


MASTERARBEIT

ANWENDUNG VON DATA MINING-ALGORITHMEN ZUR INFORMATIONSGEWINNUNG IM SOFTWARESUPPORT

ausgeführt am



Studiengang

Informationstechnologien und Wirtschaftsinformatik

Von: Mario Moser

Personenkennzeichen: 1810320014

Graz, am 10. Dezember 2019

.....
Unterschrift

EHRENWÖRTLICHE ERKLÄRUNG

Ich erkläre ehrenwörtlich, dass ich die vorliegende Arbeit selbstständig und ohne fremde Hilfe verfasst, andere als die angegebenen Quellen nicht benützt und die benutzten Quellen wörtlich zitiert sowie inhaltlich entnommene Stellen als solche kenntlich gemacht habe.

.....

Unterschrift

DANKSAGUNG

Bedanken möchte ich mich bei meinem Betreuer, Herrn Dipl.-Ing. Dr. Mark Kröll, für sein stets konstruktives Feedback und seine großartige Unterstützung bei der Erstellung dieser Arbeit.

Ich danke meiner gesamten Familie für den Rückhalt. Speziell meinem Bruder Markus für die vielen wertvollen Gespräche und Diskussionen. Außerdem danke ich meiner Freundin Stefanie, die mir so oft den Rücken freigehalten hat, und mir geduldig zur Seite gestanden ist.

Ein besonderer Dank gilt der Firma BMD Systemhaus GesmbH für die Unterstützung bei der Durchführung der Fallstudie, sowie den Interviewpartnern Herrn Moser (Firma BearingPoint), Herrn S. (Firma C.) und Herrn Fenzl (Firma BMD) für ihre Zeit.

KURZFASSUNG

Diese Arbeit beschäftigt sich mit der Anwendung von Data Mining-Algorithmen zur Informationsgewinnung im Softwaresupport. Data Mining-Algorithmen sind Tools der sogenannten „Knowledge Discovery“, der interaktiven und iterativen Entdeckung von nützlichem Wissen. Sie werden eingesetzt, um Daten zu analysieren und über statistische Modelle wertvolle Informationen einer Domäne zu finden.

Die Domäne in dieser Arbeit ist der Softwaresupport, jene Abteilung in Softwareentwicklungs-Unternehmen, die Kundinnen und Kunden bei der Lösung von Problemen unterstützt. Meist sind diese Supportabteilungen als Callcenter organisiert und arbeiten zusätzlich mit Ticketsystemen (einem E-Mail-basierten Kommunikationssystem).

Zweck dieser Arbeit ist es zu prüfen, inwiefern Data Mining-Algorithmen im Softwaresupport angewendet werden und ob tatsächlich wertvolle Informationen identifiziert werden können. Erwartet wird, Informationen über das Supportverhalten von KundInnen sowie den Einfluss von externen Faktoren wie Wetter, Feiertage und Urlaubszeiten zu entdecken.

Die Literaturrecherche dieser Arbeit, beinhaltet unter anderem die Themen Personaleinsatzplanung im Softwaresupport und Data Science (Zusammenfassender Begriff für Data Mining, Data Engineering oder Data-Driven Decision Making, etc.). Im „experimental Setup“ finden Interviews zum Thema Status quo- und Kennzahlen im Softwaresupport mit führenden österreichischen Softwarehäusern sowie eine Fallstudie zur Anwendung eines Data Mining-Vorgehensmodells statt. Letztlich wird in einem Feldexperiment geprüft, ob es mit Data Mining-Algorithmen tatsächlich möglich ist, Informationen für den Softwaresupport zu entdecken.

Als Ergebnis dieser Arbeit zählen einerseits die Identifikation von Möglichkeiten, um im Support Kosten zu sparen und Effizienz zu gewinnen und andererseits das Finden von wertvollen Informationen über Abläufe und Zusammenhänge im Support. Die gewonnenen Informationen können in weiterer Folge in den Supportprozess einfließen, um effektivere und effizientere Prozesse zu schaffen. Ein weiteres Resultat des Informationsgewinns ist auch die Qualitätssteigerung von Managemententscheidungen sein.

ABSTRACT

This thesis deals with the usage of data mining algorithms for information acquisition in the field of software support. Data Mining algorithms are tools of the Knowledge Discovery process, the interactive and iterative discovery of useful knowledge. They are used to analyze data and make use of statistical models to find valuable domain information.

The domain in this work is the field of software support, the department in software development companies that helps clients solve problems. Such support departments are usually organized as call centers and also work with ticket systems (an e-mail-based communication system).

The purpose of this thesis is to examine the extent to which data mining algorithms are usable in the field of software support and whether valuable information can actually be identified. It is expected to discover information about the support behavior of customers as well as information about the influence of external factors such as weather, holidays and holidays.

The literature review of this thesis includes topics such as personnel deployment planning in software support and data science (summary term for data mining, data engineering or data-driven decision making, etc.). The "experimental setup" includes interviews on the status quo and the key figures in the field of software support with leading Austrian software houses as well as a case study on the usage of a data mining forecast model. Finally, it is examined in a field experiment whether data mining algorithms actually make it possible to discover information for software support.

As a result of this thesis it is expected to identify ways to save costs and increase efficiency in the field of software support. In addition, it is expected to find valuable information about processes and connections in the software support. The gained information can then be incorporated into the support process to create more effective and efficient processes. Another result of the information gain is also the quality improvement of management decisions.

INHALTSVERZEICHNIS

1	EINLEITUNG	1
1.1	Problemstellung	2
1.2	Motivation	3
1.3	Zielsetzung	3
1.4	Vorgehensweise	4
1.5	Struktur	5
2	LITERATURRECHERCHE	7
2.1	Informationsgewinnung	7
2.1.1	Knowledge Discovery und Wissensmanagement	8
2.1.2	Data Science	11
2.1.3	Fazit	13
2.2	Data Mining	14
2.2.1	Das CRISP-DM-Vorgehensmodell	16
2.2.2	Aufgaben von Data Mining-Algorithmen	18
2.2.3	Fazit	22
2.3	Softwaresupport	23
2.3.1	Supportstrukturen	23
2.3.2	Personaleinsatzplanung und Kundenzufriedenheit	26
2.3.3	Fazit	27
2.4	Zusammenfassung	29
3	EXPERIMENTAL SETUP	31
3.1	Status quo und Kennzahlen im Support – Experteninterviews	31
3.1.1	Interviewpartner	31
3.1.2	Interview Setup und Leitfaden	32
3.1.3	Ergebnisse aus den Interviews	32
3.1.4	Fazit	38
3.2	Anwendung von DM-Algorithmen – Fallstudie	38
3.2.1	Fallstudie Setup	39

3.2.2	Durchführung DM-Vorgehensmodell.....	40
3.2.3	Fazit.....	57
3.3	Zusammenfassung	57
4	FELDEXPERIMENT	60
4.1	Vorgehen und Methodendesign Experiment	60
4.1.1	Aufgabenstellung	62
4.1.2	Auswertung Führungskräfte	63
4.1.3	Auswertung DM-Vorhersagemodell.....	64
4.2	Statistische Auswertung und Hypothesentest	65
4.2.1	Zweistichproben-t-Test	65
4.2.2	Hypothesentest Vorbereitung	67
4.2.3	Hypothesentest Durchführung.....	68
4.3	Zusammenfassung	69
5	FAZIT/AUSBLICK.....	70
	ANHANG A - INTERVIEWFRAGEN	74
	ANHANG B - INTERVIEW FIRMA BMD SYSTEMHAUS GMBH	75
	ANHANG C - INTERVIEW FIRMA BEARINGPOINT GMBH	79
	ANHANG D - INTERVIEW FIRMA C	82
	ANHANG E - RSTUDIO CODE.....	85
	ABBILDUNGSVERZEICHNIS	88
	TABELLENVERZEICHNIS	89

1 EINLEITUNG

Die Entscheidungsfindung ist in jedem Unternehmen ein essenzielles Thema. Grundlage jeder Entscheidung sollten fundierte Informationen sein, die einen bestimmten Sachverhalt besser verständlich machen. Den Entscheidungsfindungsprozess mit zusätzlichen Informationen zu versorgen ist eine der Kernaufgaben der Data Science. Nach Ng & Soo (2018, S. 1) tragen Data Science-Techniken durch die Analyse verschiedenster ausgewählter Datenquellen dazu bei:

- bessere Entscheidungen zu treffen,
- Trends in Daten zu erkennen,
- durch die Trends Vorhersagen zu treffen,
- die Wahrscheinlichkeit der möglichen Ergebnisse zu berechnen,
- exakte Resultate zu erzielen.

Es sollte dabei aber nicht außer Acht gelassen werden, dass die Informationen einer gewissen Qualität entsprechen müssen. Nach Schubert & Bandelow (2014, S. 424) ist es ein wesentliches Hindernis bei der Entscheidungsfindung, wenn ein solches Übermaß an Informationen vorhanden ist, dass man nicht mehr weiß, welche Informationen zentral, richtig, nur teilweise relevant und welche gar nicht wichtig im Hinblick auf die zu treffende Entscheidung sind.

Letztendlich hängt bei der Data Science – genauso wie bei der Entscheidungsfindung – alles von der Qualität und der Quantität der zu analysierenden Daten ab. Wenn bereits in der Datenquelle fehlende, falsche oder inkonsistente Werte vorhanden sind, kann keine noch so aufwendige Analyse qualitativ gute Ergebnisse liefern (Schubert & Bandelow, 2014, S. 2).

Als Teil des Überbegriffs Data Science versucht das Data Mining (DM) mit Hilfe bestimmter Vorgehensmodelle relevante Informationen aus Datenquellen zu extrahieren. Vorgehensmodelle wie das Knowledge Discovery in Databases (KDD) oder der Cross Industries Standard Process for Data Mining (CRISP-DM) legen einen hohen Wert auf Datenqualität, daher beinhalten beide Prozesse jeweils Phasen zur Datenanalyse, Datenaufbereitung und Datenverarbeitung. Dadurch soll gewährleistet sein, dass die Ergebnisse der Analysen, die in weiterer Folge als Grundlage für oft zukunftsweisende Unternehmensentscheidungen herangezogen werden, auf validen Daten basieren (Chapman et al., 2000; Fayyad, Piatetsky-Shapiro, & Smyth).

1.1 Problemstellung

Umgelegt auf die Domäne dieser Arbeit, nämlich den Softwaresupport, sind es nach Higday-Kalmanowitz & Simpson (2005, S. 5) folgende Problemfelder bzw. Fragen für die laufend Entscheidungen getroffen werden bzw. Antworten gefunden werden müssen:

- Investieren in Unterstützungsinfrastruktur oder Personal?
- Wie setzen sich die Kosten für den Kundensupport zusammen?
- Wie kann durch Prozessveränderungen Geld gespart werden?
- Werden die Supportkosten von übermäßigen Gemeinkosten beeinflusst?
- Wie lange dauert es, bis sich neue Supporttools bezahlt machen?

In Dienstleistungsunternehmen sind es die Personalkosten, die in der Kostenstruktur den größten Anteil bilden. Gerade deshalb ist es wichtig, Personalressourcen effektiv und effizient einzusetzen. Higday-Kalmanowitz und Simpson (2005) äußern sich zum Thema Personalressourcen wie folgt:

„Key to execution is the availability and assignment of qualified resources, whether through headcount or full time equivalents (FTE). Even with senior management support, buy-in from all stakeholders, CMDB information, good process definition and automation, an understaffed resource pool will not be successful in delivering quality Change Management“ (S. 86)

Die drastische Formulierung dieser Aussage lässt annehmen, dass die Planung der Mitarbeiterressourcen einer der wesentlichen Erfolgsfaktoren in Dienstleistungsunternehmen und somit auch dem Softwaresupport ist.

Das erwähnte Change-Management ist neben dem Configuration-Management und dem Incident- sowie Problem-Management auch Teil des IT-Service-Managements. Das IT-Service-Management beschreibt dabei die Gesamtheit an Maßnahmen, die ein IT-Service, wie der Support, tätigen muss, um das übergeordnete Ziel, eine möglichst positive „end-user experience“, zu erreichen. (Mitrakis, 2019, S. 87)

Ein wesentlicher Teil dieser Arbeit ist es also, jene Potenziale zu erheben, durch die eine Supportabteilung effizienter arbeiten kann. Dazu müssen sowohl die Strukturen im Support als auch die Vorgehensmodelle analysiert werden. In Bezug auf die Planung von Supportressourcen geht es im Operativen auch darum, eine Unterbesetzung der Supportmannschaft auf jeden Fall zu vermeiden. Andererseits gilt es, stets die Kosten für den Kundensupport sowie die Gemeinkosten im Support zu überwachen. Eine Überbesetzung soll also auch vermieden werden.

Durch die Analyse von Daten und deren Auswertungen soll das Data Mining dazu beitragen, Lösungen für die angesprochenen Problemfelder wie Ressourcenplanung und Anfragenbearbeitungen zu finden.

1.2 Motivation

Probleme, wie die oben genannten, treten natürlich nicht nur im Softwaresupport auf. In vielen Branchen gibt es schwer messbare Probleme oder Daten, die nur diffizil zu interpretieren sind. Genau an dieser Stelle setzen Data Scientists an. Das Data Mining liefert eine breite Palette an Tools für die Analyse und Auswertung von Datenmengen, die manuell nicht mehr bearbeitet werden können. Die ausgewählten Algorithmen können beispielsweise für Vorhersagen, Assoziationen oder Klassifikationen eingesetzt werden, um Supportaufkommen vorherzusagen, Lösungswege zu assoziieren oder Problemursachen zu klassifizieren. Data Mining wird in Verbindung mit bestimmten Data Mining Vorgehensmodellen angewendet. Dadurch wird eine strukturierte und nachvollziehbare Vorgehensweise gewährleistet.

Diese Arbeit soll einerseits den Stand der Dinge im Support sowie praktische Anwendungsfälle des Data Mining ermitteln, aufklären inwiefern Data Mining bereits im Support eingesetzt wird und in weiterer Folge den Mehrwert für die Anwendung quantifizieren.

1.3 Zielsetzung

Ziel dieser Arbeit ist es die Anwendbarkeit ausgewählter Data Mining-Algorithmen hinsichtlich Informationsgewinnung, Entscheidungsunterstützung oder Prozessverbesserung im Softwaresupport zu prüfen. Die erwähnten Einsatzgebiete stellen sich im laufenden Betrieb immer wieder als konkrete Problemstellung dar, deren Lösung dazu beitragen kann, Kosten zu sparen, die Qualität im Support zu steigern oder bessere Managemententscheidungen zu treffen. All diese potentiellen Verbesserungen verfolgen das übergeordnete Ziel, den Unternehmensgewinn nachhaltig zu steigern.

Wie eingangs erwähnt, spielt der Einsatz von Ressourcen im Softwaresupport eine wesentliche Rolle. Daher ist es auch Ziel dieser Arbeit zu erheben, wie sich das sogenannte Supportaufkommen ergibt und wie geplant werden muss, um dieses optimal zu bedienen. Auch die Lösung dieses Problems soll durch den Einsatz von Data Mining-Algorithmen vorangetrieben werden. Es stellt sich außerdem die Frage, ob es den Algorithmen möglich ist, das Supportaufkommen etwa so genau vorherzusagen wie erfahrene Führungskräfte.

Neben der Problemstellung „Disposition von Mitarbeitern“ wird auch nach Zusammenhängen in den Daten gesucht, aus denen sich Verbesserungspotenziale für das Unternehmen ergeben können. So können sich zum Beispiel nützliche Informationen für den Software-Entwicklungsprozess, oder den Mitarbeiter-Einschulungsprozess ergeben.

1.4 Vorgehensweise

Die folgenden wissenschaftlichen Methoden werden in dieser Arbeit eingesetzt, um eine Antwort auf die Forschungsfrage „Wie können Data Mining-Algorithmen zur Informationsgewinnung im Softwaresupport gewinnbringend eingesetzt werden?“ zu finden:

- Literaturrecherche
- Qualitative Interviews
- Case Study
- Feldexperiment

Die Literaturrecherche bildet die theoretische Basis der Arbeit. Sie umfasst folgende Kernbereiche:

- Wissenschaftliche Artikel: Arbeiten zu den Themen Data Science, Data Mining und Knowledge Discovery dienen als Input zum Vorgehen im Data Mining-Prozess. Der aktuelle Input sowie die gesammelten Erfahrungen sollen dieser Arbeit als erweiterte theoretische Grundlage dienen.
- Fachlicher Input: Fachliteratur zu allgemeinen Prozessen, Strukturen und Planungsmodellen im IT-Support sollen der Einführung in die Thematik dienen. Weitere Fachliteratur zum Thema Data Science dient der Aufklärung über die Möglichkeiten zur Datenverarbeitung und Literatur zum Thema Data Mining soll im Speziellen jene Themen durchleuchten, die in der Fallstudie zur Anwendung kommen. Beispiele dafür sind die Definitionen von supervised und unsupervised Learning, die Definitionen von Clusterbildung und Regressionen, sowie die Beschreibung der einzelnen Phasen der DM-Vorgehensmodelle KDD und CRISP-DM. Außerdem soll für eine thematische Abgrenzung aller genannten Begriffe gesorgt werden.
- „Funktionelle Literatur“: Ergänzend soll Literatur über statistische Verfahren den mathematischen Hintergrund des Data Minings näher erläutern. Die „funktionelle Literatur“ ist außerdem die Basis für die strukturelle Durchführung der Interviews, der Fallstudie, sowie des Feldexperiments und der Hypothesentests.

Ein wesentlicher Faktor im Data Mining ist das sogenannte Domänenwissen. Dies sind jene Informationen, die für die Identifikation der Problemstellungen, die Auswahl der passenden Datensets und für das Datenverständnis eine wesentliche Rolle spielen. Dieses Domänenwissen soll mittels qualitativer Interviews mit führenden Softwareherstellern in Österreich eingeholt werden. Unter anderem sollen folgende Fragen beantwortet werden:

- Wie sehen Struktur und Vorgehen im Support aus?
- Wie wird das Supportaufkommen pro Tag definiert?
- Wie findet die Planung der Supportressourcen statt?
- Welche Faktoren können auf das Supportaufkommen Einfluss haben?
- Gibt es bereits Einsatzgebiete für Data Mining im Support?

Die Case Study beschreibt die Anwendung des bereits angesprochenen CRISP-Vorgehensmodells als Lösungsansatz einer Problemstellung bei der Firma BMD Systemhaus GesmbH. Ziel der Fallstudie ist es, Modelle zur Gewinnung von Informationen und zur Vorhersage von Supportaufkommen im Support zu entwickeln. Aus dieser Fallstudie werden sich schließlich Hypothesen ableiten, die mit dem entwickelten Vorhersagemodell evaluiert werden.

In einem Feldexperiment werden letztlich Vorhersagen zum Supportaufkommen aus zweierlei Quellen eingeholt und mit den tatsächlichen Werten evaluiert. Einerseits liefern erfahrene Führungskräfte im Support und andererseits das Vorhersagemodell aus der Fallstudie Schätzungen zum Supportaufkommen des Monats November 2019. Die Ergebnisse dieser Messungen fließen in den Hypothesentest ein, der aufgrund des Hypothesendesigns mit einem Zweistichproben-T-Test durchgeführt wird.

1.5 Struktur

Wie in Abbildung 1 ersichtlich, besteht die vorliegende Arbeit aus den vier Kapiteln Einleitung, Literaturrecherche, experimental Setup und Feldexperiment. Abgesehen von der Einleitung ist jedes Kapitel in Unterkapitel inklusive Fazit und jeweils ein Zusammenfassungskapitel eingeteilt.

Das erste Kapitel beinhaltet die Einleitung mit Erläuterung der Problemstellung, Motivation, Zielsetzung und Struktur dieser Arbeit.

Im zweiten Kapitel sind die Literaturrecherche und deren Ergebnisse zu finden. Hier finden eine Definition sowie eine Abgrenzung der relevanten Begriffe der Data Science statt. Schließlich wird im Detail auf Data Mining Vorgehensmodelle und Aufgaben sowie Supportstrukturen und -prozesse eingegangen.

Die Theorie zum Support wird in Kapitel drei durch drei Experteninterviews mit Praxiswissen ergänzt. Schließlich folgt eine Zusammenführung, die in mögliche Anwendungsgebiete für Data Mining-Algorithmen im Support endet. In der Fallstudie, die ebenfalls diesem Kapitel zugeordnet ist, wird schließlich ein Data Mining-Vorgehensmodell erarbeitet.

In Kapitel vier werden abschließend in einem Feldexperiment Vorhersagen von erfahrenen Führungskräften im Support und von einem Data Mining-Vorhersagemodell aufgenommen, die in einem anschließenden Hypothesentest gegenübergestellt werden.

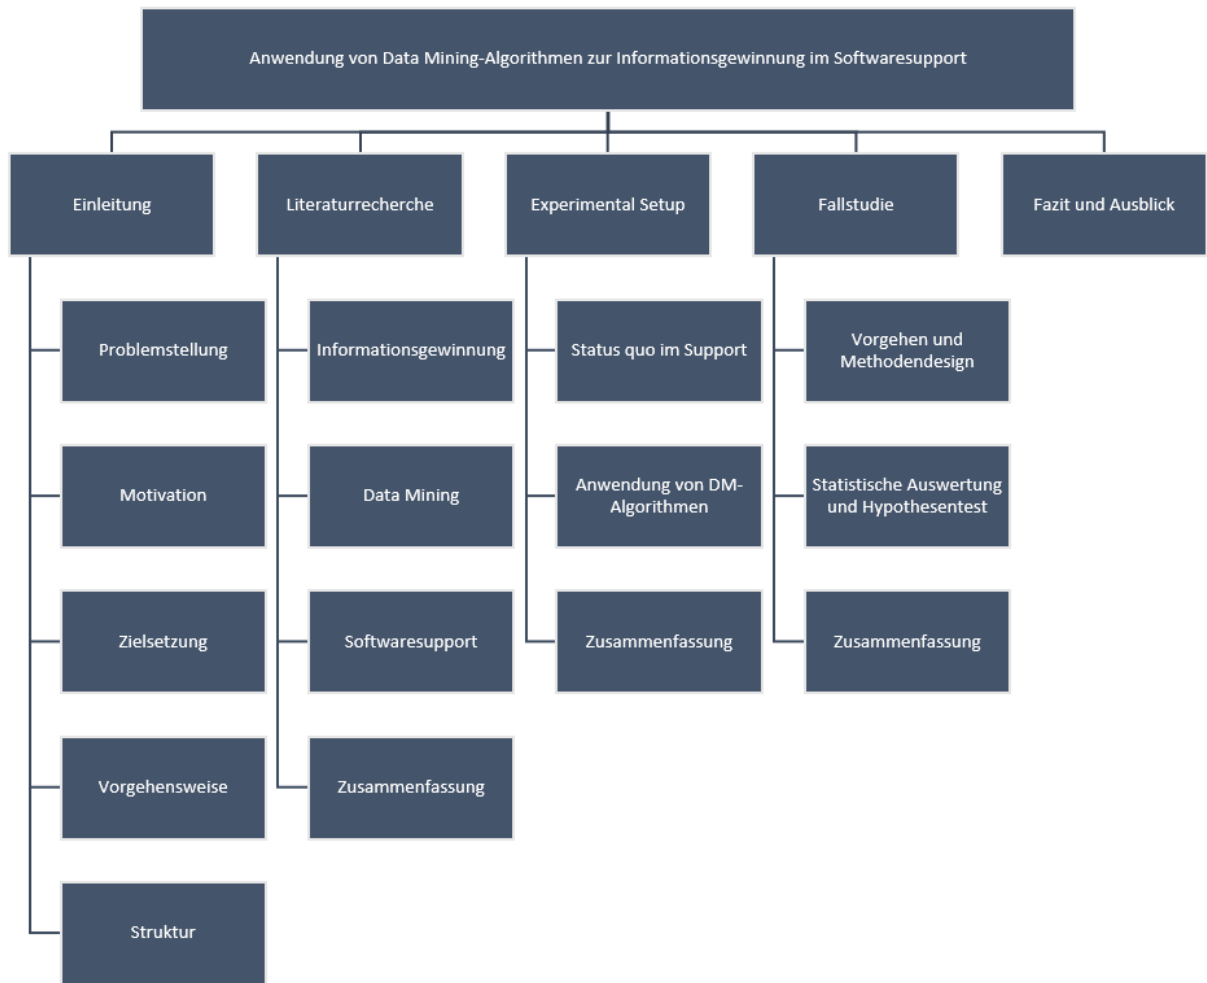


Abbildung 1: Aufbau der Arbeit (eigene Darstellung, 2019)

2 LITERATURRECHERCHE

Das folgende Kapitel bildet die theoretische Grundlage dieser Arbeit. Die drei großen Themenblöcke Informationsgewinnung, Data Mining und Softwaresupport werden beginnend mit den Grundlagen, bis hin zur Auswirkung auf diese Arbeit bearbeitet. Die Themenblöcke ergeben sich aus dem Ziel der Arbeit (Informationsgewinnung und Knowledge Discovery), der Methode (Data Mining als Methode zur Informationsgewinnung) und dem Anwendungsbereich in der Praxis (Personalressourceneinsatz im Softwaresupport).

