.h. einen Security-Check, um zu klären, ob die Software im Unternehmen verwendet werden darf (IP05, 2022, Z. 123-132).

Interviewpartner 7 führte an, dass eine weitere Herausforderung bei der Implementierung von Predictive Analytics im Controlling darin besteht, dass die Komplexität im Controlling höher ist als in anderen Bereichen. In der G&V und in der Bilanz findet sich schlussendlich das ganze Unternehmen wieder. Dafür Prognosen zu treffen ist schwieriger, als beispielsweise im Marketing gewisse Absatzmengen vorherzusagen (IP07, 2022, Z. 223-230).

Darüber hinaus wurde von den Experten angeführt, dass im Controlling zum einen oftmals nicht die erforderlichen personellen Ressourcen vorhanden sind, um sich abseits des Tagesgeschäfts noch auf weitere Themen zu fokussieren (IP06, 2022, Z. 85-88). Zum anderen besteht oftmals ein falsches Bild von Forecasts. Der Anspruch an Forecasts sollte nicht sein, diese genau zu treffen, sondern einen Maßstab zu bilden. Dieser soll bei der Erreichung der Ziele unterstützen und für Analysen sowie für die Maßnahmenetzung dienen (IP01, 2022, Z. 264-276).

## **9 Conclusio**

Abschließend werden die im Zuge der qualitativen Forschung erzielten Ergebnisse der vorhandenen Literatur gegenübergestellt und zur Beantwortung der Forschungsfragen herangezogen. Es werden in der Conclusio Schlussfolgerungen gezogen und ein Ausblick gegeben.

### **9.1 Diskussion der Ergebnisse**

Zu Beginn wird angemerkt, dass die Ergebnisse der qualitativen Forschung weitreichend die im Rahmen der Literaturrecherche erzielten Ergebnisse bestätigen. Dies kann unter anderem darauf zurückgeführt werden, dass es sich bei den Interviewpartnern durchwegs um renommierte Experten auf diesem Fachgebiet handelt, welche bereits zahlreiche Publikationen hierzu veröffentlicht haben. Viele dieser Werke sind in diese Arbeit als Quellen miteingeflossen. Aus diesem Grund konnten bereits relevante Aspekte aus Fachartikeln entnommen werden und in den Literaturabschnitt dieser wissenschaftlichen Arbeit Eingang finden.

#### **Grenzen und Restriktionen von Predictive Analytics im Controlling**

Sowohl die Literatur als auch die Ergebnisse der qualitativen Forschung zeigen als größte Schwäche von Predictive Analytics ihre Vergangenheitsorientierung auf. Daraus leiten sich Grenzen bei der Implementierung von Predictive Analytics im Controlling ab.

Einige Experten sehen im klassischen Controllingumfeld Fragestellungen, für deren Beantwortung Predictive Analytics-Methoden nicht geeignet sind. Dies ist vor dem Hintergrund zu sehen, dass die Reproduktion der Vergangenheit auf die Zukunft oftmals keinen angemessenen Ansatz darstellt. Ereignisse, welche in den historischen Daten nicht abgebildet sind, können nicht in den Modellen berücksichtigt werden. Aus diesem Grund wird die Zuverlässigkeit von Predictive Analytics im Controlling in Krisenzeiten von den Interviewpartnern – übereinstimmend mit den Ergebnissen der Literaturrecherche – als nicht ausreichend erachtet. In der Literatur wird angeführt, dass in volatilen Zeiten Planungsergebnisse innerhalb kürzester Zeit überholt sein und damit unbrauchbar werden können. Die Experten argumentierten jedoch, dass vor allem die Möglichkeit der Simulation von Szenarien, welche durch digitale Forecasts im Rahmen von Predictive Analytics-Lösungen einfach erstellt werden können, eine entscheidende Rolle in Krisenzeiten spielt. Digitale Forecasts bieten mehr Flexibilität und es können öfter und schneller Forecasts erstellt werden. Darüber hinaus führten die Interviewpartner an, dass für

eine Vielzahl von Unternehmen die Covid-19-Krise der Auslöser für die Setzung von Digitalisierungsschritten und die Umstellung auf Predictive Analytics-Methoden war.

Als eine weitere Grenze bei der Implementierung von Predictive Analytics hat ein Experte die Ergebnisoffenheit beschrieben. Unternehmen scheuen vor Investitionen in Predictive Analytics-Tools zurück, da nicht klar ist, welches Ergebnis am Ende des Implementierungsprozesses erzielt werden kann und ob die Ergebnisse von Predictive Analytics die der manuellen Planung übertreffen. Nach Ansicht der Experten kommt es häufig vor, dass am Ende eines Projektes festgestellt wird, dass kein wesentlicher Mehrwert durch das Implementierungsprojekt erzielt werden konnte und die neuen Methoden zukünftig nicht zum Einsatz kommen.

In Übereinstimmung mit der Literatur werden auch von den Experten die zentralen Anwendungsbereiche von Predictive Analytics im Controlling bei der Forecasterstellung und der Planung gesehen. Im Gegensatz zur Literatur wurde das Reporting bei den Interviews nicht als wesentlicher Einsatzbereich erwähnt. Dies kann womöglich darauf zurückgeführt werden, dass Predictive Analytics-Lösungen in der Regel zur Vorhersage zukünftiger Ereignisse eingesetzt werden. Daher wird die Relevanz von Predictive Analytics-Lösungen bei den Forecastcastingprozessen höher eingestuft als bei den Reportingprozessen. Der Literatur zu Folge können Predictive Analytics-Techniken ebenso für nicht bekannte Ereignisse, welche in der Vergangenheit oder der Gegenwart liegen, angewandt werden. Aus diesem Grund wird das Reporting als weiterer Anwendungsbereich gesehen.