Ziel dieses Kapitels ist es einerseits die Grundlagen der Data Science und folglich auch des Data Minings darzustellen. Dabei wird mit dem Zweck dieser Tätigkeiten, der Informationsgewinnung, und dem ersten daraus resultierenden Vorgehensmodell, dem Knowledge Discovery from Databases (KDD), begonnen. Nach weiteren Begriffsabgrenzungen wird das KDD mit dem aktuellen Branchenstandard, dem Cross Industry Standard Prozess for Data Mining (CRISP-DM), verglichen und Vorteile sowie Nachteile identifiziert. In Zuge dessen werden auch jene Aufgaben näher beschrieben, die das Data Mining erledigen können.

Abschließend wird auf den Softwaresupport und dessen Strukturen näher eingegangen und ein kurzer Exkurs in die Personaleinsatzplanung unternommen. Dieses Kapitel endet schließlich mit den möglichen Anwendungsfällen für Data Mining im Softwaresupport.

Die Erkenntnisse dieses Kapitels bilden die Basis für die folgenden Kapitel, besonders die Anwendungsfälle für Data Mining im Softwaresupport, da diese in den Interviews diskutiert werden und die Ausgangsbasis für die Fallstudie bilden.

2.1 Informationsgewinnung

Den Unterschied zwischen Daten, Informationen und Wissen zu kennen, ist im Zusammenhang mit der Informationsgewinnung, auch Knowledge Discovery genannt, wichtig. Ein Instrument zur Veranschaulichung der Unterschiede ist in Abbildung 2 ersichtlich. Die Wissenstreppe nach North zeigt in erster Ebene die Evolution von Zeichen zu Daten durch das Einhalten einer Syntax, von Daten zu Informationen durch die Vergabe einer Bedeutung und schließlich von Informationen zu Wissen durch die Vernetzung mit Kontext, Erfahrungen oder Erwartungen. Die Stufen vom Zeichen zur Information werden von North (2011, S. 35) auch als Informationsmanagement bezeichnet. Die weiteren Stufen, vom Generieren von Wissen über das richtige Handeln, das Erlangen von Kompetenz bis hin zur Sicherung eines Wettbewerbsvorteils, werden von North als Wissensmanagement bezeichnet.

Jacob (2012, S. 31) macht deutlich, dass das reine Sammeln von Daten in Datenbanken für ein informationsgestütztes Management nicht ausreichend ist. Vielmehr ist es notwendig, Konzepte

zum Wissensmanagement aufzustellen, um den von North (2011, S. 2) erwähnten Wettbewerbsvorteil zu erzielen.

Laut North (2011) können Wettbewerbsvorteile durch Wissen dann erzeugt werden, wenn es der Konkurrenz nicht einfach möglich ist, das Wissen eines Unternehmens zu kopieren. Das Wissen eines Unternehmens beschreibt er wie folgt:

„Wissen beinhaltet unter anderem Patente, Prozesse, Technologien, Fähigkeiten, Fertigkeiten und Erfahrungen der Mitarbeiter, Informationen über Kunden, Märkte und Lieferanten. Wissen entsteht in einem spezifischen Kontext und kann davon nicht losgelöst betrachtet werden, es ist an Personen gebunden und vielfach unbewusst.“ (S. 2)

Aus diesem Konzept ergeben sich nun folgende Fragen, die in den nächsten Abschnitten geklärt werden müssen:

- Wie lässt sich aus Daten Wissen generieren?
- Wie kann Wissen genutzt werden, um einen Wettbewerbsvorteil zu generieren?

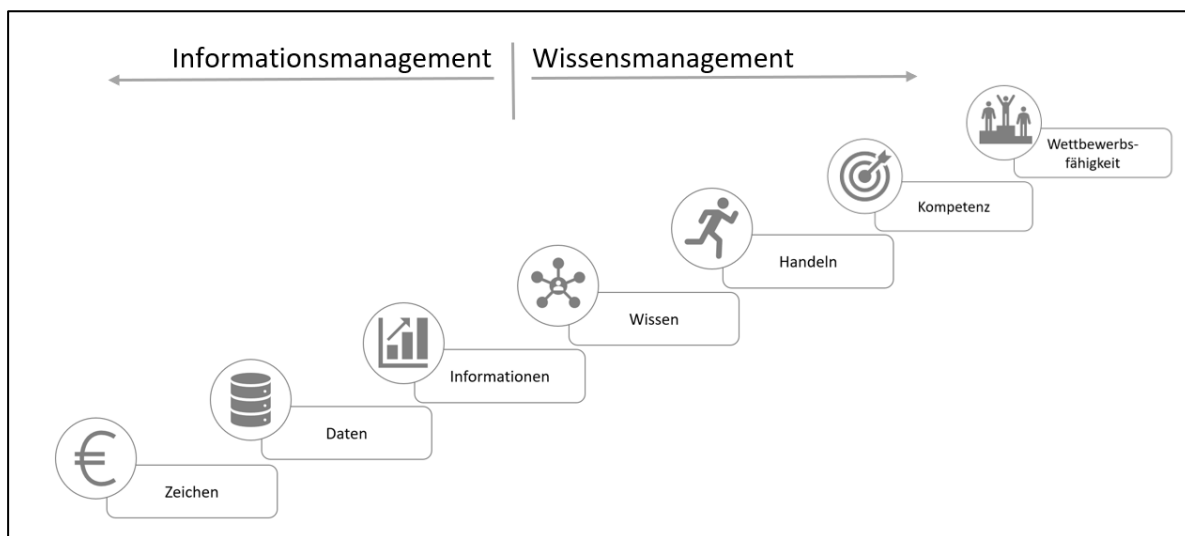


Abbildung 2: Wissenstreppe nach North (vgl. North, 2011, S. 35)

2.1.1 Knowledge Discovery und Wissensmanagement

Die Antwort auf die erste Frage liefert It. Sharafi (2013, S. 51) die Disziplin der Knowledge Discovery. Sie beschreibt das Gewinnen von Wissen aus großen Datenbeständen auf der Basis von einerseits statistischen und andererseits manuellen Analysen und Interpretationen.

Bereits 1996 erkennen Fayyad et al. (1996, S. 1), dass die gesammelten Datenmengen in Datenbanken immer rasanter ansteigen. Dabei geht es nicht nur um die Menge an Einträgen, sondern auch um die Breite an Attributen, welche gespeichert werden. Abgeleitet von der traditionellen menschlichen Analyse von Daten zur Informationsgewinnung sehen sie in Knowledge

Discovery in Databases (KDD) die Möglichkeit, die menschlichen Analysefähigkeiten zu erweitern und zumindest einen Teil der Analysearbeit zu automatisieren.

Folgendes Statement von Fayyad et al. (1996) bringt die Anforderung an den computerunterstützten Knowledge Discovery-Prozess auf den Punkt:

“Businesses use data to gain competitive advantage, increase efficiency, and provide more valuable services to customers.” (S.38)

Damit fordern sie Datenverarbeitung zur Effizienzsteigerung, zur Sicherung eines Wettbewerbsvorteils und zum Anbieten von noch wertvolleren Dienstleistungen. Besonders jene Branchen, die erst durch die Unterstützung von Datenbanksystemen imstande waren, sehr große Datenmengen aufzuzeichnen, profitieren nun von den computerunterstützten Analysearbeiten. Die Astrologie, das Marketing (Kundenverhaltensanalysen) und die Finanz- und Investitionsbranche (inklusive Betrugsüberwachung) sind einige von vielen Branchen, die bereits stark von KDD-Prozessen profitieren (Fayyad et al., 1996, S. 38 f.).

Im Rahmen der automatisierten Datenanalyse sind einige Bezeichnungen für die verschiedenen Vorgehensweisen entstanden. Neben Wissensextraktion, Informationsentdeckung und Informationsernte hat sich vor allem der Begriff Datenabbau (Data Mining) etabliert. Statistiker, Datenanalysten und Managementinformationssystem-Gemeinschaften verwendeten den Begriff Data Mining für ihre Tätigkeiten und sorgten dafür, dass er sich als Begriff für die Mustererkennung in Daten durchgesetzt hat (Fayyad et al., 1996, S. 39).

In Abbildung 3 ist ersichtlich, dass auch im Knowledge Discovery Prozess von Data Mining die Rede ist und es ein Teilbereich dieses Vorgehensmodells ist. Dieser Ablauf von interdisziplinären Tätigkeiten hat das Ziel, sogenanntes high-level knowledge aus low-level data zu gewinnen (Sharafi, 2013, S. 60). Der KDD-Prozess ist interaktiv und iterativ, besteht aus zahlreichen Schritten und kann nur durch wohlüberlegte Entscheidungen des Anwenders Ergebnisse liefern (Fayyad et al., 1996, S. 42).

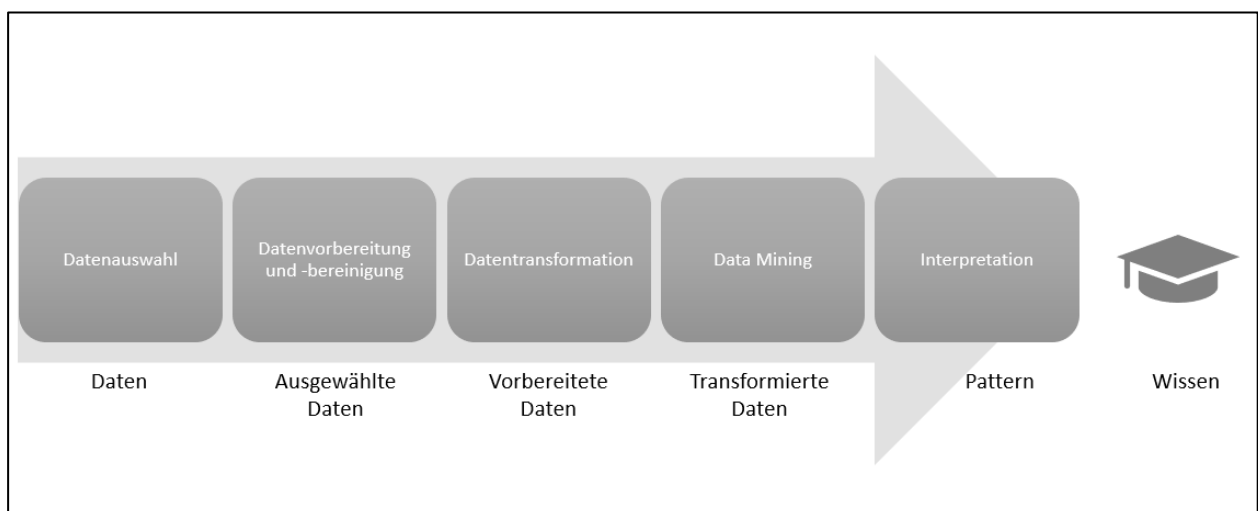


Abbildung 3: KDD-Prozess (vgl. Fayyad et al., 1996, S. 41)

Vor Ablauf des KDD-Prozesses ist es notwendig ein Verständnis für jene Fachdomäne zu entwickeln, auf die der Ablauf angewendet wird. Darauf folgt die Definition eines sogenannten Kundenziels, welches das Ergebnis des KDD-Prozesses darstellt. Im Anschluss erfolgt die Durchführung folgender Schritte lt. Fayyad et al. (1996, S. 42):

- **Datenauswahl:** Aus der Gesamtheit an Daten wird eine Datenmenge ausgewählt, die die vermeintlich relevanten Informationen zur Erreichung des Kundenziels beinhaltet. Soll beispielsweise das Kaufverhalten aller österreichischen KundInnen eines Unternehmens analysiert werden, so sind alle KundInnen des Unternehmens die Gesamtmenge und alle österreichischen KundInnen die Ziel-Datenmenge.
- **Datenvorverarbeitung:** Die Ziel-Datenmenge wird auf ihre Qualität geprüft. Dabei werden gegebenenfalls fehlerhafte Datensätze entfernt (Beispiel: Durch die Eingabe einer falschen Postleitzahl wurde eine Kundin als Österreicherin deklariert, lt. Ihrer UID-Nummer stammt sie aber aus Deutschland) oder mangelhafte Datensätze ergänzt (Beispiel: Von manchen KundInnen ist nur das Herkunftsland, aber keine Postleitzahl bekannt).
- **Datentransformation:** In diesem Schritt wird die Ziel-Datenmenge auf den kommenden Data Mining-Schritt vorbereitet. Je nach Kundenziel kann der Datensatz um berechnete Variablen erweitert werden (Beispiel: Berechnung des Alters aus dem Geburtsdatum). In Abstimmung mit dem folgenden Data Mining-Algorithmus können Variablen auch verdichtet werden (Beispiel: Tatsächlicher Jahresumsatz wird in Bereiche 0-10000, 10001-20000 und 20001-x eingeteilt). In dieser Phase werden auch Hypothesen aufgestellt, um die Ergebnisse des Data Minings gegentesten zu können.
- **Data Mining:** Anwendung eines ausgewählten Algorithmus zur Suche nach Mustern in der Datenmenge (siehe auch Abschnitt 2.2). Es sei gesagt, dass der Anwender durch die vorangegangenen Schritte die Ergebnisse maßgeblich beeinflussen kann.
- **Interpretation:** Erst durch diesen Schritt können die gefundenen Muster in Wissen umgewandelt werden. Die Ergebnisse werden durch die Erfahrungen und Interpretationen von Experten der Fachdomäne angereichert und werden somit zu Wissen. (Beispiel: Das Data Mining-Modell ergibt, dass sich die Variable Alter deutlich auf die Variable Jahresumsatz auswirkt – Interpretation: Je älter die KundInnen sind, desto mehr Umsatz bringen Sie dem Unternehmen.

Fayyad et al. (1996, S. 42) erwähnen, dass nach der Entdeckung auch die Visualisierung und Kommunikation sowie die Sicherung des Wissens von großer Bedeutung sind.

Die Antwort auf die zweite Frage liefert North (2011, S. 3), denn laut ihm muss es das Ziel eines Unternehmens sein, Wissen optimal zu nutzen, neues Wissen zu generieren und dieses in neue Produkte, Prozesse und Geschäftsfelder einfließen zu lassen. Außerdem sieht er Wissen auch als Kapital, das analog zum Finanzkapital den Wert eines Unternehmens nachhaltig steigert. Durch diese Ansätze beschreibt North den Begriff Wissensmanagement und formuliert zugleich, wie in Tabelle 1 ersichtlich, dessen Aufgaben und Ziele:

Aufgabe	Ziel
Wissensbeschaffung	Das relevante Wissen zur Abwicklung der Geschäftsprozesse steht jederzeit zur Verfügung
Wissensentwicklung	Neues Wissen wird stets durch interne- oder externe Prozesse weiterentwickelt.
Wissenstransfer	Vorhandenes Wissen wird optimal nutzbar gemacht.
Wissensaneignung	Die Lernfähigkeit eines Unternehmens und deren MitarbeiterInnen gewährleisten.
Wissensweiterentwicklung	Bestehendes Wissen wird stets aktuell gehalten und weiterentwickelt. Veraltetes Wissen entfällt.

Tabelle 1: Aufgaben und Ziele des Wissensmanagements (vgl. North, 2011, S. 3)

2.1.2 Data Science

Abgeleitet von den Ansätzen des Knowledge Discovery-Prozesses etablierte sich in den letzten Jahren der Begriff Data Science für die Tätigkeiten rund um die automatisierte Datenanalyse. Provost und Fawcett (2013, S. 4) definieren die Data Science als die Gesamtheit aller Prinzipien, Prozesse und Techniken zur Entdeckung von Phänomenen und Mustern durch die automatisierte Analyse von Daten. Das wohl wichtigste Prinzip dabei ist der Data Mining-Prozess und seine Phasen (Siehe Abschnitt 2.2.). Was sich im Vergleich zu bestehenden Ansätzen wie denen von Fayyad et al. (1996) jedoch erheblich geändert hat, ist die Menge der zu analysierenden Daten und die Rechenleistung, die Computern aktuell zur Datenverarbeitung zur Verfügung stehen (Provost & Fawcett, 2013, S. 4).

Provost und Fawcett (2013, S. 4) begründen die zunehmende Verbreitung dieser „neuen“ Disziplin unter anderem durch die bereits erwähnten leistungsstarken Computer, aber auch durch die bessere Vernetzung von professionellen Data Scientists durch das Internet und natürlich durch neu entwickelte Algorithmen zur Datenanalyse, die umfassendere und tiefere Analysen als bisher ermöglichen. Dorschel (2015, S. 103) sieht das Potenzial der Analyse und Auswertung großer Datenmengen in der Entscheidungsunterstützung (Decision Making). Außerdem eröffnet It. Dorschel die Verarbeitung von Vorhersageergebnissen durch weitere Data Mining-Methoden neue Anwendungsfälle der Data Science und spricht dabei von „Smart Data“:

„Die sinnvolle Aggregation der Daten zu Informationen, aus denen der Anwender Rückschlüsse ziehen kann, ob aufgrund der vorliegenden Datenlage Handlungen abzuleiten sind oder eben nicht, ist eine Kernfunktionalität, die mit Big Data Anwendungen verfolgt werden. [...] Damit werden aus Big Data weitere Daten produziert, die für die Entscheidungsunterstützung in der Produktionsplanung herangezogen werden können: Smart Data.“ (S. 103)

Nicht in jeder Auffassung muss Data Science eine Disziplin des Wissensentdeckens sein. Es gibt auch Ansätze, die in der Datenanalyse eine nüchterne „Übersetzungsarbeit“ sehen. So wie jene von Zhong (2007, S. 289), die besagt, dass durch Data Mining kein neues Wissen erzeugt, sondern lediglich Wissen aus einem – für Menschen – unverständlichen Format in ein verständliches Format transferiert wird. Ganz wichtig ist dabei, das Wissen durch die Transferierung nicht zu verändern, was lt. Zhong (2007, S. 295) durch das Data Driven Data Mining-Modell sichergestellt werden kann. In folgendem Statement bringt Zhong die Idee dieses Modells auf den Punkt:

“Thus, in order to keep the knowledge unchanged in a data mining process, we need to know some properties of the knowledge in data format, and use it to control the data mining process and keep it unchanged.” (S. 295)

Dies bedeutet, dass gewisse Eigenschaften des Wissens im „Datenformat“ bekannt sein müssen, um den Transfer ins „Symbolische“ – für Menschen verständliche – Format so durchführen zu können, dass keine Verfälschung stattfinden kann. Zhong legt den Fokus ganz stark auf die Daten und gibt Ihnen durch die Domäne einen Rahmen, dies wird in den folgenden drei Schritten des Data-Driven Data Mining-Modells dargestellt:

- Auswahl einer Wissenseseigenschaft, die im Datenformat und im symbolischen Format messbar ist, um Wissen aus Daten zu extrahieren.
- Messen dieser Wissenseseigenschaft im Datenformat und im symbolischen Format
- Nutzen dieser Eigenschaft, um den Data Mining-Prozess zu steuern. Diese Eigenschaft sollte nicht geändert werden.

Auch Zhong (2007, S. 301) sieht die Notwendigkeit eines automatisierten Analysetools, das Informationen in verwertbares Wissen umwandelt, um in weiterer Folge Entscheidungsträger zu unterstützen. In diesem Zusammenhang wird daher auch vom Data Driven Decision Making gesprochen.

Der Ansatz von Provost und Fawcett (2013, S. 5) sieht die Data Science hauptsächlich als Zuspielder im Entscheidungsfindungsprozess, verweist aber auch darauf, dass die notwendige Datenverwaltung und -verarbeitung weitere firmenweite, positive Effekte mit sich bringt. Ein Bild dazu liefert Abbildung 4. Dabei wird die Data Science selbst von den datenverarbeitenden Prozessen losgelöst. Provost und Fawcett sind obendrein der Ansicht, dass ein Teil des Entscheidungsfindungsprozesses komplett durch die Data Science automatisiert werden kann.

Beim Data-Driven Decision Making (DDD) handelt es sich also um das teilweise automatisierte Treffen von Entscheidungen, basierend auf Datenanalysen. Dabei wird grundsätzlich zwischen zwei Typen von Entscheidungen unterschieden:

- Entscheidungen, die auf „Entdeckungen“ in Daten basieren.
- Entscheidungen, die durch die Datenanalyse eine bessere Qualität erlangen.

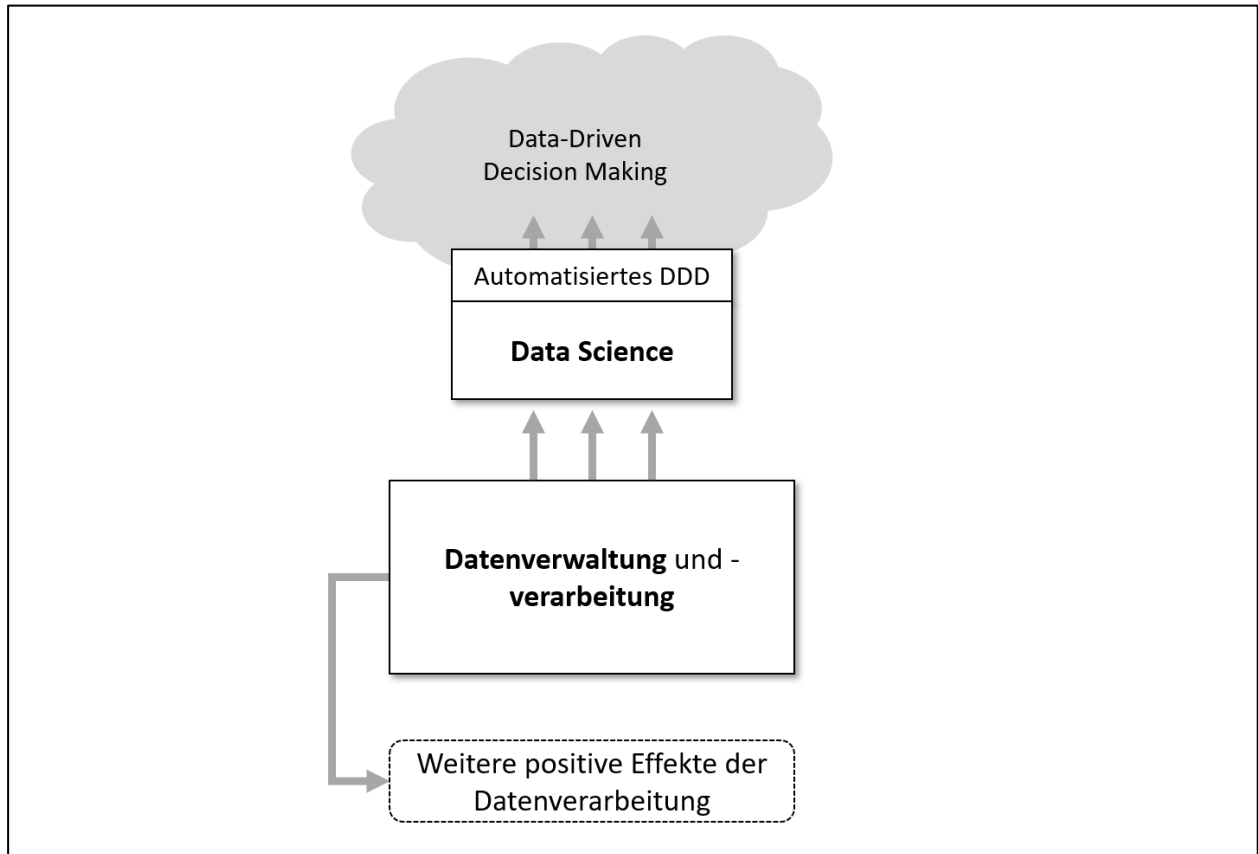


Abbildung 4: Data Science im Zusammenhang mit datenbasierenden Prozessen im Unternehmen (vgl. Provost & Fawcett, 2013, S. 5)

2.1.3 Fazit

Einen eindeutigen Namen für die Tätigkeiten rund um die Entdeckung von Mustern in Daten zur Entscheidungsunterstützung zu finden ist aufgrund der zahlreichen Theorien und Ansätze schwierig. Gleiches gilt bei dem Informationsgewinnungs-Prozess. Unabhängig davon, ob das Vorgehen Statistik, Knowledge Discovery oder Data Mining genannt wird, ist der grundlegende Ablauf aber immer derselbe. Vereinfacht gesagt, wird ein passendes Datenset gewählt und aufbereitet, über verschiedene Methoden und Rechenverfahren wird dann versucht Erkenntnisse zu gewinnen, die im letzten Schritt interpretiert und kommuniziert werden. Um aus dem gewonnenen Wissen tatsächlich einen Wettbewerbsvorteil zu gewinnen, ist es darüber hinaus notwendig, Wissensmanagement zu betreiben.

Ausgehend davon, dass Fayyad et al. schon 1996 einen detaillierten Knowledge Discovery-Prozess beschrieben haben, könnte man kritisch betrachtet anmerken, dass diese Disziplin lediglich unter dem neuen Namen Data Mining ihr Comeback erlebt. Den Kritikern kann jedoch entgegnet werden, dass es eine Vielzahl an Faktoren gibt, die sich im Vergleich zu 1996 so stark geändert haben, dass ein Vergleich der zwei Konzepte unpassend wirkt. Einige davon sind:

- Speicherkapazitäten von Datenbanken und Prozessorgeschwindigkeiten
- Speicherkapazitäten von Arbeitsspeichern
- Zugang zum Internet und den damit einhergehenden Informationen und Technologien

Die wachsenden Speicherkapazitäten von Datenbanken und der Zugriff auf Daten aus dem Internet haben zur Folge, dass die Menge und die Qualität der Daten deutlich angestiegen sind. Beide Faktoren haben maßgeblichen Einfluss auf den Output eines Informationsgewinnungsprozesses, da sie die Basis für jedes Ergebnis sind. Die gesteigerte Menge von Daten kann wiederum nur mit schnelleren Prozessoren und umfangreicheren Arbeitsspeichern bewältigt werden. Die Rolle des Zugangs zu Informationen und Technologien soll folgendes Beispiel (siehe Tabelle 2) anhand der gesammelten Daten von John C. McCallum (2019) zu Festplattenspeichergößen und -preisen liefern:

Jahr/ Monat	Speichermenge in Megabyte	Preis in \$	Preis in \$ pro Mega- byte	Megabyte pro 1 \$
1996/10	2000	276,00	0,14 \$	7,2 MB
2006/11	250000	80,97	0,00032 \$	3.087,6 MB
2016/10	3000000	87,96	0,000029 \$	34.106,4 MB
2019/10	8000000	149,99	0,000019 \$	53.336,9 MB

Tabelle 2: Darstellung von Festplattengrößen und -preisen (vgl. John C. McCallum, 2019)

Der Begriff Data Science kann also als Überbegriff für jene Tätigkeiten benutzt werden, die zur Entscheidungsfindung beitragen. Werden zur Entscheidungsfindung Data Mining-Algorithmen eingesetzt und dies zu einem gewissen Grad automatisiert, spricht man auch vom Data Driven Decision Making.

2.2 Data Mining

Auch wenn Data Mining (DM) nach Fayyad et al. (1996, S. 41) nur jene Phase des Knowledge Discovery-Prozesses ist, die versucht, Wissen aus Daten zu extrahieren, hat diese Phase beispielsweise durch die Auswahl des DM-Algorithmus so viel Auswirkungen auf den Gesamtprozess, dass in vielen Werken auch vom Data Mining-Prozess gesprochen wird. So definiert Aggarwal (2015, S. 3) Data Mining als das Sammeln, Bereinigen, Verarbeiten, Analysieren und Erzielen von nützlichen Erkenntnissen aus Daten.

Auch wenn die Begriffe Data Science und Data Mining häufig als Synonyme benutzt werden, so muss nach Provost und Fawcett (2013, S. 2) dennoch unterscheiden werden. Data Science ist eine Reihe von grundlegenden Prinzipien, die das Extrahieren von Wissen aus Daten leiten. Data Mining ist die Extraktion von Wissen aus Daten selbst, dafür werden Technologien eingesetzt, welche die Prinzipien der Data Science einbeziehen.

Dass es einen Bedarf nach Data Mining gibt, begründet Aggarwal nicht zuletzt dadurch, dass praktisch alle automatisierten Systeme, gewisse Formen von Daten erzeugen. Dies habe zu einer Datenflut geführt, die sich in der Größenordnung von Petabyte- oder Exabyte bewegt. Aggarwal (2015, S. 3 f.) nennt auch Beispiele für die größten Datenproduzenten und deren Einsatzmöglichkeiten für DM-Algorithmen:

- World Wide Web (WWW): Mit einer Anzahl an veröffentlichten Dokumenten in Milliardenhöhe ist das WWW nicht nur einer der größten Datenlieferanten, sondern durch die Vielzahl an Userzugriffen, die protokolliert und zu Kundenverhaltensprofilen zusammengefasst werden, ist es auch einer der größten Datenproduzenten. DM-Algorithmen werden hier häufig dazu eingesetzt, um Muster zwischen den Zugriffsprofilen und den zugegriffenen Dokumenten zu erkennen.
- Finanzinteraktionen: Alltägliche Dinge wie die Benutzung einer Bankomat- oder Kreditkarte zur Bezahlung oder zum Geldabheben erzeugen automatisiert Daten. Gerade in der Finanzbranche wird viel mit DM-Algorithmen zur Betrugsbekämpfung gearbeitet.
- Benutzerinteraktionen: Darunter versteht man verschiedene Arten der zwischenmenschlichen Kommunikation wie Chat oder Telefon. So erzeugt die Verwendung eines Telefons typischerweise eine Aufzeichnung beim Netzanbieter, die die Dauer des Telefonats und die Standorte der Telefonierenden aufzeichnet. Solche Protokolle werden häufig zur Unterstützung der Ressourcen- und Preisplanung analysiert.
- Sensortechnologie und Internet der Dinge: Die Entwicklung von kostengünstigen und tragbaren Sensoren, Smartphones und anderen intelligenten Geräten, die untereinander kommunizieren können, fördert die Produktion von sensorgenerierten Daten. Je nach Fachdomäne können die gemessenen Daten mittels DM-Algorithmen analysiert werden.

Bevor jedoch an die Auswahl des DM-Algorithmus gedacht werden kann, muss nach Provost und Fawcett (2013, S. 24) klar sein, ob eine Aufgabenstellung den Kategorien supervised (überwachtes) oder unsupervised (unüberwachtes) learning zuordenbar ist. Beim überwachten Lernen werden Ergebnisse nach einer bestimmten Vorgabe gesucht. Eine mögliche Fragestellung wäre: „Gibt es unter unseren KundInnen eine bestimmte Gruppe, die eine erhöhte Chance hat zur Konkurrenz zu wechseln?“, während eine mögliche Fragestellung des unüberwachten Lernens folgende wäre: „Gibt es bestimmte Gruppen unter unseren KundInnen?“. Da die Begriffe supervised learning für überwachtes Lernen und unsupervised learning für unüberwachtes Lernen etabliert sind, werden in dieser Arbeit fortan auch diese Begriffe genutzt.

Provost und Fawcett (2013, S. 25 f.) merken außerdem an, dass unabhängig davon, ob es sich um supervised- oder unsupervised learning handelt, beim Data Mining eine weitere Unterscheidung zu treffen ist. Werden aufgezeichnete Daten analysiert, um Muster zu finden und Modelle zu erstellen oder werden bestehende Modelle angewandt, um Vorhersagen zu neuen Datensätzen zu treffen. Der Unterschied liegt demnach im Ergebnis. Während der Datenverarbeitungsprozess (das Mining) ein Modell als Ergebnis liefert, hat die Anwendung von Modellen eine Vorhersage für einen bestimmten Datensatz zum Ergebnis.

Letztendlich ist Data Mining ein Handwerk und wie bei vielen Handwerken gibt es einen genau definierten Prozess, der dazu beitragen kann, die Wahrscheinlichkeit eines erfolgreichen Ergebnisses zu erhöhen (Provost & Fawcett, 2013, S. 41). Den passenden DM-Algorithmus sowie das passende Vorgehensmodell zu finden, ist Inhalt des folgenden Abschnitts.

2.2.1 Das CRISP-DM-Vorgehensmodell

„Systematisches Data Mining suggeriert, dass es ein System des Data Mining gibt, dem man in irgendeiner Art und Weise folgen kann. In einem System sind Elemente enthalten, die miteinander in Beziehung stehen und miteinander interagieren, um ein gesetztes Ziel zu erreichen.“ (Jannaschk & Thalheim, 2017, S. 12)

Laut Jannaschk & Thalheim (2017, S. 12) sind die zwei gängigsten Vorgehensmodelle im Data Mining einerseits der in Abschnitt 2.1.1. erwähnte KDD-Prozess von Fayyad et al. (1996) und andererseits der Cross Industries Standard Process for Data Mining (CRISP-DM) von Chapman et al. (2000). Der KDD-Prozess legt einen starken Fokus auf die Daten, die im Zuge des Prozesses verschiedene Transformationsschritte durchlaufen. Der Prozess läuft daher recht wissenschaftlich ab. Im Gegensatz dazu wirkt der CRISP-DM-Prozess wie für das Management gemacht, der Fokus ist klar auf das Ziel des Projekts gerichtet. Die kaufmännischen Beschränkungen sind eng mit dem Prozessablauf verbunden. Im Folgenden werden die Phasen des CRISP-DM-Prozesses wie in Abbildung 5 ersichtlich dargestellt:

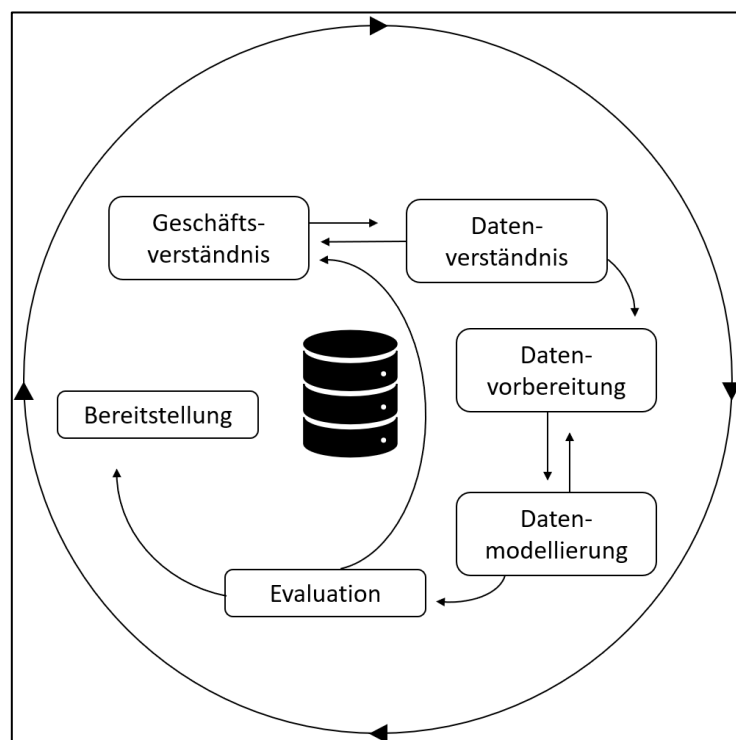


Abbildung 5: Das CRISP-DM-Referenzmodell (vgl. Chapman et al., 2000, S. 13)

- **Geschäftsverständnis:** Diese erste Phase konzentriert sich auf das Verständnis der Projektziele und -anforderungen aus betriebswirtschaftlicher Sicht, um dieses Wissen dann in ein Data Mining-Problem zu verwandeln und einen vorläufigen Plan zur Zielerreichung zu erstellen.
- **Datenverständnis:** Die Phase des Datenverständnisses beginnt mit einer ersten Datenerfassung, gefolgt von Aktivitäten, um sich mit den Daten vertraut zu machen. Es gilt Datenqualitätsprobleme zu identifizieren, erste Einblicke in die Daten zu erlangen oder interessante Teilmengen zu entdecken, um Hypothesen über versteckte Informationen zu bilden.
- **Datenvorbereitung:** Die Datenvorbereitungsphase umfasst alle Aktivitäten zur Erstellung des endgültigen Datensatzes (Daten, die in die Modellierungswerkzeuge eingespeist werden) aus den ursprünglichen Rohdaten. Aufgaben der Datenvorbereitung werden wahrscheinlich mehrmals und nicht in einer vorgeschriebenen Reihenfolge durchgeführt. Aufgaben umfassen Tabellen-, Datensatz- und Attributauswahl sowie Transformation und Bereinigung von Daten für Modellierungswerkzeuge.
- **Datenmodellierung:** In dieser Phase werden verschiedene Modellierungstechniken ausgewählt, angewendet und deren Parameter auf die optimalen Werte kalibriert. Typischerweise gibt es mehrere Techniken für einen Data Mining-Problemtyp. Einige Techniken haben spezielle Anforderungen an das Format von Dateien, daher ist häufig ein Rückschritt in die Datenvorbereitungsphase erforderlich.
- **Evaluation:** In dieser Phase des Projekts wurden bereits ein- oder mehrere Modelle erstellt, die aus Sicht der Datenanalyse qualitativ hochwertig sind. Bevor das Modell endgültig bereitgestellt wird, ist es wichtig das Modell in Hinblick auf die Projektziele gründlich zu bewerten und die ausgeführten Schritte zu überprüfen. Es gilt festzustellen, ob es Geschäftsprobleme gibt, welche im Modell nicht ausreichend berücksichtigt werden. Am Ende dieser Phase muss die Entscheidung getroffen werden, ob das gewonnene Data Mining-Modell als Ergebnis verwendet werden soll.
- **Auslieferung:** Die Erstellung des Modells ist in der Regel nicht das Ende eines Projekts. Auch wenn der Zweck der Modelle ist, Wissen aus den Daten zu gewinnen, so muss das gewonnene Wissen erst noch organisiert und später so präsentiert werden, dass es der Projektauftraggeber auch nutzen kann. Oft geht es darum „lebende“ Modelle für den Entscheidungsprozess eines Unternehmens zu entwickeln, beispielsweise die Echtzeitpersonalisierung einer Website oder Prognosewerte aus der Marketing-Datenbank zu erheben. Je nach Anforderung kann die Bereitstellungsphase mit dem Generieren eines Berichts enden, bis hin zur Implementierung eines wiederholbaren DM-Prozesses innerhalb eines Unternehmens. In vielen Fällen ist es nicht der Datenanalytiker, der mit den Ergebnissen arbeiten muss, daher ist es bei der Bereitstellung wichtig, alle Voraussetzungen für die Nutzung des DM-Modells zu schaffen.

2.2.2 Aufgaben von Data Mining-Algorithmen

Trotz der großen Anzahl spezifischer DM-Algorithmen, die im Laufe der Jahre entwickelt wurden, gibt es nur eine Handvoll grundlegend unterschiedlicher Arten von Aufgaben, mit denen sich diese Algorithmen befassen (Provost & Fawcett, 2013, S. 20). Laut Ng & Soo (2018, S. 7) hängt die Auswahl des passenden Algorithmus von den Aufgaben ab, die eine Problemstellung mit sich bringt. Die verschiedenen Aufgaben können grundsätzlich in drei Kategorien eingeteilt werden, für die sich bestimmte Algorithmen besonders gut eignen. Tabelle 3 liefert einige Beispiele dafür:

Kategorien	Beispiele für Algorithmen
Unüberwachtes Lernen (unsupervised learning)	k-Means-Clustering, Hauptkomponentenanalyse, Assoziationsanalyse, Soziale Netzwerkanalyse
Überwachtes Lernen (supervised learning)	Regressionsanalyse, k-nearest neighbour, Support-Vektor-Machine, Entscheidungsbäume, Random Forests, Neuronale Netze
Bestärkendes Lernen (reinforcement learning)	A/B-Test, Abnehmendes-Epsilon-Strategie

Tabelle 3: Kategorien von Algorithmen (Ng & Soo, 2018, S. 8)

Eine detaillierte Beschreibung der Kategorien liefern Ng & Soo (2018, S. 8-11) im Folgenden:

- Unsupervised Learning: Wird dazu genutzt, um versteckte Muster in einem Datenset zu entdecken. Diese Kategorie wird unsupervised learning genannt, da vor Ausführung nicht vorgegeben wird, nach welchen Mustern tatsächlich gesucht wird. Das Ergebnis wird also nicht vom Anwender, sondern vom Algorithmus bestimmt. Die Validierung von Ergebnissen aus unsupervised learning Algorithmen findet indirekt statt. Es werden beispielsweise die gefundenen Cluster mit bekannten und sinnvollen Eigenschaften der Datensätze verglichen. Aufgabe dieser Kategorie: „Zeige Muster, die im vorliegenden Datenset verborgen sind.“
- Supervised Learning: Umfasst jene Algorithmen, mit denen Vorhersagen, basierend auf historischen Daten, getroffen werden sollen. Supervised bedeutet also, dass die Vorhersagen auf vorgegebenen Mustern basieren. Testbar sind die Ergebnisse dieser Algorithmen direkt, indem entweder mit Einträgen aus dem Trainings-Datenset oder mit neuen Messungen verglichen wird. Innerhalb des supervised learnings wird oft zwischen Klassifizierungsproblemen und Regressionsproblemen unterschieden. Aufgabe dieser Kategorie: „Erstelle Prognosen aus den Mustern, die im vorliegenden Datenset verborgen sind.“
- Reinforcement Learning: Algorithmen dieser Kategorie verbessern ihre Modelle ständig, indem sie ihre Ergebnisse wieder direkt in den Algorithmus einfließen lassen. Aufgabe

dieser Kategorie: „Erstelle Prognosen aus den Mustern, die im vorliegenden Datenset verborgen sind und verbessere diese Vorhersagen durch die Ergebnisse.“

Eine Ergänzung zum reinforcement learning liefert Gentsch (2018, S. 38 f.). Beim reinforcement learning liegt zu Beginn kein optimaler Lösungsweg vor. Es ist Aufgabe des Algorithmus, diesen durch Versuch und Irrtum (trial and error) zu ermitteln. Gute Ansätze werden mit „Belohnungen“ und schlechte Ansätze mit „Bestrafungen“ bewertet, wodurch der Algorithmus in der Lage ist, die Umwelteinflüsse in der Entscheidungsfindung einfließen zu lassen und darauf zu reagieren.

„Das verstärkende Lernen gehört zum Gebiet des Exploration Learning, bei dem ein System autonom, also abgesehen von den richtungsweisenden Belohnungen und Bestrafungen, eigene Lösungen finden muss, die sich von den von Menschen erdachten Lösungen deutlich unterscheiden können. Besonders viel Aufmerksamkeit erhielt das Reinforcement Learning nach dem Sieg von Google DeepMinds AlphaGo über Lee Sedol. Das eingesetzte System nutzte u. a. Deep Reinforcement Learning, um in simulierten Partien gegen sich selbst seine Strategie zu verbessern.“ (S. 39)

Es lohnt sich daher, die Aufgabenstellung im Vorfeld genau zu definieren, um den passenden Algorithmus für die Aufgabenstellung zu finden. Provost und Fawcett (2013, S. 20-22) liefern im Folgenden eine gute Übersicht über die Aufgaben, die durch Data Mining-Algorithmen gelöst werden können:

- **Klassifikation:** Klassifikation und Klassenwahrscheinlichkeitsschätzung versuchen, für jeden Eintrag in einem Datenset vorherzusagen, zu welcher Klasse dieser Eintrag gehört. In der Regel schließen sich die Klassen gegenseitig aus. Für eine Klassifizierungsaufgabe erstellt ein DM-Algorithmus ein Modell, das bei einem neuen Datensatz bestimmt, zu welcher Klasse dieser gehört. Eine ähnliche Aufgabe ist das Scoring (Klassenwahrscheinlichkeitsschätzung). Ein Scoringmodell, das auf einen Datensatz angewendet wird, ergibt anstelle einer Klassenvorhersage eine Punktzahl, die die Wahrscheinlichkeiten der Zugehörigkeit zu den einzelnen Klassen darstellt.
- **Regression:** Eine Regression versucht, für jeden Datensatz den numerischen Wert einer Variablen für diesen Eintrag zu schätzen oder vorherzusagen. Ein Beispiel für eine Regressionsfrage wäre: "Wie oft wird ein bestimmter Kunde einen Service nutzen?" Die Eigenschaft, die hier vorhergesagt werden muss, ist die Dienstnutzung. Ein Modell könnte erstellt werden, indem andere, ähnliche Personen in der Gruppe und ihre historische Nutzung betrachtet werden. Eine DM-Algorithmus, basierend auf Regression, erzeugt ein Modell, das anhand eines Datensatzes den Wert der für diesen Eintrag spezifischen Variablen schätzt. Regression hängt zwar mit Klassifikation zusammen, vereinfacht sagt die Klassifikation voraus, ob etwas passieren wird, während die Regression voraussagt, wie viel etwas passieren wird.
- **Ähnlichkeitsabgleich (similarity matching):** Der Ähnlichkeitsabgleich versucht vergleichbare Datensätze zu identifizieren und in weiterer Folge zu analysieren. Dieses Vorgehen kann direkt verwendet werden, um ähnliche Entitäten in einem Datenset zu finden. Sei-

ne Anwendung könnte dieses Vorgehen bei Firmen finden, die daran interessiert sind, potenzielle Kunden zu finden, die ihren besten Geschäftskunden ähneln, um ihre Vertriebsmitarbeiter auf diese zu konzentrieren. Sie verwenden Ähnlichkeitsabgleiche auf der Grundlage von firmografischen Daten, die Merkmale der Unternehmen beschreiben. Der Ähnlichkeitsabgleich ist die Grundlage für einen der beliebtesten DM-Algorithmen zur Abgabe von Produktempfehlungen. Ähnlichkeitsmesser liegen bestimmten Lösungen für andere Data Mining-Aufgaben wie Klassifizierung, Regression und Clustering zugrunde.

- Clustering: Clustering versucht Datensätze in einem Datenset aufgrund ihrer Ähnlichkeit zu gruppieren, jedoch nicht aufgrund eines bestimmten Zwecks. Ein Beispiel für eine Clustering-Frage könnte lauten: "Bilden unsere Kunden natürliche Gruppen oder Segmente?" Clustering ist hilfreich bei der vorläufigen Untersuchung von Domänen, um festzustellen, welche natürlichen Gruppen existieren, da diese Gruppen wiederum andere Data Mining-Aufgaben oder -Ansätze vorschlagen können. Clustering wird auch als Input für Entscheidungsprozesse verwendet, die sich auf folgende Fragen konzentrieren: „Welche Produkte sollten wir anbieten oder entwickeln?“ „Wie sollten unsere Kundenbetreuungsteams strukturiert sein?“
- Koexistenzgruppierung (co-occurrence grouping): Bei dieser Art der Gruppierung wird versucht, Verknüpfungen zwischen Entitäten, basierend auf deren gemeinsamen Transaktionen, zu bilden. Ein Beispiel für eine Frage wäre: „Welche Artikel werden häufig zusammen gekauft?“ Während die Ähnlichkeit von Objekten anhand der Objektattribute überprüft wird, berücksichtigt die sogenannte Koexistenzgruppierung die Ähnlichkeit von Objekten anhand ihres gemeinsamen Auftretens in Übergängen. Das gleichzeitige Auftreten von Produkten bei Einkäufen ist eine übliche Art der Gruppierung, die als Warenkorbanalyse bezeichnet wird. Einige Empfehlungssysteme führen auch eine Art Affinitätsgruppierung durch, indem sie beispielsweise Bücher finden, die häufig von denselben Personen gekauft werden ("Personen, die X gekauft haben, haben auch Y gekauft."). Das Ergebnis der Koexistenzgruppierung ist eine Beschreibung der Elemente, die zusammen auftreten. Zu diesen Beschreibungen gehören in der Regel statistische Angaben über die Häufigkeit des gemeinsamen Auftretens und eine Einschätzung, wie überraschend dieses ist.
- Profilerstellung (Profiling): Bei der Profilerstellung wird versucht, das typische Verhalten eines Individuums, einer Gruppe oder einer gesamten Population zu charakterisieren. Ein Beispiel für eine Frage zur Profilerstellung wäre: "Wie verhält sich die typische Handynutzung dieses Kundensegments?" Verhalten kann manchmal nicht einfach beschrieben werden. Verhalten kann allgemein über eine gesamte Bevölkerung oder über kleinere Gruppen bis hin zu einzelnen Individuen beschrieben werden. Die Profilerstellung wird häufig dazu verwendet, Verhaltensnormen für Anomalieerkennung-Anwendungen festzulegen, z. B. Betrugserkennung und Überwachung auf Eingriffe in Computersystemen.