In der Literatur werden das Datenmanagement sowie die Datenbereitstellung zu den wesentlichsten Herausforderungen gezählt. Jedoch konnte im Rahmen der Interviews festgestellt werden, dass wenn bei einem Implementierungsprojekt nicht die erforderlichen Daten – in ausreichender Menge und Qualität – zur Verfügung gestellt werden können, einem Unternehmen von der Implementierung von Predictive Analytics-Lösungen abzuraten ist. Die Experten empfehlen in solchen Fällen in einem ersten Schritt das Data Management zu verbessern, um in Zukunft die erforderlichen Daten bereitstellen zu können. Somit stellt die Datenverfügbarkeit nicht nur eine Herausforderung dar, sondern erweist sich als Restriktion von Predictive Analytics.

## **Herausforderungen bei der Implementierung von Predictive Analytics im Controlling**

Im Rahmen der qualitativen Forschung stellte sich heraus, dass die Datenproblematik und das fehlende Know-how die größten Herausforderungen bei der Implementierung darstellen. Die Ansicht der Experten bestätigen die herrschende Meinung in der Literatur. In diesem Zusammenhang wurde in den Interviews auf einen weiteren relevanten Aspekt hingewiesen – das Wissensmanagement. Das Wissensmanagement bildet in vielen Unternehmen eine Herausforderung, speziell aufgrund von Mitarbeiteraustritten oder Wechseln des Managementteams kommt es vor, dass das Wissen nach einigen Jahren im Unternehmen nicht mehr vorhanden ist und die implementierten Tools nicht mehr eingesetzt werden.

Im Zuge der Interviews wurde auf eine zuvor nicht bekannte Herausforderung im Implementierungsprozess von Predictive Analytics im Controlling aufmerksam gemacht – die Anpassung der Unternehmensprozesse an die einzuführenden Tools. Die Experten haben in der Vergangenheit die Erfahrung gemacht, dass Unternehmen versuchen, bei der Implementierung ihre Prozesse den Systemen anzupassen. Dies ist jedoch ein großer Fehler – Tools müssen für die Prozesse geeignet sein und dementsprechend ausgewählt und implementiert werden. Somit sind die Systeme an die bestehenden Prozesse anzupassen.

Wie bereits erwähnt, wird sowohl in der Literatur als auch in den Interviews die Datenproblematik als wesentliche Hürde angeführt. Eine weitere Erkenntnis, die durch die Interviews hinsichtlich der Daten-Herausforderungen im Implementierungsprozess gewonnen wurde, ist, dass im Controlling oftmals Daten nur in Monatsintervallen vorliegen und beispielweise nicht auf täglicher Basis. Die liegt häufig daran, dass die Daten nur im Zuge des monatlichen Reportings aufbereitet werden. Dies kann jedoch zu Schwierigkeiten bei der Implementierung führen, wenn die Datengrundlage nicht zur Beantwortung der Fragestellung ausreichend tief ist. Ein Interviewpartner wies darauf hin, dass bei Planungen auf monatlicher Basis Daten über einen Zeitraum von zwei bis vier Jahren erforderlich sind.

Es wurde von den Experten empfohlen, vor der Implementierung von Predictive Analytics-Lösungen abzuklären, in welchem Bereich diese im Unternehmen verankert werden sollen, da dies in der Vergangenheit mehrfach zu Schwierigkeiten bei der Implementierung geführt hat. Für Unternehmen besteht die Möglichkeit, die Verantwortlichkeiten nach der Implementierung

einem zentralen Kompetenzcenter zu übertragen, welches für alle Predictive Analytics-Lösungen im Unternehmen zuständig ist. Als Konsequenz kann die Anwendung von einheitlichen Methoden sichergestellt werden und die Verantwortlichkeiten sind klar zugeordnet.

Im Literaturabschnitt der vorliegenden Masterarbeit wurde auf die Problematik der Überanpassung der Modelle eingegangen. Die Herausforderung, dass Modelle inkorrekt antrainiert werden, wurde von keinem der befragten Experten angeführt. Dies kann den Grund haben, dass Techniken zur Vermeidung von Überanpassungen mittlerweile gängige Praxis sind und in jedem Implementierungsprojekt berücksichtigt werden, sodass dies keine Herausforderung mehr darstellt. Zudem wurde von den Experten empfohlen, einfache Modelle anzuwenden. Eine Hauptursache für Überpassung ist die Komplexität der Modelle. Somit könnte diese Empfehlung als Adressierung der Herausforderung der Überanpassung der Modelle gewertet werden.

Die in Kapitel 5.2.3 beschriebene Herausforderung der hohen Implementierungskosten fügten die Interviewpartner interessante Aspekte bei. Zum einen wurden mehrfach integrierte Softwarelösungen oder Branchenlösungen erwähnt, welche zukünftig eine Implementierung wesentlich einfacher und kostengünstiger gestalten würden. Zum anderen wies ein Experte darauf hin, dass Implementierungsprojekte in Deutschland durch Förderungen gestützt werden. Durch die Incentivierung sollten für viele Unternehmen die Implementierungskosten finanzierbar sein und keine unüberwindbare Hürde darstellen.

## **9.2 Limitationen**

Um die Forschungsfragen bestmöglich beantworten zu können, wurden im Rahmen dieser Masterarbeit Interviews überwiegend mit Anbietern von Controlling- und Digitalisierungslösungen geführt, da die Experten vielen Unternehmen im Laufe des Implementierungsprozesses von Predictive Analytics unterstützend zur Seite stehen. Hieraus ergibt sich jedoch eine Limitation dieser Masterarbeit. Konkret wurden im qualitativen Forschungsprozess Erfahrungen von Controllingsmitarbeiter:innen, die bei der Implementierung von Predictive Analytics in ihrem Unternehmen beteiligt waren, nicht miteinbezogen.

Darüber hinaus wurden nur Interviewpartner aus Österreich und Deutschland befragt. Bei den Anwendungsfortschritten werden weltweit sehr wohl Unterschiede vermutet. Somit ist die Aussagekraft für Unternehmen, die in keinem der beiden genannten Staaten ansässig sind, zwangsläufig eingeschränkt.

Die gewonnenen Ergebnisse werfen weitere Fragen auf, die durch weiterführende Untersuchungen ergänzt werden könnten. Beispielsweise wurde von einem Experten die staatliche Bereitstellung von Zuwendungen für Implementierungsprojekte in Deutschland erwähnt. Dies wirft die Frage auf, ob Unternehmen in Österreich ebenso Förderungen für den Implementierungsprozess beanspruchen, also z.B. ob bei österreichischen Unternehmen eine Korrelation zwischen Predictive Analytics-Projekten und der Inanspruchnahme der Investitionsprämie besteht.

### **9.3 Ausblick**

In den nächsten Jahren wird die Anzahl an Implementierungen von Predictive Analytics im Controlling steigen. Dieser Trend hat sich bereits in den letzten Jahren abgezeichnet und wird auch zukünftig fortgesetzt werden. In Zukunft werden vermehrt kostengünstige und einfach anwendbare Predictive Analytics-Lösungen am Markt angeboten und sind somit für Unternehmen unabhängig der Unternehmensgröße relevant. Es wäre denkbar, dass Planungs-Tools in Zukunft mit Predictive Analytics-Funktionen ausgestattet werden. Dies kann dazu führen, dass Controller:innen diese Funktionen nutzen, ohne aber ein Bewusstsein dafür zu entwickeln, dass es sich dabei um Predictive Analytics handelt. Viele Nutzer:innen würden die Anwendung derartiger Funktionen somit nicht den Predictive Analytics-Lösungen zuordnen.

Als Konsequenz würde bei den meisten Unternehmen die Implementierung von Predictive Analytics-Lösungen nicht in Form großer, ressourcenaufwendiger Implementierungsprojekte stattfinden. Vielmehr wird Predictive Analytics als Standardfunktion angeboten und von den Unternehmen genutzt werden. Diese werden voraussichtlich in den ERP-Systemen und in Excel direkt integriert werden. Für Controller:innen wäre es somit nicht erforderlich, im Rahmen der Implementierung die Phase der Modellierung zu durchlaufen, da die entsprechenden Modelle bereits angeboten werden. D.h. es müssten in der Regel für die Implementierung von Standardlösungen keine Data Scientists hinzugezogen werden und das Programmier-Know-how der Controller:innen wird nicht zwingend bzw. nicht in einem detaillierten Ausmaß erforderlich sein. Im Zuge dessen würde die Herausforderung, die das Skillset der Controller:innen adressiert, in Zukunft an Relevanz verlieren.

Im Hinblick auf die Datenproblematik ist zu erwarten, dass Unternehmen in den nächsten Jahren Maßnahmen setzen werden, um ihr Datenmanagement zu verbessern. Dies wird nicht nur im Zusammenhang mit Predictive Analytics-Lösungen im Controlling erforderlich werden, sondern auch durch die steigenden Anforderungen an das Unternehmensreporting, welche oftmals stark auf die steigende Anzahl von Nachhaltigkeits-Vorgaben – Stichwort ESG und nicht-finanzielle Berichterstattung – zurückzuführen sind. Unternehmen müssen die erforderlichen Daten bereitstellen und dies setzt voraus, dass die Daten in entsprechender Qualität im Unternehmen vorhanden sind.

Durch die zukünftigen Entwicklungen, wie etwa den vermehrten Einsatz von Predictive Analytics als Standardlösung, werden sich auch die Herausforderungen ändern. Beispielsweise wäre es denkbar, dass durch die Integration von Predictive Analytics-Funktionen in ERP-Systeme oder Excel, die Hürde der Akzeptanzschaffung wegfällt. Controller:innen würden diese Funktionen als gegeben betrachten und intuitiv nutzen. Im Gegensatz zur Implementierung im Zuge eines großen Implementierungsprojektes sorgen diese für deutlich mehr Aufsehen. In diesem Fall würde Predictive Analytics möglicherweise nicht mehr als Bedrohung, sondern vielmehr als unterstützendes Tool wahrgenommen werden. Darüber hinaus wird sich dadurch die Erwartungshaltung anpassen. Der „Hype“ rund um Predictive Analytics wird abflachen und Controller:innen werden ihre Suche nach der magischen Glaskugel fortsetzen müssen.