- **Verbindungsvorhersage (Link prediction):** Die Verbindungsvorhersage versucht Verbindungen zwischen Datenelementen vorherzusagen, indem normalerweise vorgeschlagen wird, dass eine Verbindung vorhanden sein sollte, und auch die Stärke der Verbindung eingeschätzt wird. Die Linkvorhersage ist in sozialen Netzwerken weit verbreitet: "Da Sie und XY 10 Freunde teilen, möchten Sie vielleicht XYs Freund sein?" Die Verbindungsvorhersage kann auch die Stärke einer Verbindung schätzen. Wenn Sie beispielsweise KundInnen Filme empfehlen, können Sie sich ein Diagramm zwischen den KundInnen und den Filmen vorstellen, die sie gesehen oder in Beziehung gesetzt haben. Innerhalb des Diagramms suchen wir nach Verbindungen, die nicht zwischen KundInnen und Filmen bestehen, von denen wir jedoch vorhersagen, dass sie existieren und stark sein sollten. Diese Verbindungen bilden die Grundlage für Empfehlungen.
- **Datenreduktion (data reduction):** Bei der Datenreduktion wird versucht, eine große Datenmenge durch eine kleinere Datenmenge zu ersetzen, die den Großteil der relevanten Informationen aus der größeren Datenmenge enthält. Der kleinere Datensatz ist möglicherweise einfacher zu handhaben oder zu verarbeiten. Darüber hinaus kann der kleinere Datensatz die Informationen besser offenbaren. Beispielsweise kann ein umfangreicher Datensatz mit Voreinstellungen zum Anzeigen von Filmen für Verbraucher auf einen viel kleineren Datensatz reduziert werden, der die in den Anzeigedaten latente Vorlieben des Verbrauchers wiedergibt. Datenreduktion beinhaltet normalerweise einen Informationsverlust, es ist also wichtig, einen vertretbaren Kompromiss aus Informationsverlust und Informationsgewinn zu finden.
- **Kausalmodellierung (causal modeling):** Kausalmodelle helfen uns zu verstehen, welche Ereignisse oder Handlungen andere tatsächlich beeinflussen. Man nehme zum Beispiel an, dass mithilfe von Vorhersagemodellen Werbung auf die VerbraucherInnen ausgerichtet wird. Es wird festgestellt, dass die anvisierten Verbraucher tatsächlich zu einer höheren Rate einkaufen, nachdem sie anvisiert worden sind. Kaufen die VerbraucherInnen aufgrund der Werbung oder haben die Vorhersagemodelle einfach gute Arbeit geleistet, um die VerbraucherInnen zu identifizieren, die sowieso gekauft hätten? Zu den Techniken für die Kausalmodellierung gehören jene, die eine erhebliche Investition in Daten beinhalten. Dazu zählen sogenannte randomisierte kontrollierte Experimente ("A/B-Tests") sowie ausgeklügelte Methoden, um aus Beobachtungsdaten kausale Schlussfolgerungen zu ziehen. Beide Methoden können als "kontrafaktische" Analyse angesehen werden. Sie versuchen zu verstehen, was genau der Unterschied zwischen den Situationen ist, in denen das Beobachtungsereignis eintreten ist und den Situationen, in welchen dieses Ereignis nicht eingetreten ist.

Die Auswahl des passenden Algorithmus findet nicht nur aufgrund der Aufgabenstellung per se statt, sondern kann auch von den verwendeten Datentypen und den geforderten Ergebnissen abhängig sein (Jannaschk & Thalheim, 2017, S. 11).

2.2.3 Fazit

Bei der Durchführung eines DM-Projekts ist es also wichtig, ein geeignetes System/ein geeignetes Vorgehensmodell auszuwählen, um auf die verschiedenen Einflüsse (Datenmenge, Datenqualität, Auftraggeber, Budget, Aufgaben) korrekt reagieren zu können. Im Nachfolgenden werden nach Jannaschk und Thalheim (2017, S. 18-20) die Stärken, Schwächen, Chancen und Risiken der beiden vorgestellten Vorgehensmodelle zusammenfassend dargestellt:

Das KDD Modell

- Stärken: Schritte sind abstrakt angeführt, somit hat der/die AnwenderIn viel Spielraum für die jeweiligen Maßnahmen.
- Schwächen: Fehlende Einbindung des Fachwissens bei der Datenanalyse. Erkenntnisse aus der Datenanalyse können daher oft nicht zur Lösung der Fragestellung beitragen.
- Schwächen: Im Prozessmodell werden Beispiele für die Anwendung der Algorithmen gegeben, jedoch keine Beispiele für die Evaluierung der Ergebnisse.
- Chancen: Aufgrund der abstrakt angegebenen Transformationsschritte können die Methoden entsprechend gut in eine Umsetzung eingebunden werden. In Bezug auf die einzelnen Methoden ist es außerdem möglich, dass sie jeweils mehrere Transformationsschritte abdecken.
- Risiken: Der starke Fokus auf die Daten hat zur Folge, dass nicht klar ist, in welcher Beziehung die gewonnenen Informationen zur Fragestellung stehen.
- Risiken: Im KDD ist ein Rücksprung im Prozessablauf jederzeit möglich. Dadurch kann im Prozessablauf auch das Prozessziel geändert werden, was zur Folge haben kann, dass das Prozessende eines Ablaufs mit dem Prozessbeginn eines neuen Ablaufs verschimmt. Außerdem besteht die Gefahr, dass der Prozess, mangels Abbruchkriterien, in eine Endlosschleife gerät.

Das CRISP-DM Modell

- Stärken: Die Kapselung von Zielstellung und Datendefinition sowie Datenverarbeitung und Modellentwicklung.
- Stärken: Zu Beginn des DM-Prozesses werden wirtschaftliche Abbruchkriterien definiert. Diese basieren auf dem Ziel des Prozesses und dem dafür festgelegten Budget.
- Stärken: Die Definition des Ziels findet vor der Datendefinition statt, was zur Folge hat, dass die vorliegenden Daten mit Vorwissen angereichert werden und zusätzlich durch fremde Datenquellen erweitert werden können.
- Schwächen: Dokumentationen finden immer nur nach den einzelnen Arbeitsschritten statt. Eine Aufzeichnung über die Auswirkungen einzelner Transformationen ist daher nicht vorgesehen.

- Schwächen: Gleich wie beim KDD werden Beispiele für die Anwendung von Algorithmen gegeben, jedoch keine Beispiele für Evaluierungsmöglichkeiten der Ergebnisse.
- Chancen: Dem Anwender ist die Ausgestaltung der Teilschritte selbst überlassen, was eine Anpassung an die jeweilige Aufgabenstellung ermöglicht.
- Risiken: Fragestellungen, die während des Analyseablaufs auftreten, dürfen bei strenger Einhaltung des Prozesses nicht bearbeitet werden. Wenn diese Fragestellungen nicht in den Teilzielen zur Erreichung des Gesamtzieles definiert sind, aber relevant für den begonnenen Prozess sind, muss der aktuelle Prozess abgebrochen und nach neuer Definition der Teilziele neu gestartet werden.

Unter Einhaltung eines Vorgehensmodells lassen sich die Auswahl der Daten, die Vorbereitungen, die Auswahl der Algorithmen und deren Anwendung sowie Auswertung systematisch durchführen. Wie in Abschnitt 2.2.2 erwähnt, lohnt es sich die Aufgaben im Vorfeld genau zu definieren, um dann den passenden DM-Algorithmus auswählen zu können. Man muss sich bewusst sein, dass es sich dabei um ein Wechselspiel der Datenvorbereitung und der Datenmodellierung handeln kann, welches oftmals durch trial and error geprägt ist. Weitere Ausführungen zum CRISP-DM-Prozess und zur Aufbereitung einer Aufgabenstellung sowie Auswahl eines DM-Algorithmus findet in Abschnitt 3.2, der Fallstudie, statt.

2.3 Softwaresupport

Folgender Abschnitt beschäftigt sich mit der Fachdomäne dieser Arbeit, dem Softwaresupport, welcher oft auch Kundendienst genannt wird. Neben einer kurzen Einführung in die Domäne wird dargestellt, warum Data Mining in dieser Fachdomäne notwendig ist und welche Einsatzgebiete es dafür geben kann. Für das experimental Setup wird der theoretische Status quo im Hinblick auf Organisationsstrukturen und Vorgehensweisen bezüglich Personaleinsatz sowie Kennzahlenmessungen definiert. Abschließend werden mögliche Aufgabenstellungen identifiziert, die mittels Data Mining-Algorithmen gelöst werden können. Das Ergebnis dessen sind die möglichen Einsatzgebiete für Data Mining im Support.

2.3.1 Supportstrukturen

Support, in Deutsch Unterstützung, beschreibt jene Tätigkeiten ganzer Abteilungen in Unternehmen, die den KundInnen die optimale Nutzung ihrer eingesetzten Produkte ermöglichen. Im Bereich der Softwareentwicklung ist die Aufgabe des Supports daher, die optimale Nutzung der angebotenen Software zu gewährleisten. Anhand des Leistungsangebots des Softwareherstellers BMD Systemhaus GesmbH umfasst der Begriff Support folgende Tätigkeiten (BMD Systemhaus GesmbH, 2019):

- Hotline
- Ticketsystem
- Checklisten

- Selbsthilfe (FAQ, Lernvideos, Produktdokumentationen)
- Vor-Ort-Schulungen
- Fernwartungsschulungen und Wartung

Nach Knapp (2010, S. 36) spielt die Hotline, im Englischen auch Service Desk oder Help Desk genannt, eine entscheidende Rolle in Hinblick auf die Kundenzufriedenheit, da sie oft die einzige Kontaktmöglichkeit der KundInnen ist. Angetrieben von einem klaren Ziel und versorgt mit genügend Ressourcen kann die Hotline für eine positive KundInnenwahrnehmung sorgen und so auch den einen oder anderen Mangel am Produkt oder an der Organisation wettmachen. Umgekehrt kann ein mangelnder Service Desk auch die effektivsten Softwareanbieter schlecht aussehen lassen. Die komplexen Anforderungen an den Kundendienst fordern eine breit aufgestellte und in mehrere Ebenen gegliederte Organisation. Die wohl bekannteste und meist genutzte Organisationsform im Support ist das sogenannte multi-level Support Modell, welches grundsätzlich aus First-, Second- und Third Level-Support besteht (siehe Abbildung 6).

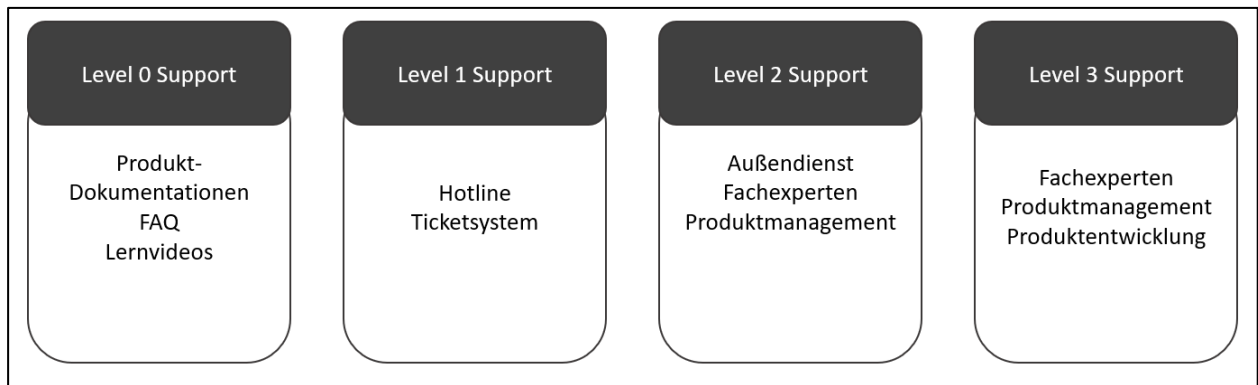


Abbildung 6: multi-level Support Modell angereichert mit dem Supportangebot der Firma BMD Systemhaus GesmbH (BMD Systemhaus GesmbH, 2019; Knapp, 2010, S. 37)

Das oberste Ziel in einer multi-level-Supportorganisation ist nach Knapp (2010, S. 37), dass möglichst viele Anfragen bereits auf Level 0 und Level 1 gelöst werden können und möglichst wenige bis zu Level 3 gelangen. Denn jede Anfrage, die bereits auf Level 0 gelöst werden kann, verursacht nur das Minimum an Kosten und jede Anfrage, die bis zu Level 3 gelangt, verursacht hingegen das Maximum an Kosten. Die einzelnen Supportlevel werden wie folgt spezifiziert:

- Level 0 Support: Als Level 0 Support werden alle Angebote einer IT-Organisation verstanden, die KundInnen bei der eigenständigen Lösung von Problemen unterstützen. Darunter befinden sich unter anderem Produktdokumentationen sowie häufig gestellte Fragen und deren Antworten (FAQ).
- Level 1 Support: Als Level 1 Support, auch als First Level Support bezeichnet, versteht sich jene Ansprechstation, an die KundInnen ihre sogenannten Incidents melden. An dieser Stelle werden auch die eingehenden Tickets erstbearbeitet.

- Level 2 Support: Kann ein Incident nicht direkt an der Hotline gelöst werden, eskaliert er und benötigt die Bearbeitung des Second Level Supports. Die Lösung könnte beispielsweise durch einen Vorort-Termin von einer Fachexpertin realisiert werden.
- Level 3 Support: Wenn der eskalierte Incident auch durch die FachexpertInnen nicht gelöst werden kann, ist der Third Level Support die letzte Rückfallebene. Die Rolle des Third Level Support wird oft von MitarbeiterInnen eingenommen, die sehr nahe mit der Produktentwicklung zusammenarbeiten bzw. selbst in der Produktentwicklung arbeiten.

Nicht zuletzt aufgrund der steigenden Anforderungen an IT-Organisationen haben sich gewisse IT Service Management (ITSM) Standards wie ITIL (IT Infrastructure Library) etabliert (Fröschle, 2017, S. 171). Ziel des ITSM ist es, IT-Services wie Web- oder Desktopanwendungen, Netzwerke, Daten oder Vernetzung zuerst zu planen, sie später umzusetzen, auszuliefern und in weiterer Folge sicherzustellen, dass auch die Qualität des IT-Services den Vereinbarungen entsprechend ist (Mitrakis, 2019, S. 1). Ein überspitztes Statement zum Software Engineering und dem Support liefern Beyer, Jones, Petoff und Murphy (2016):

“Software engineering has this in common with having children: the labour before the birth is painful and difficult, but the labour after the birth is where you actually spend most of your effort“ (S. 9)

Mit dem ITSM-Standard ITIL gehen auch neue Begrifflichkeiten und Rollen im Support einher. Der klassische First Level Support, der Störungen des Serviceanwenders entgegennimmt, klassifiziert, dokumentiert und priorisiert, wird zum Incidentmanager. Anhand definierter Service Level Agreements (SLA) bearbeiten die Incidentmanagerinnen die Anfragen und leiten sie gegebenenfalls an das Problemmanagement, vormals Second Level Support, weiter. Ist für die Lösung des Problems eine Anpassung des Services notwendig, so wird dies via Request for Change (RFC) an das Changemanagement übermittelt. (Löffler, 2011, S. 160)

Dass ITSM, in Form von ITIL nicht unumstritten ist, wird durch die beiden Kritikpunkte langsame Prozesse und fehlende Agilität verdeutlicht. Beide Punkte haben letztlich mit dem Abhandeln von Kundenwünschen zu tun und dies kann zur Folge haben, dass die Kundenzufriedenheit darunter leidet. Im Hinblick auf IT-Services bedeutet dies, dass aufgrund der langsamen und starren Prozesse neue Services bereits veraltet sind, wenn sie dem Kunden zur Verfügung gestellt werden (Mitrakis, 2019, S. 2).

Abgesehen von der Organisationsform gibt es nach Klostermann (2008, S. 122) hinsichtlich des Leistungspotenzials unter anderem auch folgende Stellgrößen im Support:

- Optimierung von Kapazitätsplanung und -einsatz
- Qualifizierung durch Ausbildung und Schulung
- kommunikations-, koordinations- und kooperationsunterstützende Systeme

Auch Beyer et al. (2016, S. 31) sehen die Bedarfs- und Kapazitätenplanung als ein relevantes Qualitätsmerkmal. Diese Planungsaktivitäten haben zum Ziel, dass der zukünftige Bedarf an SupportmitarbeiterInnen durch genügend Kapazitäten und Redundanzen gesichert ist. An dieser Stelle kritisieren Bayer et al., dass eine überraschende Anzahl an Services und Teams diese Schritte nicht durchführen. Nach Ihnen sollte zumindest das organische Wachstum (aus der Zunahme an NutzerInnen) und das anorganische Wachstum (aus Produkteinführungen, Kampagnen oder anderen geschäftsbedingten Einflüssen) berücksichtigt werden. Folgende Schritte werden üblicherweise bei der Kapazitätsplanung durchgeführt:

- Eine Prognose des Bedarfs im Hinblick auf die Zunahme der AnwenderInnen. Der Betrachtungszeitpunkt sollte dabei so gewählt werden, dass ein Kapazitätserwerb rechtzeitig vorstattengehen kann.
- Ermittlung von anorganischen Wachstumsquellen und deren geschätzter Einfluss auf den Bedarf an Kapazitäten
- Regelmäßige Stresstests im Support
- Die Kapazitätenplanung soll jene Abteilung vornehmen, die auch die Ressourcen stellen muss.

2.3.2 Personaleinsatzplanung und Kundenzufriedenheit

Eine Domäne, die sich mit dem Einsatz und der Planung von Personalressourcen beschäftigt, ist die Personaleinsatzplanung. Nach Wenger, Geiger, und Kleine (2011, S. 52) ist ein wesentlicher Bestandteil der Personallogistik, die sowohl das lang- und mittelfristige als auch das strategische und taktische Personalmanagement beinhaltet, die operative Personaleinsatzplanung. Ziel der Personaleinsatzplanung ist die optimale Einteilung der Arbeitszeiten für alle, zur Verfügung stehenden, Mitarbeiterressourcen. Folgende Aspekte sind bei der Personaleinsatzplanung zu berücksichtigen:

- die optimale Zusammenstellung von Teams, hinsichtlich fachlicher und persönlicher Qualifikationen.
- die Einhaltung von Kapazitätsanforderungen
- die Einhaltung von gesetzlichen Faktoren wie Pausen- und Erholungszeiten
- das Abfedern von unerwarteten Ereignissen wie Krankenstand, sowie das Abfedern von erwartbaren Ereignissen wie Urlaub

Eine Formulierung für das Problem leiten Wenger et al. (2011, S. 54) vom sogenannten „Nurse Rostering Problem“ ab. Vereinfacht beschreibt es die Anforderung an den Dienstplan, die Versorgung der Patienten zu jedem Zeitpunkt zu gewährleisten. Dabei sind zweierlei Arten von Nebenbedingungen einzuhalten, einerseits zwingende und andererseits präferierte Bedingungen. Bezogen auf den Dienstplan im Krankenhaus würden zwingende Bedingungen besagen, dass eine Schwester immer nur zu einer Schicht an einem Tag zugeteilt werden darf. Präferierte Bedingungen würden beispielsweise Urlaubsgesuche beinhalten.

Die Lösung dieses Problems hat maßgeblich Einfluss auf die Qualität des Supports und dies hat wiederum maßgeblich Einfluss auf die Kundenzufriedenheit. Nach Knapp (2010, S. 253) ist die Kundenzufriedenheit sogar das wichtigste Ziel eines Unternehmens. Sie sorgt dafür, dass bestehende Kunden bleiben und dass neue angezogen werden. Um dieses Ziel erreichen zu können, muss ein Unternehmen natürlich dafür sorgen, dass die permanent steigenden Erwartungen der KundInnen laufend erfüllt werden. Neben den KundInnen fordern auch die eigenen ManagerInnen laufend Kostensenkungen, Personaloptimierungen und die Steigerung der Gesamtproduktivität. Eine Möglichkeit, um diesen Erwartungen gerecht zu werden, sieht Knapp in der Analyse von Daten und der Gewinnung von Informationen daraus. Folgende vier Kategorien von Daten sind laut Knapp (2010, S. 258) zu analysieren:

- Kundendaten: Geographische und demographische Informationen zu den Kunden, die beispielsweise bei der Clusterbildung helfen können.
- Incidentdaten: Details zum Auftreten von Incidents oder Serviceanfragen. Aufgezeichnet können Datum, Uhrzeit, Kategorie und Kommunikationsweg der Anfrage werden.
- Statusdaten: Beschreiben alle Stationen, die vom Eingang bis zur Lösung des Incidents notwendig waren, außerdem muss die Dauer bis zur Auflösung protokolliert werden.
- Lösungswegdaten: Sind Aufzeichnungen zur Auflösung eines Incidents, dies kann schon die Identifikation eines Workarounds sein und bis hin zur Erkennung und Behebung einer Störungsursache gehen.

Unter anderem empfiehlt Knapp (2010, S. 265) folgende Key Performance Indicators (KPIs) zu messen:

- Abbruchrate: Der Prozentsatz abgebrochener Anrufe im Vergleich zur Gesamtzahl der eingegangenen Anrufe. Unter einem abgebrochenen Anruf versteht man einen Anruf, bei dem die Kundin auflegt, bevor eine Supportmitarbeiterin antworten kann.
- Durchschnittliche Wartezeit: Die durchschnittliche Zeit, die eine Kundin warten muss, bevor der Anruf angenommen wird.
- Antwortzeit: Die durchschnittliche Zeit, die eine Kundin warten muss, bis sie eine Antwort auf eine E-Mail oder Web-Anfrage erhält.
- Durchschnittliche Telefondauer: Die durchschnittliche Dauer der Telefonate nach bestimmten Gruppen.
- First Level Auflösungsquote: Gibt an, wie viel Prozent aller Anfragen im First Level Support gelöst werden können.

2.3.3 Fazit

Der Support ist eine Abteilung in Softwareentwicklungsunternehmen, die maßgeblich zur Kundenzufriedenheit beiträgt, indem er dafür sorgt, dass KundInnen die gekaufte Software reibungslos nutzen können. Neben Vor-Ort- und Fernwartungsschulungen sowie Selbsthilfeange-

boten ist das Herzstück einer Supportabteilung üblicherweise der Helpdesk inklusive Ticketverarbeitung. Die Struktur und das Vorgehen eines Helpdesks können je nach Anforderung an die Organisation abweichen. Ein weit verbreiteter Organisationsstandard ist das multi-level Support Modell, das grundsätzlich in First, Second und Third Level Support gegliedert ist. Bezüglich des Vorgehens gibt es namhafte Vertreter aus dem IT-Service-Management wie ITIL (IT Infrastructure Library), um nur ein Beispiel zu nennen.

Abgesehen von der Organisationsform des Supports sind es die Optimierung des Ressourceneinsatzes, die Ausbildungen der MitarbeiterInnen sowie die Performanz von Kommunikationssystemen und -wegen im Support, die als Stellschrauben der Qualität gesehen werden. Die Ressourcenplanung steht darüber hinaus im Zusammenhang mit der Kundenzufriedenheit und der Gesamtproduktivität.