## 10 Literaturverzeichnis

- Abbott, D. (2014). *Applied Predictive Analytics. Principles and Techniques for the Professional Data Analyst*. Indianapolis, IN: Wiley.
- Azevedo, A. & Santos, M. F. (2008). KDD, Semma and CRISP-DM: A parallel overview. In Ajith Abraham (Hrsg.), *IADIS European Conference on Data Mining 2008* (S. 182–185).
- Ballwieser, W. & Weißenberger, B. (2023). Controlling, Rechnungslegung und Unternehmensbewertung in Krisenzeiten: Herausforderungen und Lösungsbeiträge. *Der Betrieb*, 76(1-2), 1–7.
- Bayerl, E. (2020). Veränderungen und Lösungsansätze im Controlling. In W. Rosar, M. Setnicka & K. Krippner (Hrsg.), *Digitalisierung im Steuer- und Rechnungswesen* (1. Aufl., S. 289–298). Wien: Linde.
- Becker, S. D. & Schäffer, U. (2017). Was erfolgreiche Unternehmen im Forecasting auszeichnet. *Controlling & Management Review*, 61(9), 8–15.
- Bentley, D. (2017). *Business Intelligence and Analytics*. New York: Library Press.
- Bischof, C. & Wilfinger, D. (2018). Big Data Analytics im Controlling: Anwendungsbereiche, Vorteile und Umsetzung am Beispiel von SAP HANA. In R. Gleich & M. Tschandl (Hrsg.), *Digitalisierung & Controlling. Technologien, Instrumente, Praxisbeispiele* (S. 161–174). München: Haufe.
- Bley, C., Giesel, A. & Ruhwedel, F. (2020). Einsatz von Big Data und Predictive Analytics in der Unternehmensplanung - Ergebnisse einer Befragungsstudie. *Controlling - Zeitschrift für erfolgsorientierte Unternehmenssteuerung*, 32(2), 45–52.
- Borgmeyer, F. A. (2023). Krisenzeiten - Die einzige Gewissheit ist zurzeit die Ungewissheit. Unternehmensführung in Krisenzeiten. *FLF Finanzierung, Leasing und Factoring*, (1), 43–45.
- Brauchle, A. & Hanisch, B. (2017). Big Data und Analytics in der Unternehmenssteuerung. Anwendungsbeispiele aus dem Finanzbereich eines Automobilherstellers. In M. Kieninger (Hrsg.), *Digitalisierung der Unternehmenssteuerung. Prozessautomatisierung, Business Analytics, Big Data, SAP S/4 HANA, Anwendungsbeispiele* (S. 212–225). Stuttgart: Schäffer-Poeschel.
- Braunecker, C. (2016). *How to do Empirie, how to do SPSS*. Wien: Facultas.
- Burow, L., Gerards, Y. & Demmer, M. (2017). Effektiv und effizient steuern mit Predictive Analytics. *Controlling & Management Review*, 61(9), 48–56.

- Chamoni, P. & Gluchowski, P. (2017). Business Analytics — State of the Art. *Controlling & Management Review*, 61(4), 8–17.
- Christ, O. & Ebert, N. (2016). Predictive Analytics im Human Capital Management: Status Quo und Potentiale. *HMD Praxis der Wirtschaftsinformatik*, 53(3), 298–309.
- Damm, J. (2017). Der Blick in die Glaskugel bleibt Zukunftsmusik. *Information - Wissenschaft & Praxis*, 68(1), 83–86.
- Deipenbrock, S., Landewee, L. & Sälzer, G. (2019). Digitale Transformation des Controllings bei Deutsche Post International. Potentiale und Herausforderungen durch Nutzung von Predictive Analytics. *Controller Magazin*, 44(1), 45–50.
- Delen, D. & Ram, S. (2018). Research challenges and opportunities in business analytics. *Journal of Business Analytics*, 1(1), 2–12. Verfügbar unter: <https://doi.org/10.1080/2573234X.2018.1507324>
- Dietrich, D., Heller, B. & Yang, B. (2015). *Data Science and Big Data Analytics. Discovering, Analyzing, Visualizing and Presenting Data*. Indianapolis, IN: Wiley.
- Dresing, T. & Pehl, T. (2018). *Praxisbuch Interview, Transkription & Analyse. Anleitungen und Regelsysteme für qualitativ Forschende* (8. Aufl.). Marburg: Eigenverlag.
- Drozdynski, M. (2016). BI-gestütztes Personalcontrolling am Beispiel des Caritasverbands Moers/Xanten. Anwenderbericht. *Das Krankenhaus*, 108(3), 224–225.
- Dworski, E. A. (2005). Rolling Forecasts. *Wissenschaftsmanagement Zeitschrift für Innovation*, 11(5), 39–40.
- Engelbergs, J. (2016). Big Data und Predictive Analytics- Ansätze für die Unternehmenssteuerung. In P. Horváth & U. Michel (Hrsg.), *Digital Controlling & Simple Finance. Die Zukunft der Unternehmenssteuerung* (S. 3–12). Freiburg: Schäffer-Poeschel.
- Engelbergs, J. (2017). Steuerung des digitalen Unternehmens Zalando. In M. Kieninger (Hrsg.), *Digitalisierung der Unternehmenssteuerung. Prozessautomatisierung, Business Analytics, Big Data, SAP S/4 HANA, Anwendungsbeispiele* (S. 245–257). Stuttgart: Schäffer-Poeschel.
- Ereth, J. & Kemper, H.-G. (2016). Business Analytics und Business Intelligence. *Controlling - Zeitschrift für erfolgsorientierte Unternehmenssteuerung*, 28(8-9), 458–464.
- Evans, J. R. (2017). *Business Analytics. Methods, models, and decisions* (2. Aufl.). Harlow: Pearson Education.
- Fink, V. (2021). *Künstliche Intelligenz in der Personalarbeit. Potenziale nutzen und verantwortungsbewusst handeln*. Stuttgart: Schäffer-Poeschel.

- Gadatsch, A. (2016). Die Möglichkeiten von Big Data voll ausschöpfen. *Controlling & Management Review*, 30(Sonderheft 1), 62–66.
- Gänßlen, S. & Losbichler, H. (2014). Big Data - ein Segen für das Controlling? *CFO aktuell*, 8(4), 144.
- Grönke, K. & Ahr, H. (2017). Reengineering des CFO-Bereichs. Automatisierung der Prozesse, neue Organisationsformen und veränderte Rollen. In M. Kieninger (Hrsg.), *Digitalisierung der Unternehmenssteuerung. Prozessautomatisierung, Business Analytics, Big Data, SAP S/4 HANA, Anwendungsbeispiele* (S. 123–138). Stuttgart: Schäffer-Poeschel.
- Hacker, A. (2022). Funktionsweise der modernen digitalisierten Finanzverwaltung. In R. Leitner, R. Brandl, A. Hacker, J. Idler, C. Kahl, R. Kert et al. (Hrsg.), *Finanzstrafrecht 2021. Digitalisierung der abgabenrechtlichen Veranlagung und Kontrolle: (finanz-)strafrechtliche Implikationen* (S. 1–12). Wien: Linde.
- Haneke, U., Trahasch, S., Zimmer, M. & Felden, C. (2019). Einleitung. In U. Haneke, S. Trahasch, M. Zimmer & C. Felden (Hrsg.), *Data Science. Grundlagen, Architekturen und Anwendungen* (1-13). Heidelberg: dpunkt Verlag.
- Hansmann, K.-W. (1983). *Kurzlehrbuch Prognoseverfahren*. Wiesbaden: Gabler Verlag.
- Haselmayer, M. (2022). Hands-on-Einstieg in Ihr Finance-Analytics-Projekt. *Controlling & Management Review*, 66(5), 56–59.
- Häusl, N. & Leitinger, H. (2009). Berichtswesen. In K. Gaedke & C. Denk (Hrsg.), *Controlling für die tägliche Praxis* (S. 97–142). Wien: Linde.
- Hoffjan, A. & Wahrstötter, S. (2022). Das gehört zukünftig in die Toolbox des Controllers. *ZfK - Zeitung für kommunale Wirtschaft*, (12), 24. Verfügbar unter: [https://www.wiso-net.de/document/ZFKO\\_\\_eb75e28eaa1c59aa17fd54e6657cd128012590c1](https://www.wiso-net.de/document/ZFKO__eb75e28eaa1c59aa17fd54e6657cd128012590c1)
- Holthoff, G. & Decher, R. (2020). Implementierung von Predictive Analytics im Forecasting. Algorithm Aversion und weitere Herausforderungen. *Controlling - Zeitschrift für erfolgsorientierte Unternehmenssteuerung*, 32(6), 52–58.
- Iffert, L. (2016). Predictive Analytics richtig einsetzen. *Controlling & Management Review*, 60(Sonderheft 1), 16–23.
- International Group of Controlling (2015). Erfolgskritische Controller-Kompetenzen. In International Group of Controlling (Hrsg.), *Controller-Kompetenzmodell. Ein Leitfaden für die moderne Controller-Entwicklung mit Muster-Kompetenzprofilen* (IGC-Schriften, S. 51–108). Freiburg: Haufe.

- Isensee, J. & Hüsler, L. (2020). Effizienz im Reporting steigern. Mit den richtigen Maßnahmen den Aufwand reduzieren. In A. Klein & J. Gräf (Hrsg.), *Reporting und Business Analytics* (S. 27–39). Freiburg: Haufe.
- Jenßen, A. & Klatt, M. (2004). Der Forecast. Controlling immer am Puls der Zeit. *Controller Magazin*, 29(3), 262–266.
- Keating, B. (2008). Data Mining: What is it and how is it used? *The Journal of Business Forecasting*, 27(3), 33–35.
- Kelleher, J. D., Mac Namee, B. & D'Arcy, A. (2015). *Fundamentals of Machine Learning for Predictive Data Analytics. Algorithms, Worked Examples, and Case Studies*. Massachusetts: The MIT Press.
- Khan, S., Hedfeld, P. & Bürkle, T. (2021). Personalcontrolling und der demografische Wandel. *Controller Magazin*, 46(3), 88–90.
- Kieninger, M. & Schimank, C. (2017). Auf dem Weg zur digitalisierten Unternehmenssteuerung. In M. Kieninger (Hrsg.), *Digitalisierung der Unternehmenssteuerung. Prozessautomatisierung, Business Analytics, Big Data, SAP S/4 HANA, Anwendungsbeispiele* (S. 4–17). Stuttgart: Schäffer-Poeschel.
- Kotu, V. & Deshpande, B. (2015). *Predictive Analytics and Data Mining*. Waltham, MA: Elsevier.
- Krügerke, C. & Weber, J. (2010). Controllerunterstützung im Vertrieb. Ergebnisse einer branchenübergreifenden Erhebung. *CFO aktuell*, 4(2), 70–74.
- Lamnek, S. (2010). *Qualitative Sozialforschung* (5. Aufl.). Weinheim: Beltz.
- Lanquillon, C. & Mallow, H. (2015a). Advanced Analytics mit Big Data. In J. Dorschel (Hrsg.), *Praxishandbuch Big Data* (S. 55–89). Wiesbaden: Springer.
- Lanquillon, C. & Mallow, H. (2015b). Grenzen konventioneller Business-Intelligence-Lösungen. In J. Dorschel (Hrsg.), *Praxishandbuch Big Data* (S. 255–263). Wiesbaden: Springer.
- Laursen, G. H. N. & Thorlund, J. (2016). *Business Analytics for Managers. Taking business intelligence beyond reporting* (2. Aufl.). Hoboken, NJ: Wiley.
- Lee, P. M. (2013). Use Of Data Mining In Business Analytics To Support Business Competitiveness. *Review of Business Information Systems (RBIS)*, 17(2), 53–58. Verfügbar unter: <https://doi.org/10.19030/rbis.v17i2.7843>
- Leyk, J., Kirchmann, M. & Tobias, S. (2017). Planung, Forecast und Reporting in der digitalen Welt. In M. Kieninger (Hrsg.), *Digitalisierung der Unternehmenssteuerung. Prozessautomatisierung, Business Analytics, Big Data, SAP S/4 HANA, Anwendungsbeispiele* (S. 52–63). Stuttgart: Schäffer-Poeschel.