Die Brücke zum Data Mining schlägt Knapp (2010), indem sie die Messung und Analyse von Daten zur Informationsgewinnung fordert und einige relevante KPI als Beispiel nennt. In Bezug auf die Data Mining-Aufgaben aus Abschnitt 2.2.2. ergeben sich die in Tabelle 4 ersichtlichen möglichen Anwendungsfälle im Support, ob die entsprechenden Daten auch tatsächlich vorhanden sind fließt in diese Aufstellung nicht ein:

Data Mining Ansätze	Potentielle Anwendungsfälle
Klassifikation	Vorhersage, ob ein Incident an den Second Level Support „eskaliert“ werden muss.
Regression	Vorhersage der Gesamtzahl der Anrufe an einem Tag. Vorhersage der Gesamtzahl der Tickets an einem Tag.
Ähnlichkeitsabgleich	Lösungsempfehlungen für Incidents
Clustering	Erkennung von Verhaltensmustern der Kunden
Koexistenzgruppierung	-
Profilerstellung	Aus Aufzeichnungen über das Programmverhalten bei Fehlverhalten kann darauf geschlossen werden, was die Ursache eines Incidents ist.
Verbindungs- vorhersage	Kann zur Lösung von Incidents beitragen, indem aufgezeichnete Lösungswege analysiert werden.
Datenreduktion	Analyse der 10 größten KundInnen in einem Segment, um Aussagen über das gesamte Segment zu treffen.
Kausalmodellierung	Analyse, warum Tickets eskaliert werden mussten.

Tabelle 4: Anwendungsfälle für den Einsatz von Data Mining im Support (eigene Darstellung)

Da die Klassifikation entweder vorhersagt, ob etwas eintreten wird, oder versucht, die Zugehörigkeit zu einer Klasse zu finden, würde sie sich dafür anbieten, einen Incident schnell zu kategorisieren. Neben der Vorhersage, ob ein Incident eskalieren wird, könnte auch gleich die passende Mitarbeiterin im Second Level Support vorgeschlagen werden. Mit einer Kausalmodellierung kann beispielsweise auch analysiert werden, warum ein gewisses Ticket eskaliert worden ist und ein ähnliches etwa nicht. Die Regression sagt im Unterschied zur Klassifikation aus, wie oft etwas eintreten wird. Im Sinne der Ressourcenplanung würde die Vorhersage des Telefon- und Ticketaufkommens einen wesentlichen Beitrag dazu leisten, den Ressourcenbedarf zu ermitteln.

Sowohl der Ähnlichkeitsabgleich als auch die Verbindungsvorhersage können dafür genutzt werden, ähnliche – bereits gelöste – Incidents zu analysieren und den SupportmitarbeiterInnen einen Lösungsvorschlag zu unterbreiten. Das Clustering als Methode des unüberwachten Lernens kann Gruppierungen in den Daten hervorbringen, die bis dato unbekannt waren. Beispielsweise könnten neue Verhaltensmuster der KundInnen oder MitarbeiterInnen unter bestimmten Bedingungen entdeckt werden. Die Profilerstellung könnte dazu genutzt werden, das Programmverhalten zu analysieren und daraus schnell die möglichen Ursachen eines Incidents zu finden. Auch die Datenreduktion beispielsweise nach Kundengruppen oder Incidentgruppen kann zur Informationsgewinnung beitragen.

2.4 Zusammenfassung

Die Literaturrecherche zu den Themen Informations- und Wissensmanagement, Data Science und Softwaresupport liefert eine erste mögliche Antwort auf die Forschungsfrage: „Wie können Data Mining-Algorithmen zur Informationsgewinnung im Softwaresupport gewinnbringend eingesetzt werden?“ Durch Datenaufzeichnung und Messung von KPIs im Support, deren Analyse mit Hilfe von DM-Algorithmen und der daraus folgenden Informationsgewinnung und -sicherung kann neues Wissen generiert und gewinnbringend eingesetzt werden. Gewinnbringend treten die Ergebnisse der Analysen dadurch auf, dass basierend auf den gewonnenen Informationen beispielsweise das Personal besser geplant werden kann, wodurch Kosten reduziert werden können. Bei gleichbleibenden Erlösen würde sich dies bereits positiv auf den Gewinn auswirken. An dieser Stelle tut sich das CRISP-DM-Vorgehensmodell im Data Mining hervor, da dieses die Definition eines Data Mining-Projekts inklusive Projektziele vorsieht. Nicht zuletzt aufgrund der Verträglichkeit mit den Geschäftszielen läuft es dem klassischen KDD-Prozess daher auch den Rang ab.

Die in Tabelle 4 abgeleiteten Anwendungsfälle für DM-Algorithmen im Support basieren rein auf der theoretischen Kombination von Problemstellungen und Lösungsansätzen, dabei wird die Variable Realität noch größtenteils außer Acht gelassen. Viele Fragen bleiben diesbezüglich noch ungeklärt, wie:

- Haben SupportmitarbeiterInnen im Arbeitsalltag genügend Zeit, um das Ergebnis einer Klassifizierungsvoraussage hinsichtlich Eskalationserwartung oder Problemursache abzuwarten?
- Gibt es bereits genügend Aufzeichnungen zur Lösungsfindung von Incidents, um einen Ähnlichkeitsabgleich oder eine Verbindungsvorhersage durchzuführen oder kann die Lösungsfindung überhaupt nachvollziehbar aufgezeichnet werden?
- Bietet die Vorhersage des Telefonaufkommens oder des Ticketaufkommens tatsächlich einen Mehrwert in der Organisation einer Supportabteilung?

Um genauere Aussagen über die Anwendbarkeit der genannten DM-Modelle treffen zu können, muss die Thematik in der Praxis weiter analysiert werden. In den nächsten Schritten wird versucht, die oben erwähnten Fragen durch Experteninterviews zu beantworten und weitere Erkenntnisse zur Anwendbarkeit von DM-Algorithmen mittels einer Fallstudie zu erlangen.

3 EXPERIMENTAL SETUP

Im folgenden Kapitel wird zuerst versucht, die Erkenntnisse aus der Literaturrecherche durch drei qualitative Interviews mit Vertretern führender österreichischer Softwareunternehmen zu verifizieren und zu verfeinern, anschließend wird eine Fallstudie zur Anwendung von DM-Algorithmen im Support durchgeführt. Ziele der Interviews sind die Verifizierung des ermittelten Status quo aus der Literaturrecherche, dessen Ergänzung durch relevanten Praxisinput sowie weitere unterstützende Informationen zur Durchführung der Fallstudie zu erheben. In der Fallstudie wird schließlich versucht, Data Mining in der Praxis anzuwenden. Dabei wird eines der beschriebenen Vorgehensmodelle genutzt, um einen passenden DM-Algorithmus zu ermitteln und auf echten Geschäftsdaten anzuwenden. Die Ergebnisse der Fallstudie fließen nicht zuletzt auch in das Feldexperiment in Kapitel 4 ein.

3.1 Status quo und Kennzahlen im Support – Experteninterviews

Im Folgenden werden die Experteninterviews zur Generierung von Praxis-Know-how durchgeführt. Die Expertise ergibt sich vor allem aus der Erfahrung der Interviewpartner in ihrer Tätigkeit als Führungskraft im Softwaresupport. Gleichzeitig sind alle Interviewpartner im deutschsprachigen Raum (DACH) tätig und stehen auch aufgrund ihrer Unternehmensgröße von jeweils mehr als 300 Mitarbeitern etwa den gleichen Herausforderungen bezüglich der Organisation des Supports hinsichtlich des obersten Ziels im Support, der Kundenzufriedenheit, gegenüber.

Nach einer kurzen Vorstellung der Interviewpartner folgen das Interview-Setup und der Leitfaden, aus dem sich die Interviewfragen (Anhang A) ergeben. Letztlich werden die konsolidierten Antworten der Interviewpartner als Interviewergebnisse dargestellt.

3.1.1 Interviewpartner

Für die Experteninterviews stehen drei erfahrene Partner aus der Softwarebranche zur Verfügung. Erfahren nicht nur durch die Personen an sich, sondern auch durch die Organisation, die sie vertreten. Diese sind renommierte und beständige Unternehmen am österreichischen Softwaremarkt.

Die Firma BearingPoint GmbH, vertreten durch Herrn Hannes Moser, ist Anbieter für webbasierte Softwarelösungen im E-Commerce für Telekommunikationsanbieter. Die Supportabteilung von BearingPoint ist nach internen Organisationseinheiten strukturiert. Herrn Mosers Erfahrungsbericht bezieht sich auf eine Supporteinheit, die etwa 20 bis 25 MitarbeiterInnen umfasst.

Die Firma BMD Systemhaus GesmbH, vertreten durch Herrn Martin Fenzl MBA, ist Marktführer bei Softwarelösungen für Steuerberater in Österreich. Die Desktopanwendung bietet - unter anderem - Lösungen zu den Bereichen Rechnungswesen und Controlling (RWC), Customer-Relationship-Management (CRM) und Enterprise-Ressource-Planning (ERP). Der Support ist je nach Kundenbedürfnissen teilweise in einer Linien- und teilweise in einer Team-Organisation geführt. Herrn Fenzls Erfahrungsbericht beinhaltet detaillierte Informationen über die Arbeitsweisen von circa 300 MitarbeiterInnen.

Der dritte Interviewpartner möchte in dieser Arbeit nicht namentlich genannt werden und wird im Folgenden als „Firma C“ bezeichnet. Die Firma C, vertreten durch Herrn S., erzielt ihren Erfolg in der projektbasierten Webentwicklung. Als Innovationspartner in der Digitalisierung nimmt die Anzahl der KundInnen und MitarbeiterInnen laufend zu. Herrn S. Erfahrungsbericht handelt von den circa 25 MitarbeiterInnen, die für den Softwaresupport zuständig sind.

3.1.2 Interview Setup und Leitfaden

Es wird ein semi-strukturiertes Interview geführt, das vorwiegend durch offene Fragen gesteuert wird. Auf geschlossene Einstiegsfragen zur jeweiligen Person wird verzichtet, im Interview werden lediglich die offenen Schlüsselfragen zu den folgenden Themen behandelt:

- Status quo im Support: Fragen zum Leistungsangebot der Supportabteilung in Bezug auf die Organisationsstruktur im Support sowie in Bezug auf Vorgehensmodelle oder Arbeitsabläufe. Außerdem werden mögliche Stellschrauben sowie Ressourcen- und Personaleinsatzplanung diskutiert.
- Key Performance Indicator (KPI) und Datensammlung im Support: Fragen zur Datensammlung und -analyse. Es soll geklärt werden, welche Daten gesammelt werden, wie diese gesammelt werden und in welche KPIs diese Daten schließlich fließen. Abschließend folgen Fragen dazu, in welcher Art und Weise diese KPIs eingesetzt werden.
- Data Mining im Support: Fragen zur Anwendung von Data Mining und Informationsgewinnung im Support sowie die Fragestellungen aus Abschnitt 2.4. Außerdem wird eine Bewertung der Anwendungsfälle für Data Mining im Softwaresupport (Abschnitt 2.3.3) eingefordert.

Nach einer Zusammenfassung der Ergebnisse wird mit den Interviewpartnern das weitere Vorgehen besprochen.

3.1.3 Ergebnisse aus den Interviews

Anhand der drei Kategorien (Status quo im Support, KPI und Datensammlung und Data Mining im Support) aus dem Interview-Setup werden im Folgenden die Antworten aller Interviewpartner konsolidiert.

Status quo im Support

In Punkto Organisationsformen im Softwaresupport ist das multi-level Support Modell (vgl. Abschnitt 2.3.1) aktuell ein stetiger Begleiter. Das Prinzip, sämtliche Aktivitäten der Lösungsfindung von Kundenanfragen auf –drei bis vier Ebenen aufzuteilen und abhängig von Eskalationsstufen, die Verantwortlichkeiten zu definieren, ist im Support nach wie vor ein bewährter Ansatz, obgleich sich die Organisationseinheiten im Wandel befinden. Unter dem Deckmantel der Agilität und dem Fokus auf die Kundenbedürfnisse entwickeln sich auch in Supportabteilungen Supportteams mit unterschiedlichen Kompetenzen, eben auf die Kundenbedürfnisse abgestimmt. Seien es die „fachübergreifenden Kundenteams“ bei der Firma BMD, die „DevOps“ Teams bei BearingPoint oder die „Customer Service Teams“ bei Firma C. „DevOps“ gilt als Kunstwort, dass aus den beiden Begriffen Development und IT-Operations gebildet wurde, wie Ravichandran, Taylor, & Waterhouse (2016) im Folgenden darstellen:

Rather than maintaining discreet applications engineering (“Dev”) and IT management (“Ops”) competencies and organizations, DevOps dictates use of smaller teams with cross-functional expertise to improve software functionality and the processes used to deliver it. (S. 6)

Organisationsstrukturen- und Vorgehensmodelle im Support

Dabei sollen bekannte Schwachstellen des multi-level Support Modells ausgeglichen werden. Dazu zählt beispielsweise die Tatsache, dass jede Rolle in diesem Modell üblicherweise von einer anderen Person ausgeführt wird oder der Informationsverlust, der bei der Eskalation einer First Level Support-Anfrage zum Second Level Support stattfindet. Bedürfnisorientierte Teams, wie in den Interviews angesprochen, besetzen beispielsweise die Hotline mit erfahrenen Mitarbeitern, die Tätigkeiten des First- und Second Level Supports ausführen. Im Organisationsmodell von BearingPoint wird der First Level Support direkt an den Kunden und die Kundin ausgelagert. Da laut Servicevertrag nur bestimmte, zertifizierte Personen Tickets erstellen dürfen, ist gewährleistet, dass eine gewisse erste Analyse bereits durch die KundInnen durchgeführt worden ist. Im „DevOps“-Team von BearingPoint wird dem fehlenden technischen Wissen der SupportmitarbeiterInnen mit der Integration von SoftwareentwicklerInnen entgegengewirkt. In manchen Fällen kann es also dazu kommen, dass eine Softwareentwicklerin eine Kundenanfrage löst. Gleichzeitig werden SupportmitarbeiterInnen unter anderem auch damit beauftragt Softwaretests durchzuführen. In der Supportorganisation der Firma C findet an dieser Stelle noch eine Trennung zwischen „DevOps“- und Entwicklungsteam statt. In Anlehnung an das multi-level Support Modell wäre die Organisation dann so zu verstehen, dass das Customer Service Team den First Level Support durchführt, das „DevOps“ Team den Second Level Support und erst dann das Entwicklungsteam als Third Level Support konsultiert wird.

Dieses Aufbrechen bestehender Strukturen hat außerdem zur Folge, dass die Anwendung etablierter Vorgehensmodelle aus dem IT Service Management (vgl. Abschnitt 2.3.1) an Bedeutung verlieren. In allen Interviews war von eigens definiertem Vorgehen, teilweise auch Workflows, die Rede, die zwar nicht mit letzter Konsequenz verfolgt werden, den SupportmitarbeiterInnen

rInnen jedoch als Vorlage zur Lösungsfindung bis hin zur Softwareanpassung dienen. So gibt es bei BMD beispielsweise das Prinzip der „Idee“, die von jeder Mitarbeiterin erstellt werden kann und vom Produktmanagement auf Realisierbarkeit geprüft wird. Einzig Firma C arbeitet mit einem an ITIL angelehnten, extra entwickelten Vorgehensmodell mit dem KundInnen-Tickets abgearbeitet werden sollen.

Leistungsangebot

Die Basis der Leistungsangebote ist bei allen Interviewpartnern gleich. Ein E-Mail-basiertes Ticketsystem und eine Telefonhotline stellen alle Supportabteilungen zur Verfügung, jedoch unterscheidet sich der Fokus bei den einzelnen Organisationen. Während BMD den Fokus auf eine effiziente Hotline während der Betriebszeiten (Werktags von 08:00 – 17:00 Uhr) legt und Tickets nebenher erledigt werden, setzen BearingPoint und Firma C den Fokus auf das Ticketsystem. Abseits der Betriebszeiten bieten beide einen Bereitschaftsdienst (Firma C von 06:00 – 22:00 Uhr, BearingPoint sogar 24/7). Die Reaktionszeit auf Tickets ist in den Serviceverträgen definiert und beträgt je nach Prioritätsstufe 15 Minuten oder 1-2 Werktage. Auch im sogenannten Level 0 Support (Unterstützungsangebot für KundInnen ohne Hilfe des Helpdesks) sind alle Interviewpartner aktiv. Neben einer Basis von FAQ befinden sich unter anderem Produktdokumentationen und Lernvideos auf Kundenplattformen.

Personaleinsatzplanung

Bis dato wird die Verfolgung eines bestimmten Vorgehens bei der Besetzung der jeweiligen Hotline vernachlässigt. Unter der Besetzung der Hotline versteht sich, wie viele SupportmitarbeiterInnen für die Bearbeitung von KundInnenanfragen abgestellt sind. BearingPoint und Firma C verfolgen dahingehend keine Schritte, bei BMD wird basierend auf der Erfahrung der letzten Jahre geplant. Dabei wird aber nicht nach erwartetem Aufkommen geplant, sondern nach Ereignissen, die den Aufwand erhöhen oder verringern. So wird für den 15. eines Monats, aufgrund der Meldepflicht der Umsatzsteuervoranmeldung, im Rechnungswesen einfach eine Mitarbeiterin mehr eingeteilt. Aufgrund der vielseitigen Aufgaben im Support spielt das zwar keine große Rolle, da die Mitarbeiterin während weniger anfrageintensiven Hotlinephasen einfach einer anderen Tätigkeit nachgeht. Dieses Vorgehen schafft jedoch Ineffizienzen, die aufsummiert auf 300 SupportmitarbeiterInnen und etwa 220 Werktage im Jahr durchaus beachtlich sind. BearingPoint greift nur in den Standardablauf des Bereitschaftsrades ein, wenn mit außergewöhnlichen Ereignissen wie Inbetriebnahmen, großen Updates oder vom Kunden geplanten Events zu rechnen ist. Doch selbst dies hat eher zur Folge, dass zusätzliche Ressourcen zur Ticketbearbeitung zur Verfügung stehen und nicht zusätzliches Personal an der Hotline.

KPI und Datensammlung

Die Messgröße Supportaufkommen wird von allen Interviewpartnern als die Gesamtheit aller einkommenden Anfragen beschrieben. Bei der Interpretation dieser Zahl ist jedoch Vorsicht geboten. Bei BearingPoint münden nicht nur alle KundInnenanfragen in ein Ticket, es gibt auch proaktive Prozesse, die im KundInnensystem laufen und bei Auffälligkeiten auch Tickets erstel-

len. Lt. Herrn Moser ist dies ein beträchtlicher Tickettreiber, der jedoch gern gesehen ist, denn jedes Ticket, das erledigt werden kann, bevor die KundInnen ein Problem wahrnehmen, ist ein Erfolg. Auch bei BMD ist das Supportaufkommen an sich nicht das Maß aller Dinge. Da hier nicht alle Anrufe zwingend in ein Ticket münden, ist die Dauer der Telefonate mindestens gleich relevant. Bei Firma C ist es die Anzahl der Tickets, kombiniert mit deren Priorität.

Zuzüglich zu den üblichen KPIs zum Hotlinegeschehen, wie Anzahl der Anrufe, Dauer aller Anrufe, durchschnittliche Wartezeit, gibt es auch relevante KPIs zur Ticketabarbeitung. Zu den Tickets gibt es drei relevante KPIs:

- Zeit bis zur Erstbearbeitung: Zeitraum vom Eingang eines Tickets bis zur ersten Antwort an den Kunden oder die Kundin.
- Zeit bis zu einem Workaround: Zeitraum bis eine Umstandslösung gefunden wurde, mit der KundInnen zumindest weiterarbeiten können, die Ursache des Problems aber noch nicht gelöst wurde.
- Zeit bis zur Lösung: Zeitraum vom Eingang eines Tickets bis zur Behebung der Ursache.

Neben der Zeit bis zur Erstbearbeitung, die Servicevertragsinhalt und damit relevant ist, liegt der Fokus auf der Zeit bis zum Workaround. Stillstände im System sind unbedingt zu vermeiden, deshalb liegt der Fokus im Support auch darauf, schnell Lösungen zum Weiterarbeiten zu finden. Wenn der Workaround gefunden wurde, wird das Ticket jedoch nicht geschlossen, sondern es wird weiter an der Ursache geforscht, bis diese behoben werden konnte. Wenn dies nur durch Codeänderungen realisierbar ist, kann das durch die verschiedenen Durchlaufstationen wie Produktmanagement und Softwaretest erheblich länger dauern.

Datensammlung

Die Erstellung dieser KPIs und die Protokollierungen laufen bei allen Interviewpartnern in eigenen Informationssystemen ab. Während BMD beispielsweise auf eine eigens entwickelte Software setzt, nutzt BearingPoint das Open Source Tool OTRS, das an die eigenen Bedürfnisse angepasst wurde und auch zum Reporting genutzt werden kann. Firma C arbeitet dagegen komplett mit Atlassian Jira, das den kompletten Ticketworkflow abbildet. Das Reporting ist bei BMD ins Business Intelligence-Tool QlikView ausgelagert. Die Analyse dieser Kennzahlen läuft bei allen Interviewpartnern in regelmäßigen Zeiträumen ab. Ein Eingriff in den laufenden Betrieb durch Erreichen eines Schwellenwerts ist jedoch nicht vorgesehen.

Data Mining im Support

Bezüglich Data Mining befinden sich alle Interviewpartner entweder noch in den Kinderschuhen oder in der Planung. BearingPoint plant beispielsweise den Monitoring-Prozess, der im KundInnensystem läuft, um DM-Algorithmen zu erweitern, wodurch dieser nicht nur ein Ticket senden kann, wenn auffälliges Verhalten stattfindet, sondern auch wenn Fehler oder Probleme vorhergesagt werden. Firma C plant eine Klassifizierung von Supporttickets hinsichtlich Eskalations-

wahrscheinlichkeit und möglichen Ursachen. Die Firma BMD führt die ersten Versuche mittels der Fallstudie dieser Arbeit durch.

Folgende drei Fragen zur Anwendbarkeit von Data Mining im Support wurden den Interviewpartnern gestellt, um die Ergebnisse aus der Literaturrecherche dem Faktor Realität gegenüberzustellen.

Haben SupportmitarbeiterInnen im Arbeitsalltag genügend Zeit, um das Ergebnis einer Klassifizierungsvorhersage hinsichtlich Eskalationserwartung oder Problemursache abzuwarten?

- BMD: Im Zuge eines Telefonats müssen die MitarbeiterInnen ohnehin diverse Informationen in einem Protokoll erfassen. In dieser Zeit (ca. 2 Minuten) wäre eine Vorhersage definitiv hilfreich, danach wäre es schon zu spät.
- BearingPoint: Richtige Zeit-Engpässe entstehen nur durch die Prioritätslevels. Wenn jedoch der erste Kontakt zur Kundin oder zum Kunden hergestellt wurde, ist jedes Tool erlaubt, das zur Lösungsfindung beiträgt.
- Firma C: In der Bearbeitung von KundInnenanfragen haben die MitarbeiterInnen in jedem Fall etwa 15 Minuten Zeit zur Bearbeitung. In dieser Zeit wäre eine Vorhersage definitiv interessant und wünschenswert.

Gibt es bereits genügend Aufzeichnungen zur Lösungsfindung von Incidents, um einen Ähnlichkeitsabgleich oder eine Verbindungsvorhersage durchzuführen oder kann die Lösungsfindung überhaupt nachvollziehbar aufgezeichnet werden?

- BMD: Aufzeichnungen zur Lösungsfindung sind nur in textueller Form vorhanden. Sobald eine Hotlineanfrage zu einem internen Second Level Ticket eskaliert wurde, gibt es zumindest eine Aufzeichnung darüber, welche Personen in die Lösungsfindung involviert waren. Dies wird aber nicht mit letzter Konsequenz verfolgt.
- BearingPoint: Jedes Ticket durchläuft einen Workflow, wobei Statuswerte gesetzt werden und auch einige Informationen über das Problem getrackt werden. Was jedoch in den einzelnen Schritten des Workflows im Detail passiert, wird auch nur textuell protokolliert.
- Firma C: Tickets durchlaufen einen Workflow, wobei nicht automatisch protokolliert wird, welche MitarbeiterInnen welche Tätigkeiten zur Lösungsfindung durchgeführt haben. Dazu werden Kommentare genutzt.

Bietet die Vorhersage des Telefonaufkommens oder des Ticketsaufkommens tatsächlich einen Mehrwert in der Organisation einer Supportabteilung?

- BMD: Je genauer das Supportaufkommen vorhergesagt werden kann, desto gezielter kann die Hotline eingeplant werden. Über diesen Hebel könnten Ineffizienzen eingespart werden, da die MitarbeiterInnen nebenbei keine andere Arbeit erledigen müssen und sich voll auf die Hotline konzentrieren können.