- Losbichler, H., Falschlunger, L. & Eisl, C. (2017). Messbare Resultate statt Dogmen in der Berichtsgestaltung. In M. Kieninger (Hrsg.), *Digitalisierung der Unternehmenssteuerung. Prozessautomatisierung, Business Analytics, Big Data, SAP S/4 HANA, Anwendungsbeispiele* (S. 66–89). Stuttgart: Schäffer-Poeschel.
- Mailund, T. (2017). *Beginning Data Science in R. Data Analysis, Visualization, and Modeling for the Data Scientist*. New York, NY: Springer.
- Mayer, T.-L., Stegmüller, W. & Zeibig, S. (2017). Digitaler Forecast bei der KSB AG. In M. Kieninger (Hrsg.), *Digitalisierung der Unternehmenssteuerung. Prozessautomatisierung, Business Analytics, Big Data, SAP S/4 HANA, Anwendungsbeispiele* (S. 228–244). Stuttgart: Schäffer-Poeschel.
- Mayr, A., Hofer, P., Karrer, S. & Winzer, J. (2021). Herausforderungen der COVID-19-Pandemie für die Unternehmensführung und das Controlling. Instrumente & Maßnahmen zur Krisenbewältigung. *CFO aktuell*, 15(2), 55–58.
- Mayring, P. (1994). Qualitative Inhaltsanalyse. In A. Boehm (Hrsg.), *Texte verstehen. Konzepte, Methoden, Werkzeuge* (Bd. 14, S. 159–175). Konstanz: UVK Verlag.
- Mayring, P. (2016). *Einführung in die qualitative Sozialforschung* (6. Aufl.). Weinheim: Beltz.
- Mayring, P. (2022). *Qualitative Inhaltsanalyse. Grundlagen und Techniken* (13. Aufl.). Weinheim: Beltz.
- Mehanna, W., Tatzel, J. & Vogel, P. (2016). Business Analytics im Controlling - Fünf Anwendungsfelder. *Controlling - Zeitschrift für erfolgsorientierte Unternehmenssteuerung*, 28(8-9), 502–508.
- Mey, G., Mruck & Katja (2007). Qualitative Interviews. In G. Naderer & E. Balzer (Hrsg.), *Qualitative Marktforschung in Theorie und Praxis* (S. 249-278). Wiesbaden: Gabler.
- Möller, K., Federmann, F., Pieper, S. & Knezevic, M. (2016). Predictive Analytics zur kurzfristigen Umsatzprognose. *Controlling - Zeitschrift für erfolgsorientierte Unternehmenssteuerung*, 28(8-9), 509–518.
- Möller, K. & Pieper, S. (2015). Predictive Analytics im Controlling. Chancen für bessere Entscheidungen erkennen und nutzen. *IM+io Fachzeitschrift für Innovation, Organisation und Management*, 36(4), 40–45.
- Mussnig, W., Juritsch, U., Rausch, A. & Sitter, A. (2021). *Controlling für Führungskräfte. Analysieren - Bewerten - Entscheiden* (4. Aufl.). Wien: Linde.

- Nasca, D., Munck, C. & Gleich, R. (2018). Controlling-Hauptprozesse: Einfluss der digitalen Transformation. In R. Gleich & M. Tschandl (Hrsg.), *Digitalisierung & Controlling. Technologien, Instrumente, Praxisbeispiele* (S. 73–88). München: Haufe.
- Nobach, K., Zirkler, B. & Hofmann, J. (2020). Implikationen der Digitalisierung für das Controlling. *Controller Magazin*, 45(6), 56–62.
- Oehler, K. (2018). Predictive Analytics. Integraler Bestandteil von Controlling-Systemen. *CFO aktuell*, 12(1), 25.
- Oehler, K. (2019). *Advanced Analytics für Controller. Einsetzbare Anwendungen zum Nachbauen mit R*. Freiburg: Haufe.
- Pollmann, R. (2020). *Controlling-Berichte professionell gestalten. Reportings aussagekräftig erstellen und visualisieren*. Freiburg: Haufe.
- Power, D. J., Heavin, C., McDermott, J. & Daly, M. (2018). Defining business analytics: an empirical approach. *Journal of Business Analytics*, 1(1), 40–53. Verfügbar unter: <https://doi.org/10.1080/2573234X.2018.1507605>
- Provost, F. & Fawcett, T. (2017). *Data Science für Unternehmen*. Frechen: mitp-Verlag.
- Pufahl, M. (2014). *Vertriebscontrolling. So steuern Sie Absatz, Umsatz und Gewinn* (5. Aufl.). Wiesbaden: Springer Gabler.
- Putler, D. S. & Krider, R. E. (2012). *Customer and Business Analytics. Applied Data Mining for Business Decision Making Using R*. Boca Raton, FL: CRC Press.
- Rehman, M. H. u., Liew, C. S., Abbas, A., Jayaraman, P. P., Wah, T. Y. & Khan, S. U. (2016). Big Data Reduction Methods: A Survey. *Data Science and Engineering*, 1(4), 265–284. Verfügbar unter: <https://doi.org/10.1007/s41019-016-0022-0>
- Reitzenstein, B. & Sdahl, H. (2018). Predictive Analytics und die Herausforderungen im Controlling. *Controller Magazin*, 43(6), 10–15.
- Ritz, C. & Koran, B. U. (Hrsg.). *BAO-Kommentar* (7. Aufl.). Wien: Linde.
- Sanders, W., Fiedler, J. & Radtke, B. (2021). Planen und steuern mit Predictive Analytics. *Controlling & Management Review*, 65(8), 36–41.
- Schäffer, U. (2017). Predictive Analytics macht Planung und Steuerung flexibler. *Controlling & Management Review*, 61(4), 34–40.
- Schäffer, U. & Weber, J. (2018). Digitalisierung ante portas. *Controlling - Zeitschrift für erfolgsorientierte Unternehmenssteuerung*, 30(1), 42–48.
- Schentler, P., Leber, S. & Pohlner, S. (2022). Management multipler Krisen: Die (neuen) Aufgaben des CFO. *CFO aktuell*, 16(6), 211–215.

- Schulte, C. (2020). *Personal-Controlling mit Kennzahlen. Aussagefähige Instrumente für eine aktive Steuerung im Personalwesen* (4. Aufl.). München: Franz Vahlen.
- Schulze, M., Thiele, P. & Gleich, R. (2019). Optimierung des Planungs-, Budgetierungs- und Forecast-Prozesses mithilfe des Controlling-Prozessmodells 2.0. Aktuelle Trends und Entwicklungen. *CFO aktuell*, 13(2), 62–65.
- Seiter, M. (2019). *Business Analytics. Wie Sie Daten für die Steuerung von Unternehmen nutzen* (2. Aufl.). München: Vahlen.
- Setnicka, M. (2016). Konzeption und Aufbau des Predictive Analytics Competence Center im BMF. *taxlex*, 16(10), 322-224.
- Setnicka, M. (2020). Strategisches Management mit Advanced Analytics Setnicka. *GRC aktuell - Governance - Risiko - Compliance - Management*, 3(1), 28–30.
- Setnicka, M. & Madlberger, H. (2020). Use Case II – Fallauswahl durch Predictive Analytics. In W. Rosar, M. Setnicka & K. Krippner (Hrsg.), *Digitalisierung im Steuer- und Rechnungswesen* (1. Aufl., S. 252–257). Wien: Linde.
- Seufert, A. & Oehler, K. (2016). Controlling und Big Data: Anforderungen an die Methodenkompetenz. *Controlling & Management Review*, 30(Sonderheft 1), 74–81.
- Singh, D. S. & Singh, G. (2017). Big Data - A Review. *International Research Journal of Engineering and Technology*, 4(4), 822–824.
- Sommerer, J. (2018). Übertragung des ICV-Wirkungsstufenmodells auf das Personalcontrolling: Eine empirische Untersuchung der Wirkungsorientierung bei den DAX30. *Betriebswirtschaftliche Forschung und Praxis*, (4), 472–494.
- Stephan, M. & Grether, B. (2020). Predictive Analytics: Grundlagen, Projektbeispiele und Lessons Learned. In A. Klein & J. Gräf (Hrsg.), *Reporting und Business Analytics* (S. 42–63). Freiburg: Haufe.
- Strohmeier, S. & Piazza, F. (2015). Prozesse der Human Resource Intelligence und Analytics. In S. Strohmeier & F. Piazza (Hrsg.), *Human Resource Intelligence und Analytics* (S. 49–87). Wiesbaden: Springer.
- Strohmeier, S., Piazza, F. & Neu, C. (2015). Trends der Human Resource Intelligence und Analytics. In S. Strohmeier & F. Piazza (Hrsg.), *Human Resource Intelligence und Analytics* (S. 339–367). Wiesbaden: Springer.
- Trahasch, S. & Felden, C. (2019). Grundlegende Methoden der Data Science. In U. Haneke, S. Trahasch, M. Zimmer & C. Felden (Hrsg.), *Data Science. Grundlagen, Architekturen und Anwendungen* (S. 65–100). Heidelberg: dpunkt Verlag.

- Vriens, M., Chen, S. & Vidden, C. (2019). *From data to decision. A handbook for the modern business analyst*. San Diego, CA: Cognella Academic Publishing.
- Wilhelm, I. (2022). Controlling einer mittelständischen Unternehmensgruppe über Self-Service-BI. *CFO aktuell*, 16(5), 188–190.
- Winters, R. (2017). *Practical Predictive Analytics. Back to the future with R, Spark, and more!* (1st ed.). Birmingham: Packt Publishing.
- Witten, I. H. & Frank, E. (2005). *Data mining. Practical machine learning tools and techniques* (2. Aufl.). Amsterdam: Elsevier.
- Zdrowomyslaw, N. (2016). Personalcontrolling in der Unternehmenspraxis. In W. Becker & P. Ulrich (Hrsg.), *Handbuch Controlling* (S. 223–245).