- **BearingPoint:** Ja die Vorhersage bietet einen Mehrwert und wird auf jeden Fall interessant, wenn die Organisation noch weiterwächst, sodass die Supportteams größer werden.
- **Firma C:** Die Vorhersage von Supportaufkommen bietet in der aktuellen Supportorganisation keinen Mehrwert. Während der Betriebszeiten sind in jedem Fall genügend MitarbeiterInnen verfügbar.

Abschließend folgen zusammengefasst sind die jeweiligen Einschätzungen zu den ermittelten Anwendungsfällen für DM im Support:

- **Schnelle Vorhersage, ob eine KundInnenanfrage an den Second oder Third Level Support eskaliert werden muss:** Können sich die Interviewpartner gut vorstellen. Es ist zu beachten, dass der First Level Support seine Aufgaben wie Loggingprotokolle einholen und Screenshots erstellen, nicht vernachlässigen darf.
- **Vorhersage von Supportaufkommen zur Ressourcenplanung:** Ist vor allem in größeren Organisationen, wo der First Level Support fokussiert auf die effiziente Abarbeitung von KundInnenanfragen ist, interessant. In Supportteam-Strukturen eigentlich nicht relevant.
- **Vorschlag von Lösungsmöglichkeiten auf Basis von Informationen, die SupportmitarbeiterInnen im Telefonprotokoll erfassen:** Würden alle Interviewpartner im Support einsetzen wollen. Jedoch kann dies erst nach einer längeren Datenerfassungsphase stattfinden, da die Lösungsfindungen bei allen Organisationen in textueller, also unstrukturierter, Form gespeichert sind.
- **Erkennung von Verhaltensmustern bei KundInnen:** Dies nennen die Interviewpartner als gute Möglichkeit, um aktuell noch unbekannt Informationen zu gewinnen. Teilweise werden diese Analysen manuell durchgeführt. Ein gewisser Automatismus und eine neue Herangehensweise wären wünschenswert.
- **Programmverhaltensprofile, die aus einem bestimmten Programmverhalten eine bestimmte Ursache ableiten:** Hängt stark davon ab, wie die Daten gesammelt werden können. Bei BearingPoint findet diese Sammlung teilweise schon automatisiert statt. Auch die Firma BMD würde eine solche Vorhersage nutzen. Lediglich Firma C kann diese Profile kaum nutzen, da die Kundensysteme zu unterschiedlich sind.
- **Vergleich des aktuellen Bearbeitungsverlaufs mit vergangenen Fällen, um nächste Schritte vorzuschlagen:** Da meist nach einem bestimmten Bearbeitungsworkflow gearbeitet wird, ist dieser Vorschlag nicht für alle Interviewpartner relevant. Außerdem ist auch hier eine aufwendige Sammlung von Daten notwendig, bevor erste DM-Algorithmen eingesetzt werden können, um schließlich Ergebnisse zu liefern.
- **Analyse der 10 größten Kunden in einem Segment, um Aussagen über das gesamte Segment treffen zu können:** Findet meist manuell statt. Wäre nur für BMD relevant, da die Kundenstruktur eine andere ist.

- **Analyse, warum gewisse Tickets eskaliert werden mussten und vergleichbare nicht:** Wird von allen Interviewpartnern als äußerst interessant eingestuft. Teilweise wurde dies bereits durchgeführt, aber nicht basierend auf DM-Algorithmen.

3.1.4 Fazit

Aus den Experteninterviews wird ersichtlich, dass das Herzstück der Supportabteilungen nicht zwangsweise der Helpdesk ist, sondern die Ticketverarbeitung mittlerweile eine vergleichbare, wenn nicht wichtigere, Rolle spielt. Das multi-level Support Modell war den Interviewten nicht nur ein Begriff, sondern dient allen drei Supportorganisationen als Vorlage zur Rollenverteilung, auch wenn das Modell teilweise sehr abstrahiert angewendet wird.

Dass die allgemeine Verfügbarkeit für KundInnen ein wichtiges Thema ist, haben alle Organisationen verstanden. Schließlich werden sogar 24/7 Bereitschaftsdienste angeboten. Die Ressourcenplanung selbst stellte bei den Interviewten nur bedingt eine Qualitätsstellschraube dar, da sie aufgrund Ihrer Organisationsform ohnehin immer Ansprechpartner für die Kunden bereitstellen. Da dieses Thema nur für den Teil der Supportabteilung von BMD, der in einer Liniorganisation arbeitet, interessant ist, hängt seine Relevanz höchstwahrscheinlich von der Organisationseinheit als Linie oder der Anzahl der eingesetzten MitarbeiterInnen im Support ab.

In Bezug auf das Data Mining stehen Supportabteilungen vor einigen Chancen und damit einhergehenden Herausforderungen. Als Chancen seien die effizientere Bearbeitung von Supportanfragen, die Identifizierung von Ausbildungsbedarfen und die allgemeine Gewinnung von Informationen über Kundenverhalten und Supportabläufe zu nennen. Untere anderem können folgende Punkte als Herausforderungen angesehen werden, um diese Chancen wahrnehmen zu können:

- Anpassung des allgemeinen Vorgehens im Support
- Anpassung der Dokumentation von Arbeitsschritten
- Strukturierte Speicherung der Lösungswege
- Akzeptanz durch die MitarbeiterInnen
- Finanzielle Investitionen und Refinanzierung

3.2 Anwendung von DM-Algorithmen – Fallstudie

Die folgende Fallstudie beschäftigt sich mit der Anwendung von DM-Algorithmen unter Einhaltung eines DM-Vorgehensmodells im Support. Ziel ist es die Anwendbarkeit von DM-Algorithmen und -Vorgehensmodellen im Support zu belegen. Als Partner der Fallstudie dient die Firma BMD Systemhaus GesmbH. Im Zuge der Studie wird ein DM-Vorgehensmodell anhand echter Datensätze zum Supportaufkommen aus dem laufenden Betrieb abgearbeitet. Einfluss in das Studien-Setup liefern einerseits die Ergebnisse aus der Literaturrecherche, andererseits die Ergebnisse aus den Interviews aus Abschnitt 3.1.

3.2.1 Fallstudie Setup

Die Rahmenbedingungen der Fallstudie ergeben sich aus den folgenden Parametern:

- Einsatzmöglichkeiten: Anhand der diskutierten Einsatzmöglichkeiten des DM im Support und dessen Bewertungen aus den Interviews ergeben sich zwei potenzielle Einsatzmöglichkeiten für eine Fallstudie. Einerseits die Vorhersage von Supportaufkommen zur Planung des First Level Supports und andererseits die Unterstützung der Lösungsfindung von Anfragen im First Level Support.
- Datenquellen: Die Unterstützung zur Lösungsfindung bedarf einer Analyse bereits abgeschlossener Anfragen und deren Lösungsweg. Diese Daten sind als Textform nicht strukturiert gespeichert, eine Analyse wird daher nicht möglich sein. Für die Vorhersagen des Supportaufkommens sind Aufzeichnungen über das bisherige Supportaufkommen sowie deren Einflussfaktoren (Feiertage, Ferien, etc.) nötig. Die Telefondaten werden bereits seit Jahren gemessen und stehen daher auch in strukturierter Form zur Verfügung. Daten zu den Einflussfaktoren müssten separat ermittelt werden.
- DM-Aufgaben: Lösungswegunterstützungen würden in die DM-Aufgaben des Ähnlichkeitsabgleichs, Profilerstellung sowie Verbindungsvorhersage fallen. Die Vorhersage von Supportaufkommen ist Aufgabe der Regression.
- DM-Algorithmus: Jene DM-Aufgaben, die zur Lösungsfindungsunterstützung beitragen, sind mehreren Algorithmen des supervised und unsupervised learnings zugehörig. Die Regression ist ganz eindeutig dem supervised learning zugehörig.
- DM-Vorgehensmodell: Anhand der definierten Stärken und Schwächen wären beide Vorgehensmodelle, sowohl der KDD- als auch der CRISP-DM-Ablauf für die Fallstudie passend.

Nicht zuletzt aufgrund der häufigen Nennungen des CRISP-DM-Ablaufs in vergleichbaren Studien wird dieses Vorgehensmodell für die folgende Fallstudie verwendet. Auch seine Flexibilität in der Anwendung und die Tatsache, dass die Zieldefinition vor der Datendefinition passiert, wodurch die vorliegenden Daten mit Vorwissen angereichert werden können, trägt positiv zum Ablauf des Prozesses bei.

Die Entscheidung über die Einsatzmöglichkeit wird realistischerweise aufgrund der Datenquellen getroffen. Die Sammlung von passendem Datenmaterial für eine Lösungsfindungsunterstützung wäre schlichtweg zu zeitaufwendig für diese Fallstudie. Neben dem großen Vorteil, dass die Analysedaten bei der Partnerfirma BMD Systemhaus GesmbH weitestgehend vorhanden sind, ist die Regressionsanalyse zur Supportaufkommensvorhersage auch von den anderen Interviewpartnern als realistische Einsatzmöglichkeit des Data Mining im Softwaresupport genannt worden. Darüber hinaus lässt sich das Einsatzgebiet auch für den technischen Support oder weitere Branchen adaptieren, die mit der Planung von Ressourcen unter Einbeziehung von diversen Variablen herausgefordert sind. Weiters liefert die Regressionsanalyse als „Nebenprodukt“ Informationen darüber, wie die einzelnen Variablen in Zusammenhang stehen. Wenn also das Supportaufkommen an einem bestimmten Tag unter der Einbeziehung von di-

versen Faktoren vorhergesagt werden soll, liefert die Regressionsanalyse zusätzlich das Ausmaß des Einflusses der Faktoren auf die abhängige Variable Supportaufkommen (Bruce & Bruce, 2017, S. 127).

Es sei erwähnt, dass die Vorhersagen nicht über den gesamten Support, sondern über die einzelnen Fachbereiche getätigt werden. Konkret werden die Fachbereiche FIBU (Finanzbuchhaltung), KORE (Kostenrechnung und Controlling), BILANZ (Bilanz und Anlagenbuchhaltung), CRM (Customer Relationship Management) und WWS (Waren- und Lagerwirtschaft) analysiert. Diese Fachbereiche werden im Folgenden auch als Fachgruppen oder Supportgruppen bezeichnet.

3.2.2 Durchführung DM-Vorgehensmodell

Anhand der sechs Phasen des CRIPS-DM-Vorgehensmodells wird im Folgenden die Regressionsanalyse zur Vorhersage des Supportaufkommens dokumentiert.

Geschäftsverständnis

In Phase eins des Vorgehensmodells wird ein erstes Verständnis für die Fachdomäne erarbeitet, woraus Projektziele und -anforderungen abgeleitet werden. Der Weg zur Zielerreichung ist dann das sogenannte Data Mining-Problem, welches gelöst werden muss. Nach Chapman et al. (2000) sind die konkreten Aufgaben dieser Phase die folgenden:

- Unternehmensziele bestimmen
- Situation einschätzen
- Data Mining-Ziele bestimmen
- Projektplan erstellen

Unternehmensziele bestimmen

Das Unternehmensziel in dieser Fallstudie ist eine effiziente Gestaltung der Softwaresupport-Abteilung. Durch Vorhersage der Supportaufkommen kann eine gezielte Planung und Einteilung der Ressourcen stattfinden, die zu diesem Ziel beitragen. Da aktuell kein spezifisches Vorgehen zur Einteilung der Ressourcen im Bereich des First Level Supports stattfindet, ist es das Unternehmensziel, die Ressourcenplanung zukünftig mittels DM-basierter Vorhersagemodelle zu unterstützen. In der ersten Einführungsphase folgt keine Integration des Vorhersagemodells in ein bestehendes System.

Situation einschätzen

Wie aus dem Interview mit Herrn Fenzl ersichtlich, werden aktuell noch keine Data Mining-Algorithmen eingesetzt. Die Datenerfassung im Support ist jedoch recht umfangreich. Neben den Protokollen der MitarbeiterInnen erfasst auch die Queuing-Software jeden Anrufer und jede Anruferin. Die Daten der Queuing-Software bieten sogar noch den Vorteil, dass auch jene Anrufer aufgezeichnet sind, die nicht durchgekommen sind, da die AnruferInnen bereits aufgelegt

haben, bevor jemand die Anfrage entgegennehmen konnte. Weiters sind die Aufzeichnungen hinsichtlich der Ticketbearbeitungen und der Änderungen pro Softwareupdate umfangreich. Daten zu den Einflussfaktoren müssten jedoch erst erhoben werden, da sie nicht in strukturierter Form abgelegt sind. Dies sind gesetzliche/fachliche Einflüsse, Feiertage, Schulferien sowie Wetter und Mondphase. Die Aussagekraft der Mondphase ist wissenschaftlich zwar umstritten, wird in dieser Fallstudie jedoch trotzdem beachtet, da sie von Interviewpartnern genannt wurde.

Data Mining Ziele bestimmen

Abgeleitet vom Ziel, die Ressourcenplanung im Softwaresupport durch DM-Algorithmen zu unterstützen, um den First Level Support effizienter und zielgerichteter zu planen, ergibt sich folgendes Data Mining-Ziel: „Sage voraus, wie viele Telefonate und Tickets zu einem bestimmten Fachbereich an einem bestimmten Tag aufkommen werden.“ In Bezug auf die Qualität der Vorhersage ist zu beachten, dass diese das tatsächliche Aufkommen nicht unterschreiten soll, denn die zeitgerechte Bearbeitung der Kundenanfragen muss immer gewährleistet sein. Ausgehend davon, dass bisher auch „großzügig“ eingeteilt wird, ist das Qualitätsziel der Vorhersage: „Die Vorhersage soll das tatsächliche Aufkommen nicht unterschreiten. Eine Überschreitung wird toleriert, sofern sie unter der herkömmlichen Einschätzung liegt.“ Das Statement über die Qualität ist vor allem in der ersten Phase der Einführung noch recht weich formuliert und würde bei Erfolg in einer weiteren Ausbaustufe strenger definiert werden. Wie in Abschnitt 2.2.2 dargestellt eignet sich die Regressionsanalyse, um Vorhersagen über das Ausmaß eines eintreffenden Szenarios erstellen zu können. Des Weiteren bietet sie die Möglichkeit weitere Informationen über das Datenset zu gewinnen, wie Dolic (2004) beschreibt:

„Die Regressionsanalyse ist als Methode, Zusammenhänge zwischen metrischen Variablen zu beschreiben, wohl eine der zentralsten Anwendungen in der Statistik.“ (S. 213)

Projektplan erstellen

Der Projektplan zur Erreichung eines DM-Zieles sieht zu jeder Phase im CRISP-DM-Modell eine Einschätzung zu Ressourcen, Abhängigkeiten und dem Vorgehen vor. Vereinfacht lässt sich sagen, dass die Ressource Zeit in dieser Fallstudie in jeder Phase eine Rolle spielt, da die Fertigstellung dieser Arbeit terminiert ist. Viele Entscheidungen über das Vorgehen in dieser Fallstudie werden also im Hinblick auf die Ressource Zeit getroffen. An den gegebenen Stellen wird folglich der Hinweis darauf vermerkt sein. Aufgrund des dauerhaften Zugangs zu den Daten aus der BMD Systemhaus GesmbH hält sich der Risikofaktor dahingehend in Grenzen. Zu diesem Zeitpunkt, an dem die Interviews mit den erfahrenen Supportmitarbeitern bereits geführt sind, stellen auch die Inputs aus der Praxis keine bedrohende Abhängigkeit dar.

Die Erreichung der dargestellten Ziele soll mit dem Tool RStudio und der Programmiersprache „R“ ermöglicht werden. Nach EDUCBA (2019) ist die Programmiersprache R eine der am häufigsten verwendeten Programmiersprachen in der Statistik und im Data Science. Ein großer Vorteil der Open Source Lösung besteht darin, dass über 8000 Zusatzpakete angeboten werden. Da das Vorhersagemodell im Zuge der Fallstudie nicht in ein anderes System integriert

werden soll, sind keine Kompatibilitätsprüfungen dahingehend notwendig. Die Daten werden im einfach strukturierten Dateiformat „CSV“ – Beistrich getrennt – verarbeitet.

Datenverständnis

In der zweiten Phase des CRISP-DM-Modells findet eine Erfassung der relevanten Datensätze statt. Es gilt, sich mit den Daten vertraut zu machen und eventuelle Qualitätsprobleme oder Anforderungen zu identifizieren. In informeller Form können erste Hypothesen über versteckte Informationen gebildet werden Chapman et al. (2000) nennen folgende Schritte in dieser Phase:

- Erste Daten sammeln
- Daten beschreiben
- Daten untersuchen
- Datenqualität untersuchen

Die erste Durchsicht der aufgezeichneten Daten wirkt durchaus positiv. Die Daten sind gut strukturiert und auf Anhieb verständlich. Die folgende Auswertung über das Telefonaufkommen aus dem Queuing-System liefert einen Überblick über die Kennzahlen je Supportgruppe pro Tag. Als Analysezeitraum wird die Zeit vom 01. Jänner 2015 bis zum 31. Oktober 2019 herangezogen, da fünf Jahre ein aussagekräftiger Zeitraum sind. Es wird bewusst mit dem 01. Jänner gestartet, um im Kontext eines Kalenderjahres zu bleiben. Darüber hinaus haben sich innerhalb dieses Zeitraums weder die Kunden- noch die Programmstruktur überdurchschnittlich verändert.

In Tabelle 5 ist ein Auszug aus dem Ursprungsdatensatz der Firma BMD dargestellt. Dieser beinhaltet die relevanten Telefonaufzeichnungen des Softwarepakets CRM, der Kalenderwoche 41, 2019. Diese zeigt die wichtigsten Messungen der Queuing Software, wie durchschnittliche Wartezeit in Minuten, maximale Wartezeit in Minuten, Anrufe gesamt und Gesprächszeit gesamt. Obendrein wird separat jeweils der Anteil an Telefonaten gemessen, die nicht bis zu den SupportmitarbeiterInnen durchgekommen sind, weil die KundInnen schon aufgelegt haben, bevor jemand die Anfrage entgegennehmen konnte (in dieser Tabelle aus Gründen der Vereinfachung nicht dargestellt).

Anrufe CRM	Durchschn. Wartezeit in Minuten	Maximale Wartezeit in Minuten	Gesprächszeit gesamt (HH:MM:SS)	Anrufe gesamt
07.10.2019	2,66	15,1	15:17:01	124
08.10.2019	2,73	15,1	15:51:02	117
09.10.2019	2,20	15,1	14:11:21	114
10.10.2019	1,91	15,1	11:34:18	103
11.10.2019	3,03	16,0	09:42:35	75

Tabelle 5: Auszug aus dem Ursprungsdatensatz für das Softwarepaket CRM für die KW 41, 2019 (Telefondatenaufzeichnung Firma BMD)

Auch das Ticketaufkommen wird in strukturierter Form je Supportgruppe und pro Tag angeliefert. Die Auswertung stammt aus dem BMD-eigenen Ticketsystem, wie in Tabelle 6 ersichtlich. Sie zeigt den Auszug aus den Ticketdatenaufzeichnungen für das Paket BILANZ, für die Kalenderwoche 41, 2019.

Die durchschnittliche Durchlaufzeit wird in Tagen absolut und relativ gemessen und erklärt, wie lange die Bearbeitung der eingegangenen Tickets durch die jeweilige Supportgruppe dauerte. Dabei bedeutet absolut, dass von einem 24-Stunden-Tag ausgegangen wird. Da ein Arbeitstag jedoch meist auf die Stunden von 07:00 – 18:00 Uhr begrenzt ist, wird zusätzlich die relative Einheit eines 11-Stunden-Tages angegeben. Die durchschnittliche Liegezeit beschreibt jene Zeit, die vergeht, bis ein Ticket zum ersten Mal von einer Sachbearbeiterin bearbeitet wird. „Absolut“ und „relativ“ haben in diesem Kontext die gleiche Bedeutung. Letztlich wird auch die tägliche Anzahl der neuen Tickets aufgezeichnet.

Tickets BILANZ	Durchschn. Durchlaufzeit absolut in Std.	Durchschn. Durchlaufzeit relativ in Std.	Liegezeit ab- solut in Std.	Liegezeit relativ in Std.	Tickets gesamt
07.10.2019	5,3	4,0	1,0	0,9	18
08.10.2019	7,7	5,4	2,1	1,4	24
09.10.2019	3,6	2,5	0,7	0,6	21
10.10.2019	2,2	1,1	0,2	0,2	10
11.10.2019	3,0	1,3	1,3	0,5	10

Tabelle 6: Auszug aus dem Ursprungsdatensatz für das Softwarepaket BILANZ für die KW 41, 2019 (Ticketdatenaufzeichnung Firma BMD)

In Tabelle 7 ist der sogenannte „NTCS Versionsbericht“ (NTCS – aktueller Produktname der BMD Software) ersichtlich. Darin dargestellt ist die Anzahl an Neuerungen und Änderungen (SCR – System Change Request) in der Software pro wöchentlichem Update. Jeden Mittwoch wird das aktuellste Update zur Verfügung gestellt und es steht den AnwenderInnen frei, dieses zu installieren. Aus diesem Grund ist dieser Einflussfaktor mit Vorsicht zu betrachten, da es nicht nachvollziehbar ist, ob und wann die Updates tatsächlich eingespielt werden. Lediglich das Jahresupdate zum Jahreswechsel ist verpflichtend zu installieren. Auch wenn diese Kennzahlen teilweise unscharf sind, sollten sie in der Vorhersage berücksichtigt werden, da sie in der Realität definitiv Auswirkungen auf das Supportaufkommen haben.

NTCS Versionsbericht Anzahl SCR	Paket FIBU	Paket BILANZ	Paket CRM	Paket WWS	Paket KORE
KW 39	1	3	0	2	0
KW 40	6	4	3	2	2
KW 41	3	4	5	6	1
KW 42	1	5	1	3	1
KW 43	0	5	7	2	0

Tabelle 7: Darstellung der Neuerungen und Änderungen aus dem „NTCS Versionsbericht“ der relevanten Softwarepakete von KW 39 bis KW 43 (Datenaufzeichnung Firma BMD)

Diese Auswertung listet den jeweiligen Versionsnamen und das Veröffentlichungsdatum (meist Mittwochnachmittag) auf. Da die Auswirkungen auf das Supportaufkommen erst verzögert auftreten werden, ist es ratsam, die Auswirkung auf die Folgewoche zu beziehen.

Die Einflussfaktoren wie Ferientage und Schulferien werden aus öffentlichen Quellen bezogen. Wie in Tabelle 8 dargestellt, wurden die unterschiedlichen Ferienzeiten der Bundesländer dahingehend angepasst, dass je der erste und der letzte Ferientag einer Periode herangezogen werden. Diese Anpassung entspricht der Realität, da sich auch die Kunden der Firma BMD Systemhaus GesmbH über alle Bundesländer Österreichs erstrecken.

Weihnachtsferien	24. Dezember 2018 – 06. Jänner 2019
Semesterferien	4. Februar 2019 – 23. Februar 2019
Osterferien	13. April 2019 – 23. April 2019
Pfingstferien	8. Juni 2019 – 11. Juni 2019
Sommerferien	29. Juni 2019 – 08. September

Tabelle 8: Schulferien in Österreich 2019 (vgl. BMBWF, 2019)

Mangels wissenschaftlicher Quellen zu den Mondphasen werden die Vollmondzeiten von der Non-Profit-Organisation Wikipedia bezogen. Detaillierte taggenaue Wetteraufzeichnungen sind nur kostenpflichtig erhältlich, daher wird von der Nutzung dieser Quellen abgesehen. Die Stadt Wien bietet jedoch monatliche Durchschnittstemperaturen, diese können zur Analyse herangezogen werden. Ihre Aussagekraft muss jedoch erst untersucht werden.

Datenvorbereitung

In der Phase der Datenvorbereitung wird der endgültige Datensatz zur Analyse erstellt. Aus den Rohdaten werden jene Daten ausgewählt und gegebenenfalls überarbeitet, um ein Analysedatenset zum Ergebnis zu haben. Chapman et al. (2000) ordnen dieser Phase folgende Punkte zu:

- Daten auswählen
- Daten bereinigen
- Daten erzeugen
- Daten kombinieren
- Daten überarbeiten

Da sich die Vorhersage auf die Anzahl der Telefonate und Tickets bezieht, wird auch pro Fachbereich nur deren Anzahl in den finalen Datenträger übernommen. Da die Vorhersage pro Tag sein wird, basiert auch der Datenträger auf der Einheit Werktag. Die Variable Feiertag und Ferien bezieht sich auf die jeweilige Kalenderwoche des Tages. So haben die Feiertage am 01. und 06. Jänner zur Folge, dass die Kalenderwochen eins und zwei die Ausprägungen Feiertag und Ferien „JA“ haben. Mit der Ausprägung Vollmond: „JA“, werden einerseits jene Tage gekennzeichnet, an denen der Vollmond tatsächlich eintritt und andererseits der Tag davor und danach. Auch die Ausprägung Halbtage: „JA“ ist durchaus relevant, da freitags die Hotline nur bis 12:00 Uhr (sonst 17:00 Uhr) erreichbar ist. Die Anzahl der SCRs pro Fachbereich wird verzögert dargestellt. So werden beispielsweise die SCRs aus der KW 40 der Folgeweche, also der KW 41, zugeordnet. Dies wird in Tabelle 9 für das Paket FIBU veranschaulicht:

Datum	#Anrufe FIBU	#Tickets FIBU	Woche mit Feiertag	Ferienwoche	SCR der Vorwoche
07.10.2019	276	67	Nein	Nein	1
08.10.2019	304	61	Nein	Nein	1
09.10.2019	322	63	Nein	Nein	1
10.10.2019	299	54	Nein	Nein	1
11.10.2019	208	31	Nein	Nein	1

Tabelle 9: Auszug aus dem tatsächlichem Datensatz für die Datenmodellierung (eigene Aufbereitung)

Aus dem Datenträger wurden auch Datensätze entfernt. Beispielsweise wurden Tage ausgenommen, an denen kein Hotlinebetrieb stattfindet. An Wochenenden, Feiertagen und am 24. und 31. Dezember ist die BMD Hotline nicht erreichbar, darum werden diese Daten auch nicht ausgewertet. Dies ergibt über den Betrachtungszeitraum vom 01. Jänner 2015 bis inkl. 31. Oktober 2019 rund 1.200 Werktage, an denen aufsummiert etwa 800.000 Telefonate eingegangen sind. Unter Berücksichtigung der 5 Softwarepakete ergibt das einen Tagesdurchschnitt von circa 110 Telefonaten. Bei den Tickets verdeutlicht sich der Relevanzunterschied durch die aufsummiert etwa 6.000 Tickets, was einen Tagesdurchschnitt von circa 28 Tickets ergibt.

Datenmodellierung

In der Phase der Datenmodellierung werden nun die DM-Algorithmen angewendet, um Informationen zu erheben. In dieser Fallstudie wird also eine Regressionsanalyse mit dem Tool RStu-

die durchgeführt. In dieser Phase werden nach Chapman et al. (2000) folgende Aufgaben ausgeführt:

- Modellierungsmethode auswählen
- Testmethode definieren
- Modellerstellung
- Modellbewertung

Modellierungsmethode auswählen

Wie im Setup der Fallstudie (Abschnitt 3.2.1) definiert, findet eine Regressionsanalyse zur Lösung des Data Mining Problems statt. Nach Bruce & Bruce (2017, S. 127 - 129) werden mit einfachen linearen Modellen die Beziehungen zwischen der Größe einer Variable X und der Größe einer zweiten Variable Y dargestellt. Dabei wird in weiterer Folge versucht, vorherzusagen, um wie viel sich der Wert Y ändert, wenn sich der Wert X um ein bestimmtes Maß ändert. Dies wird in folgender Formel dargestellt:

$$Y = b_0 + b_1X$$

Formel 1: Formel für einfache lineare Regressionen

Die sogenannte abhängige Variable Y ergibt sich somit aus der Summe aus dem Intercept (b_0) und dem Produkt aus der unabhängigen Variable X und deren Steigung (b_1). Nach Bruce & Bruce (2017, S. 128) sind der linearen Regression folgende Begriffe zuzuordnen:

- Response: Dies ist die abhängige Variable Y, also der Wert, der durch die Regression vorhergesagt werden soll.
- Independent variable: Dies sind die unabhängigen Variablen X, durch die Y vorhergesagt werden soll. Die Variable Y ist also von den Variablen X abhängig.
- Record: Als Record wird ein Datensatz eines Datensets bezeichnet. Jeder Trainingsdatensatz muss eine Y-Variable und mindestens eine X-Variable führen.
- Intercept: Heißt zu Deutsch Achsenabschnitt und bildet den vorhergesagten Wert, wenn alle X null sind.
- Regression coefficient: Beschreibt die Steigung der Regressionslinie einer unabhängigen Variablen.
- Fitted values: Dies sind die vorhergesagten Werte für Y. Diese Werte werden in der Statistik mit einem „Hut“ (\hat{Y}) dargestellt, daher werden diese Werte im englischen auch „y hat“ genannt.
- Residuals: Als Residuen werden die Abstände der einzelnen Werte zur Regressionsgeraden angesehen.

- Least squares: Bezeichnet jene Methode, die die Regressionsgerade anhand des kleinsten quadrierten Summenfehlers definiert.

Lineare Modelle werden üblicherweise nicht nur mit einer, sondern mit mehreren unabhängigen Variablen gebildet. Nach Dolić (2004, S. 220) spricht man dann von einer multiplen Regression, welche in folgender Formel dargestellt wird, wobei Y in dieser Fallstudie der Anzahl der Telefonate oder Tickets entspricht und X_n den Einflussfaktoren wie Feiertage, Ferientage oder Anzahl der SCR entspricht:

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n + e$$

Formel 2: Formel für multiple Regressionen

Bruce & Bruce (2017, S. 134 f.) ergänzen die relevanten Begriffe zur linearen Regression um die folgenden:

- Root mean squared error (RMSE): Dies ist die Quadratwurzel des durchschnittlichen quadratischen Fehlers der Regression und die gängigste Methode, um Regressionsmodelle zu vergleichen.
- Residual standard error (RSE): Beschreibt die gleiche Kennzahl wie die RMSE, nur bezieht sie die Freiheitsgrade mit ein.
- R-squared: Ist der Anteil der Varianz (der Daten), der durch das Modell erklärt werden kann.

Ein Nachteil der multiplen linearen Regression wird in dieser Fallstudie jedoch auch schlagend, nämlich die Reduzierung von Variablen auf ihre durchschnittliche Steigung. Bezogen auf die Variable Datum bedeutet dies, dass einmalig ein Trend errechnet wird (steigend oder fallend) und davon ausgehend, alle zukünftigen Tage abhängig sind. Wenn nun die Tendenz als grundsätzlich fallend errechnet wird, so hätte dies unter Umständen zur Folge, dass in X Jahren die Vorhersagen nur mehr negativ sein können.

Aufgrund dieser Schwäche wurden basierend auf der linearen Regression, weitere Algorithmen entwickelt, um das time-series forecasting Problem zu lösen. Ziel dieser Spezialform der Regression ist eine tagesbezogene Vorhersage von Werten (Chatfield, 2001). Ein nützliches Tool im time-series forecasting ist das Prophet Forecasting Model (*prophet*), ein Open Source Projekt der Firma Facebook Inc (Taylor & Letham, 2017).

Nach Yang (2019, S. 4) versucht *prophet* aus der unabhängigen Variable Zeit mehrere lineare und nicht lineare Eigenschaften abzuleiten und als zusätzliche Variablen zu verwenden. Die Modellierung der Saisonalität als additive Komponente entspricht dem Ansatz der exponentiellen Glättung (Gewichtung einzelner Tage des Jahres) in der Holt-Winters-Technik (einbeziehen von Trend und Saisonalität). Prophet formuliert das Vorhersageproblem als eine Übung zur Kurvenanpassung, anstatt explizit die zeitliche Abhängigkeit jeder Beobachtung innerhalb einer Zeitreihe zu betrachten.

Testmethode definieren

Bruce & Bruce (2017, S. 138) definieren die Cross Validation als intuitivste Testmethode für Regressionsmodelle. Schließlich besagt sie, einige der Analysedaten im Datenset beiseite zu legen und mit den restlichen Daten das Modell zu trainieren. In weiterer Folge wird dann versucht, die Vorhersagekraft des Modells mit den „geparkten“ Daten zu testen. Bekräftigt wird diese These dadurch, dass die genutzten Metriken zur Bewertung von linearen Modellen – wie der quadrierte Summenfehler – zu den In-Sample-Metriken zählen. Sie werden alle auf denselben Daten angewendet, die zur Erstellung des Modells verwendet worden sind. Der Unterschied zwischen Cross-Validation und anderen Holdout-Sample-Validierungen ist nun jener, dass das Datenset zu Beginn in eine bestimmte Anzahl Teile (k) gestückelt wird und die Modellbildung und der Stichprobentest so lange wiederholt werden, bis alle Teile je einmal gegen ein Modell getestet wurden. Ein üblicher Standard ist die Aufteilung in Zehntel, wie in Abbildung 7 ersichtlich.



Abbildung 7: Cross Validation (vgl. Ng & Soo, 2018, S. 18)

Da eine Cross-Validation für diese Fallstudie zu umfangreich ist, wird auf eine einfache „hold-out“ Methode gesetzt. Nach Provost und Fawcett (2013, S. 113) muss bei der „holdout“ lediglich ein Teil der bekannten Daten ausgelassen, also nicht zum Training genutzt, werden und später der Modelltest auf eben diese ausgelassenen Daten angewendet werden. Findet der Test gegen die ausgelassenen Daten statt, spricht man von der Generalisierungsgenauigkeit. Die ausgelassenen Daten werden in diesem Kontext auch „test set“ genannt.

Modellerstellung

In der Modellerstellung wird nun ein multiples lineares Regressionsmodell erstellt, um einen ersten Einblick auf die Daten zu erlangen und gewisse Aussagen zu der Aussagekräftigkeit einzelner Einflussfaktoren tätigen zu können. Dieses Vorwissen fließt anschließend einerseits in ein neues lineares Modell und andererseits in ein Modell mittels prophet-forecasting model. Diese beiden Modelle werden mit den gleichen Basisdaten (Paket FIBU, Anrufe) erstellt und gegen das „test set“ Oktober 2019 getestet.

In der ersten Phase der Modellierung wurde ein multiples lineares Regressionsmodell erstellt. Das Datenset „df_support.csv“ ist der in der Datenvorbereitungsphase definierte Datenträger und wird als CSV-Objekt eingelesen. Zur weiteren Datenverarbeitung würde noch jener Schritt im Code zählen, wenn die metrischen Werte Tag, Kalenderwoche, Monat und Jahr in eine Intervallskala umgewandelt werden. Dafür wird die R Funktion „as.Date.factor“ genutzt. Hintergrund ist jener, dass die Tage eines Monats oder die Monate eines Jahres zwar Zahlenwerte sind, aber keine Gewichtung wie „größer/kleiner“, „weniger/mehr“ oder „besser/schlechter“ sinnvoll möglich ist, daher werden die Werte als Datum zu einer Intervallskala (Cleff, 2012, S. 21). Weiters werden mit der R Funktion „relevel“ die Basisfälle für den Intercept je auf „Nein“ gesetzt. In einem ersten Modell wird die zufällig ausgewählte, abhängige Variable „FIBU.Anrufe“ in Zusammenhang mit den unabhängigen Variablen Datum, Vollmond, Ferien, Feiertag, Halbtage und SCR aller untersuchten Pakete gesetzt. Über die „summary“-Funktion werden die beschriebenen Kennzahlen des Regressionsmodells dargestellt.

- RSE: ~ 68,7
- R-squared: ~ 0,5
- F-statistic: ~ 120

In einem einfachen Modell bietet die Aussagekraft des RSE nur bedingt einen Mehrwert, da diese Kennzahl hauptsächlich dafür genutzt wird, mehrere Modelle miteinander zu vergleichen. Daher wird keine Aussage über die ~ 68,7 getroffen. Der R-squared von ~ 0,5 besagt, dass dieses Modell die Varianz der Y Variable (Anzahl der Telefonate FIBU) mithilfe der unabhängigen Variablen X zu 50% erklären kann. Dies bedeutet, dass die unabhängigen Variablen grundsätzlich dafür geeignet sind, Y vorherzusagen, jedoch eindeutig noch weitere Variable fehlen, um Y genauer vorherzusagen zu können. Es kann auch bedeuten, dass eingesetzte Variable anders genutzt werden müssen. Die F-statistic von ~ 120 besagt, dass ein Zusammenhang zwischen den Einflussvariablen auf die Anzahl der Anrufe besteht. Unter Berücksichtigung von 10 Freiheitsgraden bei 1205 Datensätzen ist dies ein signifikanter Wert, da der p-wert $< 2,2e^{-16}$ beträgt.

Koeffizient	Estimate (Steigung der Regressionslinie)	Signifikanz
Intercept (Basisfall)	867,9	> 99,9%
Datum	-0,031	> 99,9%
Vollmond – Ja	-0,2811	
Ferien – Ja	-30,60	> 99,9%
Feiertag – Ja	-58,59	> 99,9%
Halbtag – Ja	-131,3	> 99,9%
WWS.SCR	16,14e	> 99,9%
CRM.SCR	-0,1220	
BILANZ.SCR	0,5133e	> 95,0%
KORE.SCR	-1,465	
FIBU.SCR	2,298	

Tabelle 10: Auszug aus der Modellzusammenfassung aus dem ersten linearen Modell (eigene Aufbereitung)

Anhand der Koeffizienten lt. Tabelle 10, die die Steigung der jeweiligen unabhängigen Variablen beschreiben, würden folgende Aussagen auf dieses Modell zutreffen:

- Sowohl der Vollmond als auch Feiertage, Ferienzeiten und Halbtage wirken sich negativ auf das vorhergesagte Telefonaufkommen aus.
- Gleichzeitig lässt sich anhand des Datumskoeffizienten sagen, dass die Tendenz des Supportaufkommens sinkend ist, wenn auch nur sehr schwach.
- Die SCR der Pakete WWS, BILANZ und FIBU wirken sich positiv auf das Telefonaufkommen aus und jene SCR der Pakete CRM und KORE negativ.

Die Signifikanzcodes offenbaren, dass die ermittelten Werte für Intercept, Datum, Ferien, Feiertage, Halbtage, WWS.SCR zu 100 %iger Sicherheit signifikant sind. Die Kategorie BIL.SCR ist immerhin zu 95 %iger Sicherheit signifikant. Alle anderen Koeffizienten sind nicht signifikant.

R bietet für die Bewertung von Koeffizienten hinsichtlich ihrer Aussagekraft auf Y eine eigene Funktion namens „drop1“. Diese Funktion liefert je Koeffizienten, die Kennzahlen Residual Sum-Of-Squares (RSS) und Akaike's Information Criterion (AIC), welche vereinfacht aussagen, inwiefern die Modellqualität steigt oder sinkt, wenn der Koeffizient aus dem Modell entfernt wird (R Documentation, 2019). Demnach bedeutet der höchste AIC Wert, die meiste Aussagekraft eines Koeffizienten. Die folgende Tabelle 11 zeigt den Output der Funktion „drop1“, sortiert nach AIC:

Koeffizient	RSS	AIC
Vollmond	5685252	10295
CRM.SCR	5685830	10295
FIBU.SCR	5690604	10296
KORE.SCR	5693969	10297
<none>	5685243	10297
BILANZ.SCR	5704385	10299
WWS.SCR	5842924	10328
Ferien	5933748	10347
Datum	5985702	10358
Feiertag	6292067	10419
Halbtag	9065425	10863

Tabelle 11: Ergebnis der Funktion *drop1*, sortiert aufsteigend nach AIC (eigene Aufbereitung)

Das Ergebnis dieser Auswertung besagt, dass die Ausprägung Halbtag (die grundsätzlich die Freitage identifiziert) die meiste Erklärungskraft des Modells besitzt. Dies ist definitiv nachvollziehbar, da freitags die Hotline-Zeit um 4 Stunden kürzer ist als an den restlichen Werktagen. Dass sowohl Wochen, in denen sich Feiertage befinden als auch Ferienwochen Einfluss auf die Aussagekraft des Modells haben werden, war aufgrund der Interviews zu erwarten. Dass nun die Variable Feiertagswoche mehr Aussagekraft als die Ferienwoche besitzt, ist definitiv eine neue Information. Natürlich spielt auch das Datum eine signifikante Rolle in diesem Modell.

Diese Auswertung zeigt auch, dass gewisse Variablen nur sehr wenig Aussagekraft im Modell besitzen. In diesem Fall gibt es sogar Variablen, die die Aussagekraft des Modells verschlechtern, wie die Variablen Vollmond, CRM.SCR, FIBU.SCR und KORE.SCR. In weiteren Modelltests muss überlegt werden, ob diese Variablen überhaupt noch ins Modell aufgenommen werden sollen. Da der Großteil der SCR-Kennzeichen zu diesen schwachen Variablen gehört, muss überlegt werden, ob diese nicht generell aus den Modelltests entfernt werden. Wie im Datenverständnis beschrieben, kann nicht sichergestellt werden, dass die Updates auch eingeplant werden. Um diesen Faktor richtig einbeziehen zu können, müsste in einer eigenen Studie das Updateverhalten der KundInnen genauer analysiert werden, um auch weitere Aussagen darüber treffen zu können, wann die Auswirkungen von SCRs im Supportaufkommen spürbar werden.

Basierend auf diesen Ergebnissen wurde ein weiteres lineares Modell (*model2*) mit dem Zweck der Datenvorhersage erstellt. Dieses enthält lediglich die unabhängigen Variablen Datum, Feiertag, Ferien und Halbtag). In einer „holdout“ Validierung wird nun dieses Modell mit den Trainingsdaten bis zum 30. September 2019 („training set“) befüllt und gegen die tatsächlichen Werte aus den Werktagen im Oktober („test set“) getestet.

Es wurden Vorhersagewerte mittels der „predict“-Funktion erstellt. Dafür wurden alle Oktober-Werktage als Intervall angegeben und die weiteren Variablen Feiertag und Halbtage wie im Datenträger befüllt. Die summierte Differenz der vorhergesagten Anrufe zu den tatsächlichen Anrufen liegt bei etwa 590.

Für die Modellierung des prophet-Modells wurde ein eigener Datenträger „forecast_prophet.csv“ angelegt. Im Gegensatz zum ersten Datenträger enthält dieser auch jene Tage an denen grundsätzlich nicht gearbeitet wird (Samstag, Sonntag, Feiertag) und das Datum im Format „YYYY-MM-DD“, dies fordert prophet für die Modellerstellung. Als direkte Vorbereitung für die spätere „holdout“ Validierung, werden vom Dataset nur die Daten vom 01.01.2015 – 30.09.2019 eingelesen.

Die Variable „df.model.fit“ wird auf die für das Modell relevanten Spalten reduziert. Schließlich werden die Werte für Feiertag und Ferien bis inkl. Oktober 2019 für die spätere Vorhersage geladen. An dieser Stelle fließt wieder das Vorwissen aus der ersten linearen Regression ein, daher werden nur diese Variablen für die Modellerstellung genutzt.

In drei Schritten wird das Modell schließlich erstellt und in der Variablen „m“ gesichert:

- Prophet(): Erstellt eine neue Modellhülle für die prophet-Vorhersage.
- Add_regressor(): Grundsätzlich reichen für ein valides prophet-Modell die unabhängige Variable Datum und die abhängige Variable Anrufe.FIBU. Mittels Add_regressor() lässt sich das Modell um weitere Variablen erweitern.
- Fit.prophet(): Diese Funktion trainiert schließlich mit den übermittelten Daten und liefert das Vorhersagemodell als Ergebnis.

Nach der Modellerstellung werden die Zukunftsdatensätze präpariert. Prophet liefert mit make_future_dataframe() bereits eine Vorlage, die mit den vorher gesicherten tatsächlichen Werten für Feiertag und Ferien ergänzt werden.

Die Predict()-Funktion ermittelt nun die Vorhersageergebnisse. Prophet liefert zur visuellen Darstellung des Modells und der Vorhersageergebnisse den Plot aus Abbildung 8 und 9. In Abbildung 8 ist eine Parallele zum ersten linearen Modell auffallend. Nach einem Hoch zu Beginn des Jahres 2015 ist der Trend bis 2020 fallend. Auch die Interpretation des ersten linearen Modells hat ergeben, dass der Koeffizient Datum eine leicht negative Steigung aufweist.




Abbildung 8: Darstellung des Jahrestrends mittels prophet-Modell (eigene Aufbereitung)

Ein deutliches Bild über die Telefonaufkommensverteilung liefert Abbildung 9. Das Modell hat ohne eigene Variable für Halbtage oder Wochenenden erkannt, dass freitags das Supportauf-

kommen deutlich niedriger als an den anderen Tagen ist. Obendrein ist gut dargestellt, dass samstags und sonntags kein Hotlinebetrieb stattfindet. Der Jahresgraph zeigt mit beeindruckender Genauigkeit, wie das Supportaufkommen über das Jahr verteilt ist. Deutlich ersichtlich sind beispielsweise das niedrige Supportaufkommen über die Sommermonate und der Anstieg zu Jahresbeginn mit der Spitze etwa Mitte März.

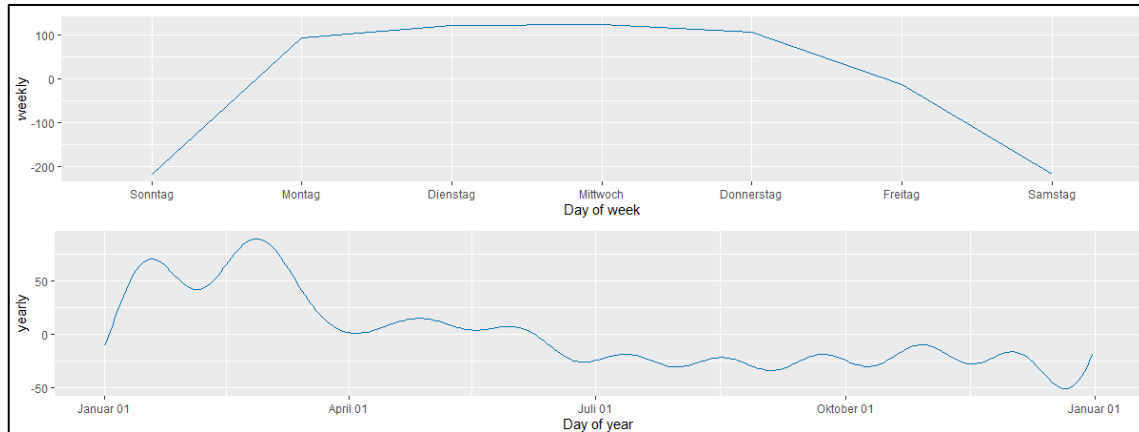


Abbildung 9: Prophet Vorhersage Plot mit Wochendaten und Jahresdaten (eigene Aufbereitung)

Auch wenn prophet eine integrierte Funktion für eine Cross Validierung bereitstellt, wurde der Modelltest wieder mittels „holdout“ Validierung und dem „test set“ Oktober durchgeführt. Da die Vorhersagen für Samstage und Sonntage negativ dargestellt werden, wurden diese in einem ersten Schritt gegen 0-Werte ausgetauscht. Anschließend wurde die gleiche Rechnung wie beim linearen Modell durchgeführt. Die summierte Differenz der vorhergesagten Anrufe zu den tatsächlichen Anrufen liegt beim prophet-Modell bei etwa -90.

Modellbewertung

Abschließend bleibt letztlich die Bewertung der beiden Vorhersagemodelle. Ausgehend vom Setup der Entwicklungsumgebung ist zu sagen, dass die Installation der R Packages „rstan“ und „prophet“ nur nach der Installation eines externen Programms „RTools“ möglich ist. Ein solches Modell zum Deployment im Web könnte also Probleme mit sich bringen. In diesem Punkt hat das lineare Modell seine Stärke, da es mit den RStudio-Bordmitteln funktioniert.

In Bezug auf die Handhabung des Modells inkl. Vorhersage und Auswertungsmöglichkeiten ragt Facebook’s prophet klar hervor. Dies ist vor allem bei der Vorhersage sichtbar. Beim prophet-Modell sind deutlich weniger Codezeilen für eine Vorhersage notwendig als beim linearen Modell.

Letztendlich ist das Ergebnis der tatsächlichen Vorhersage die wichtigste Messgröße. Im Vergleichsbeispiel wurden die jeweiligen Differenzen zwischen Vorhersage und tatsächlichem Wert aufsummiert. Im Vergleich zum linearen Modell, das auf ein Monat gesehen etwa 590 Telefonate zu viel vorhersagt, ist das prophet-Modell mit knapp 90 Telefonaten zu wenig deutlich genauer.