## Weitere Quellen

Aßmann, J., Sauer, J. & Schulz, M. (2020). *Ein agiles Vorgehensmodell zur Einführung von Predictive Analytics in Unternehmen*. Elmshorn: Nordakademie Hochschule der Wirtschaft. Verfügbar unter: [https://ceur-ws.org/Vol-2738/LWDA2020\\_paper\\_28.pdf](https://ceur-ws.org/Vol-2738/LWDA2020_paper_28.pdf)

Bundesabgabenordnung (BAO) BGBI 1961/194 idF BGBI I 2018/32

Chartered Institute of Management Accountants. (2016). *CGMA Report. Business Analytics and Decision Making*. Verfügbar unter: <https://www.cgma.org/Resources/Downloadable-Documents/business-analytics-briefing.pdf>

Eckerson, W. (2007). *Predictive Analytics. Extending the Value of Your Data Warehousing Investment*. The Data Warehousing Institute.

Lausberg, I. & Hoffmann, D. (2019). *Robotic Process Automation, Predictive Analytics und Künstliche Intelligenz* (Warth & Klein Grant Thornton, Hrsg.). Düsseldorf.

Reuter, R. (2019, 25. November). *Controlling 4.0 - genaue Prognosen durch Predictive Analytics* (GENIOS WirtschaftsWissen, Hrsg.) (Nr. 11). Verfügbar unter: [https://www.genios.de/wirtschaft/controlling\\_4\\_0\\_genauere\\_prognosen/c\\_control\\_20191125.html](https://www.genios.de/wirtschaft/controlling_4_0_genauere_prognosen/c_control_20191125.html)

Reuter, R. (2021, 29. Dezember). *People Analytics - neue Impulse für das Personalcontrolling. Neuer Anshub für das Personalcontrolling* (GENIOS WirtschaftsWissen, Hrsg.) (Nr. 12). Verfügbar unter: [https://www.genios.de/wirtschaft/people\\_analytics\\_neue\\_impulse\\_f\\_r\\_das/c\\_control\\_20211229.html](https://www.genios.de/wirtschaft/people_analytics_neue_impulse_f_r_das/c_control_20211229.html)

Tischler, R. & Fuchs, C. (2022). *Predictive Planning and Forecasting on the Rise – Hype or Reality?* (Business Application Research Center, Hrsg.). Würzburg.

# Anhang A

## Interviewleitfaden

### Thema der Masterarbeit: Predictive Analytics im Controlling – Herausforderungen im Implementierungsprozess

FHWien der WKW, Masterstudiengang Financial Management und Controlling

Abschlussjahr 2023

Betreuer der Arbeit: Christopher Liska B.A. M.A.

Wie bereits erwähnt beschäftigte ich mich im Rahmen meiner Masterarbeit mit dem Implementierungsprozess von Predictive Analytics im Controlling und möchte der Frage nachgehen, ob die Implementierung für Unternehmen eine Hürde darstellt und auf welche Herausforderungen und Grenzen man dabei stößt. Es ist vorgesehen, dass dieses Interview aufgezeichnet wird. Ihre Daten werden selbstverständlich vertraulich behandelt.

**Einstiegsfrage:** Bitte beschreiben Sie kurz Ihr Aufgabenfeld.

#### Hauptteil:

- 1) Welche Anwendungsbereiche sehen Sie für Predictive Analytics speziell im Controlling?
- 2) Für Unternehmen welcher Branche und Größe lohnt sich eine Implementierung Ihres Erachtens?
  - *Zusatzfrage: Gibt es Situationen oder Unternehmen denen von einer Implementierung abzuraten ist? Warum?*
- 3) Konnten Sie in den letzten fünf Jahren Entwicklungen und Trends von Predictive Analytics im Controlling feststellen und wenn ja, welche?
- 4) Welche Herausforderungen stellen sich bei der Implementierung von Predictive Analytics im Controlling Ihrer Erfahrung nach?
- 5) Was gilt es im Vorfeld bzw. bei der Umsetzung zu beachten?
  - *Zusatzfrage: Wie verläuft eine erfolgreiche Implementierung?*

- 6) Was sind Ihrer Meinung nach die Hauptgründe für das Scheitern einer Implementierung?
- *Zusatzfrage: In welchem Stadium scheitern Implementierungen typischerweise?*
- 7) Haben die derzeitigen Krisen (wie beispielsweise die Covid-19-Krise) Auswirkungen auf die Entwicklungen von Predictive Analytics im Controlling?
- 8) Kann man aus der erfolgreichen Implementierung von Predictive Analytics in anderen Bereichen eines Unternehmens (z.B. Marketing, Risk Management, etc.) Rückschlüsse für Predictive Analytics-Projekte im Controlling ziehen?
- 9) Verändert sich durch Predictive Analytics die Zusammenarbeit mit anderen Bereichen in einem Unternehmen? Treten erfahrungsgemäß Fragen zu den Datenzugriffsrechten, der Datenverantwortung sowie Datenpflege auf?
- 10) **Abschlussfrage:** Welche zukünftigen Entwicklungen erwarten Sie in den nächsten 10 Jahren?
- *Zusatzfrage: Wird es Ihres Erachtens künftig zur Norm, Predictive Analytics im Controlling anzuwenden?*