Die Modellbewertung findet aufgrund dieser drei Kriterien statt. Basierend auf den Bewertungen wird das prophet-Modell für diese Fallstudie in die nächste Phase der Evaluation gehen.

Evaluation

Nach der Modellierungsphase geht das DM-Projekt in eine Evaluationsphase über. Zu diesem Zeitpunkt wird das aktuelle DM-Modell mit den Projektzielen konfrontiert. Es folgt eine Prüfung, ob auch alle Geschäftsziele durch das Modell erfüllt werden können. Am Ende dieser Phase findet die Entscheidung statt, ob dieses Modell auch ausgeliefert werden kann. Nach Chapman et al. (2000) werden folgende Schritte in dieser Phase durchgeführt:

- Ergebnisse evaluieren
- den Prozess reflektieren
- nächste Schritte definieren

Ergebnisse evaluieren

Anhand des beschriebenen Geschäftsverständnisses wird das Modell nun den Geschäftszielen gegenübergestellt. Ziel des Projekts ist es, die Softwaresupportabteilung effizienter zu gestalten. Durch konkrete Vorhersagen des Telefonaufkommens können SupportmitarbeiterInnen gezielt für Hotlinetätigkeiten eingeplant werden und so effizienter ihre Arbeit verrichten. In der ersten Phase der Einführung von Data Mining im Support ist keine Integration des Modells in ein bestehendes System notwendig.

Es wurden jedoch nicht alle Ziele restlos vom prophet-Modell erfüllt. Auch wenn dieses Modell ohne umfangreiche Analyse der Einflussvariablen gute Vorhersagen liefert, so war die Vorhersage für den Monat Oktober 2019 insgesamt um etwa 90 Anrufe zu niedrig. Dies widerspricht dem DM Projektziel, dass das Vorhersagemodell nicht unter dem tatsächlichem Supportaufkommen liegen darf. Bei etwa 600 gemessenen Telefonaten in diesem Monat, entspricht dies aber lediglich einer Abweichung von 1,5 %. Die endgültige Bewertung dieses Ergebnisses obliegt dem Fallstudienpartner.

Da das Modell in der ersten Phase in kein bestehendes System eingegliedert werden muss, können die genannten Bedenken hinsichtlich Auslieferung vorerst vernachlässigt werden. Für eine Integration in eine Webanwendung muss auf jeden Fall eine Analyse der Voraussetzungen für die Lauffähigkeit erstellt werden.

Den Prozess reflektieren

Rückblickend kann das Ergebnis dieser Fallstudie durchaus positiv bewertet werden. Auch wenn einige behandelte Themen – wie der tatsächliche Einfluss der SCRs auf das Supportaufkommen – noch einer genaueren Analyse bedürfen, konnte dank eines starken Softwaretools ein brauchbares Data Mining-Modell erstellt werden. Nicht zuletzt aufgrund des Funktionsumfangs eines Softwaretools für DM-Algorithmen spielt dieses eine wesentliche Rolle bei der Durchführung von DM-Projekten. Die Software von RStudio besticht vor allem mit der großen Community der AnwenderInnen, die andere User mit Packages wie „rstan“ oder „prophet“ versorgen.

Nächste Schritte definieren

Für das Vorantreiben von DM-Algorithmen im Support sind die folgenden Schritte als nächste empfehlenswert:

- **Analyse der Anwendungsfälle:** Im Support gibt es eine breite Palette an Anwendungsmöglichkeiten für DM-Algorithmen. Abgesehen von Vorhersagen, können auch Klassifizierungen und Empfehlungen einen Mehrwert in der Abarbeitung von Supporttasks bieten. Wie in den Interviews ersichtlich, ist die Zeit während der Bearbeitung eines Tickets eine kritische Ressource. Jede Möglichkeit, schnelle, aber präzise Informationen zu gewinnen, ist im Support gern gesehen. Auch abseits des Hotline- und Ticketbetriebs konnten Anwendungsfälle ermittelt werden. Beispielsweise kann die Analyse von Ticketbearbeitungen Schulungsbedarfe oder Ineffizienzen im Vorgehensmodell der Ticketbearbeitungen aufzeigen. Um mit dem jeweiligen DM-Algorithmus auch die gewünschten Ziele zu erreichen, gilt es die Anwendungsfälle genau zu analysieren, um konkrete Anforderungen ableiten zu können.
- **Analyse der Datenmessungen:** Wie in der Bewertung der Anwendungsfälle durch die Interviews oder im Fallstudiensetup ersichtlich, ist die Datenmessung die Basis eines jeden DM-Projekts. Ad hoc können nur Analysen für jene Daten durchgeführt werden, die bereits seit Jahren gesammelt worden sind. Können diese Daten jedoch nicht passend für DM-Algorithmen eingesetzt werden, müssen neue Daten erhoben werden. Es empfiehlt sich also eine Analyse der Datenmessungen im Supportbetrieb, einerseits hinsichtlich kurzfristig geplanter Analysen, andererseits auch hinsichtlich potenziell nützlicher Analysen. Dabei ist auf jeden Fall darauf zu achten, dass die Daten in möglichst strukturierter Form abgelegt werden. In den Interviews wurde bemängelt, dass gewisse Daten ausschließlich textuell gespeichert werden. Mit diesen Daten sind Analysen weitaus aufwendiger.
- **Analyse der Einflussfaktoren:** Wie in der Modellierungsphase ersichtlich, kann der Modelltest ergeben, dass gewisse Variablen nicht die gewünschte Aussagekraft für den Vorhersagewert haben. Eine ausführliche Analyse der unabhängigen Variablen ist an dieser Stelle unerlässlich. Am Beispiel der SCRs lässt sich darüberhinaus ableiten, dass die Qualität der Daten mitunter die wichtigste Rolle im Data Mining spielt.
- **Analyse der Integrationsmöglichkeiten:** Hinsichtlich Deployment ist eine Analyse der Anforderungen an das DM-Modell notwendig. Ob das Modell online verfügbar sein soll, in eine Desktopapplikation integriert werden oder nur im Zuge eines Reports berechnet werden soll, muss schon vor Start des DM-Projekts definiert werden. Dies hat natürlich auch Auswirkung auf die Toolauswahl.

Auslieferung

In der Abschlussphase des CRISP-DM-Modells gilt es, die Auslieferung des Modells durchzuführen. Ziel ist es, das Modell dem Projektauftraggeber so zur Verfügung zu stellen, dass er

selbst nicht Datenanalytiker sein muss, um es bedienen zu können. Meist findet die Integration in ein anderes, bestehendes BI-System statt.

Chapman et al. (2000) definieren folgende Schritte für diese Abschlussphase:

- Auslieferung planen
- Darstellung und Wartung planen
- Abschlussreport erstellen
- Projekt reflektieren

Das Deployment, zu Deutsch Auslieferung, spielt in dieser Fallstudie keine Rolle, da das Vorhersagemodell in kein bestehendes System integriert wird und auch die Bedienung des Modells nicht manuell von MitarbeiterInnen stattfindet. In dieser Phase des Einführungsprozesses liegt der Fokus auf der Prüfung der Realisierbarkeit von DM-Modellen im Softwaresupport. Die Realisierbarkeit von DM-Modellen im Support kann durch diese Fallstudie belegt werden. Bei dem erstellten Modell ist zwar keine Wartung erforderlich, könnte aber einfach realisiert werden, indem tägliche Exporte der Telefonzahlen erstellt werden und das R Script täglich neue Vorhersagemodelle erstellt.

Das DM-Projekt kann nicht zuletzt aufgrund der gewonnenen Erkenntnisse erfolgreich abgeschlossen werden. Nachfolgend sind die Kommentare zu den produktiven Phasen angeführt:

- Geschäftsverständnis: In dieser initiativen Phase konnten schnell erste Zieldefinitionen anhand des Interviews mit dem Auftraggeber formuliert werden. Da zu diesem Zeitpunkt bereits klar war, welche Daten für die Analyse zur Verfügung stehen, mussten weitere Anwendungsmöglichkeiten für DM-Algorithmen gar nicht erst diskutiert werden. Für den Zweck dieser Fallstudie – einen ersten Test der Anwendbarkeit von DM-Algorithmen im Support durchzuführen – waren die vorhandenen Daten passend.
- Datenverständnis: In dieser sehr umfangreichen Phase konnte von den Aussagen aus dem Interview einiges an Information generiert werden. Einflussfaktoren konnten identifiziert werden und dazu passende Datensätze wurden erstellt. Der Einfluss des Wetters konnte jedoch nicht analysiert werden, da es keine öffentliche kostenfreie Wetterdatenbank gibt. Auch wurden andere Einflussfaktoren wie die Anzahl der SCRs nicht ausreichend aufbereitet. In der Folge mussten die Vorhersagemodelle ohne diese potenziellen Einflussgrößen gebildet werden.
- Datenvorbereitung: Diese Phase stellte sich im Nachhinein als essenziell für qualitative DM-Modelle heraus. Davon abgesehen, dass gewisse Softwaretools bestimmte Datenformate voraussetzen, spielt auch die Gestaltung des Datenträgers für die Modellierung eine wichtige Rolle. Genauer gesagt, fallen Datenvorbereitungen in der unhandlichen Programmierumgebung weg, wenn diese bereits im Datenset gespeichert sind.
- Datenmodellierung: Dies ist das Kernstück des CRISP-DM-Vorgehensmodells, denn in dieser Phase wird erkennbar, ob in den vorherigen Phasen sauber gearbeitet worden ist. Somit kann das DM-Projekt an dieser Stelle scheitern, wenn die Vorhersagekraft des

Modells zu schwach ist oder keine Modellierung aufgrund von Fehlern im Datenset stattfinden kann. Nach der Erstellung des linearen Modells und der Interpretation war schnell ersichtlich, dass das lineare Modell den Einfluss des Datums nicht korrekt einbeziehen kann. Nach kurzer Recherche konnte Facebook's prophet als spezielles Tool für diese Vorhersagen identifiziert und rasch installiert werden.

3.2.3 Fazit

Die Anwendung des CRISP-DM-Vorgehensmodells ist für weitere DM-Projekte empfehlenswert. Die Aufbereitung der einzelnen Phasen und deren Arbeitspakete nach Chapman et al (2000) bietet genügend Handlungsspielraum und führt die Anwenderin oder den Anwender zugleich effizient zur Projektauslieferung. Das Setup der Fallstudie, basierend auf den Anwendungsmöglichkeiten für DM-Algorithmen im Support und deren Bewertungen aus den Interviews, ergab relativ deutlich, dass mit den vorhandenen Daten nur eine Regressionsanalyse sinnvoll durchführbar wäre. Jegliche andere Anwendungsmöglichkeit hätte eine Phase der Datensammlung mit sich gebracht, welche im Zuge der Fallstudie nicht realisierbar war. Die Anwendung eines anderen DM-Algorithmus, beispielsweise einen Klassifikator, für das Vorhersageproblem heranzuziehen wurde aufgrund des bereits großen Umfangs der Fallstudie verworfen.

Die Ausführung des DM-Projekts endete mit durchaus positiven Ergebnissen, so konnte ein Vorhersagemodell für eine Fachgruppe des Softwaresupports erstellt werden, das täglich das erwartete Telefonaufkommen vorhersagt und dabei im Betrachtungszeitraum Oktober in Summe lediglich 1,5 % vom tatsächlichen Telefonaufkommen abwich. Es ist jedoch zu beachten, dass um 1,5% zu wenig vorhergesagt wurde, was den DM Projektzielen widerspricht, denn es wurde definiert, dass die Vorhersage nicht unterhalb des tatsächlichen Aufkommens liegen soll.

Davon abgesehen liefert das Vorhersagemodell eine realitätsgetreue Abbildung der Aufkommensverteilung innerhalb einer Woche und eines Jahres. Aus diesem Report konnten beispielsweise die schwachen Sommermonate, der Anstieg zu Jahresbeginn und die Spitze Mitte März dargestellt werden. In Bezug auf die Einflussfaktoren auf die Anzahl der täglichen Telefonate im Fachbereich FIBU lässt sich nach den Modelltests auch sagen, dass Wochen mit Feiertagen und Ferienwochen signifikanten Einfluss haben. Unwissenschaftliche Faktoren wie die Wirkung des Vollmonds haben hingegen keine Aussagekraft auf dieses Modell.

3.3 Zusammenfassung

Im experimentalen Setup konnten die Erkenntnisse aus der Literarturreche durch Input aus der Praxis angereichert werden. In den Experteninterviews zu den Themenblöcken Status quo im Support, KPIs und Datensammlung und Data Mining im Support stellte sich beispielsweise heraus, dass das multi-level Support Modell in der Realität nur als Vorlage dient, und in den verschiedensten Abwandlungen und Ausprägungen gelebt wird. In manchen Organisationen wird der First Level Support an die KundInnen ausgelagert, dafür gibt es einen Fourth Level Support, der organisatorisch nicht dem Support zugegliedert ist. In anderen Organisationen wird der First

und Second Level Support von derselben Person an der Hotline ausgeführt, in einer weiteren werden die Support Level nicht von MitarbeiterInnen, sondern von ganzen Teams ausgefüllt. Dies lässt sich einerseits durch den wachsenden Bedarf an Agilität und andererseits durch den verstärkten Fokus von Ressourcen auf Kundenanforderungen erklären. Ein Resultat aus diesem Wandel ist, dass Vorgehensmodelle aus dem IT-Servicemanagement an Bedeutung verlieren, da ihre starren Prozesse nicht an diese flexiblen Arbeitsweisen angepasst werden können. Neben der Organisationsform an sich differiert auch das Leistungsangebot. Nach den Interviewergebnissen ließe sich die Aussage tätigen, dass der Trend weg vom klassischen Callcenter in Richtung Ticketbearbeitung bzw. Rückrufhotline geht. Dies müsste aber in weiteren Studien untersucht werden.

Aus den Themen KPI und DM in Bezug auf den Support kann ergänzend zur Literatur erwähnt werden, dass vor allem Messungen zur Anfragenfrequenz und Anfragebearbeitung stattfinden. Unabhängig davon, in welchem Medium die Anfrage an den Support übermittelt wird, sind unter anderem die Anzahl der Anfragen, die Dauer bis zum Workaround und die Dauer bis zur Lösungsauslieferung verbreitete KPIs. Nicht zuletzt finden diese Messungen auch statt, um den Inhalten der Serviceverträge mit den KundInnen zu entsprechen. Den Trend zum Data Mining haben alle Interviewpartner bereits erkannt. Aus diesem Grund starten auch bereits die ersten Projekte zur Anwendung von DM-Algorithmen. Die Interviewpartner mussten aber dennoch einräumen, bei diesem Thema noch in den Kinderschuhen zu stecken.

Letztlich lieferten die Interviewpartner Bewertungen zu möglichen Anwendungsfeldern für DM-Algorithmen im Support, die in weiterer Folge in einer Fallstudie weiter behandelt wurden. Konkret wurden von den Interviewpartnern Klassifikationen für Tickets, Vorhersage von Supportaufkommen und Empfehlungen für Ticketbearbeitungen als potentielle Einsatzgebiete genannt. Anhand einer Fallstudie mit der Firma BMD Systemhaus GesmbH wurden diese drei Einsatzgebiete weiter auf ihre Einsatzfähigkeit hin analysiert und schließlich wurde die Vorhersage von Supportaufkommen als Anwendungsgebiet für die Fallstudie identifiziert. Ausschlaggebend für diese Entscheidung war die Tatsache, dass es nur für diesen Anwendungsfall strukturierte Daten der vergangenen Geschäftsjahre gab. In der Anwendung des CRISP-DM-Vorgehensmodells wurden also die Projektziele Vorhersagemodell für Supportaufkommen erstellen und einfache Bereitstellung für Tests ohne Integration in ein externes System aufgenommen.

Neben dem erfolgreichen Erstellen eines Vorhersagemodells mit dem R Package „prophet“, konnten auch gewisse Einflussfaktoren den Kategorien „aussagekräftig“ (Feiertage, Ferienwochen, Halbtage) und „nicht aussagekräftig“ (Wirkung des Vollmonds, Änderungen und Neuerungen durch Updates) zugeordnet werden. Letzteres geschah durch die Koeffizientenanalyse eines multiplen linearen Modells. Nachdem das „prophet“-Vorhersagemodell den Projektzielen entsprach, wurde es auch in der Phase der Bereitstellung dem Support für Tests zur Verfügung gestellt. Zusätzlich zu den guten Ergebnissen bei der Vorhersage von Werten überzeugte „prophet“ auch mit der deren Darstellung. An dieser Stelle seien die Plots in Abbildung 8 und 9 zur generellen Trendanalyse sowie Monats- und Jahrestrend zu nennen. Sie stellen in beeindruckender Genauigkeit die Realität dar.

Aufgrund dieser Eigenschaften des DM-Modells stellt sich an dieser Stelle die Frage, wie nahe die Vorhersage von erfahrenen Führungskräften im Support an der Wirklichkeit ist und ob das DM-Vorhersagemodell vergleichbare Vorhersagen liefern kann.

4 FELDEXPERIMENT

Das folgende Kapitel beinhaltet die Informationen zum Feldexperiment, indem die Vorhersagen des DM-Modells den Vorhersagen erfahrener Support Führungskräfte gegenübergestellt werden. Ziel ist es die – im vorherigen Kapitel – gestellte Frage, ob DM-Vorhersagemodelle die Realität genauso gut Abbilden und Vorhersagen können als erfahrene Führungskräfte im Support, zu beantworten. Gemessen werden beide Vorhersagen am tatsächlichen Supportaufkommen des Novembers 2019.

4.1 Vorgehen und Methodendesign Experiment

Als Partner des Experiments dient erneut die Firma BMD Systemhaus GesmbH. Für das Experiment wurde keine Laborumgebung geschaffen. Für die fünf Supportgruppen FIBU (Finanzbuchhaltung), KORE (Kostenrechnung und Controlling), BILANZ (Bilanz und Anlagenbuchhaltung), CRM (Customer Relationship Management) und WWS (Waren- und Lagerwirtschaft) wurden Vorhersagen zum Supportaufkommen aufgenommen. In Anlehnung an ein Feldexperiment wurde dabei versucht, das übliche Vorgehen bei der Ressourcenplanung nachzuahmen.

Als Basis für die Planung und Umsetzung des Experiments diente der Leitfaden für Experimente vom Bundesministerium für Bildung, Wissenschaft und Forschung (BMBWF, 2017). Dieser fordert die Deklaration von unabhängigen, abhängigen und Störvariablen sowie ein Statement zur internen und externen Validität.

- **Unabhängige Variable:** Beschreibt die Art und Weise, wie die Vorhersagen getätigt werden. In diesem Experiment fand das einerseits anhand der Erfahrung und des Vorgehens der Supportführungskräfte bei der Ressourcenplanung der Hotline statt, andererseits mittels des DM-Vorgehensmodells aus der Fallstudie.
- **Abhängige Variable:** Vorhersage des Supportaufkommens, aufgegliedert in Anzahl der Telefonate und Anzahl der Tickets pro Tag je Supportgruppe.
- **Störvariable:** Störend auf die Vorhersagen können sich bei den Supportführungskräften Erfahrungsunterschiede und die Haltung zum Experiment auswirken. Störvariablen bei der Modellvorhersage können falsche Trainingsdaten oder Ungenauigkeiten in der Modellerstellung sein.
- **Interne Validität:** Diese ist gegeben, wenn der gemessene Effekt auf die abhängige Variable tatsächlich aufgrund der Änderungen der unabhängigen Variablen entsteht. Sofern keine unerwarteten Störvariablen auftreten, ist die interne Validität aufgrund der Tatsache, dass zwei zur Gänze unterschiedliche Vorhersagevarianten genutzt werden, gegeben.

- Externe Validität: Diese ist gegeben, wenn sich die gemessenen Effekte gut verallgemeinern lassen. Um die externe Validität möglichst hoch zu halten, wurde keine eigene Laborumgebung für die Datenerhebung eingerichtet. Die Daten wurden aus der üblichen Planung der Personalressourcen erhoben. Um die externe Validität noch weitere voranzutreiben, würde sich eine weitere Messung in einer anderen Organisation anbieten. Dies wird aber für diese Arbeit nicht erwogen.

Der Umsetzungsplan für Experimente vom BMBWF (2017) sieht für den Ablauf von Experimenten grundsätzlich drei Phasen vor: die Planungs-, Durchführungs- und Auswertungsphase. Im Folgenden findet die Beantwortung der relevanten Fragen hinsichtlich Planungsphase eines Experiments statt:

1. Was soll mit der Durchführung des Experiments erreicht werden?
2. Wie findet die Überprüfung der Hypothese statt? Was genau wird gemessen und mit welcher Versuchsanordnung werden die abhängigen Variablen erfasst?
3. Gibt es nur eine unabhängige Variable, die verändert werden soll? Oder gibt es mehrere?
4. Wie sollen die unabhängigen Variablen verändert werden?
5. Welche Störvariablen können auftreten? Wie können sie ausgeschaltet werden?
6. Wo können Fehler entstehen?
7. Gibt es einen Zeitrahmen für das Experiment?
8. Wie findet die Auswahl der Testpersonen statt?

Im Zuge des Experiments soll geklärt werden, ob es möglich ist, das Supportaufkommen im Support – gemessen an der Anzahl der Anrufe und Tickets – mittels Data Mining-Algorithmen so vorherzusagen, dass ein Mehrwert gegenüber der herkömmlichen Planungsmethode, basierend auf Erfahrungen, entsteht. Aus dieser Fragestellung leitet sich nun die folgende gewagte Arbeitshypothese ab: Die Vorhersage des Supportaufkommens kann für den Monat November 2019, kann durch Data Mining-Algorithmen genauso gut oder besser durchgeführt werden als durch das erfahrungsbasierte Vorgehen von Support Führungskräften.

Die Überprüfung der Hypothese findet über einen Zweistichproben- t-Test statt (siehe Abschnitt 4.1.2). Dafür werden im Experiment tägliche Vorhersagen zum Telefon- und Supportaufkommen der Supportgruppen FIBU, KORE, BILANZ, CRM und WWS getroffen. Anschließend werden die Vorhersagen mit den tatsächlichen Supportzahlen der Tage verglichen. Die Differenz zwischen vorhergesagten und tatsächlichen Zahlen fließt schließlich in den t-Test ein. Um H_0 verwerfen zu können, müssten also die Differenzen der Data Mining-Vorhersagen deutlich niedriger sein als die der Führungskräftevorhersagen.

In diesem Experiment gibt es zeitlich bedingt nur eine unabhängige Variable, die verändert wird, nämlich die Art der Vorhersage. Und auch diese Variable wird nur in zwei Ausprägungen getes-

tet. In einem umfangreicheren Setup könnten mehrere Vorhersagemodelle genutzt und mehrere Zeiträume getestet werden.

Um Störvariablen zur Führungskräftevorhersage zu vermeiden, wird das Einzelgespräch mit den jeweiligen MitarbeiterInnen gesucht und die Aufgabenstellung klar erklärt. Schließlich werden die Vorhersagen ohne externes Eingreifen getätigt und in einer Textdatei abgespeichert. Gewisse Erfahrungsunterschiede können in diesem Schritt nicht vermieden werden, da MitarbeiterInnen mit unterschiedlichen Erfahrungsstufen als Führungskräfte eingesetzt werden. Das Data Mining-Vorhersagemodell basiert auf der Fallstudie dieser Arbeit. In der angedeuteten Cross Validation lieferte dieses Modell bereits überzeugende Ergebnisse.

Um Fehler zu vermeiden, wurden die möglichen Fehlerquellen unter der Beteiligung von Personen nach dem BMBWF (2017) analysiert. Zu den folgenden Punkten wurden in weiterer Folge Vorkehrungen getroffen:

- Die Versuchsleiterin des Experiments sieht und misst nur, was sie sehen will: Nach der Instruktion der Aufgabenstellung werden die Versuchspersonen angehalten, die Vorhersagen ohne externe Einflüsse durchzuführen. Weder die Versuchsleiterin noch andere MitarbeiterInnen können somit die Vorhersage manipulieren.
- Persönliche Einstellung und Meinung der Versuchspersonen zum Experiment: Dies kann nur zu einem gewissen Grad vermieden werden. Im Vorgespräch wurde klar kommuniziert, dass es sich um ein Experiment handelt, dass keine Auswirkung auf die Beurteilung der Führungskraft hat.
- Verwendung unterschiedlicher Messinstrumente: Alle Versuchspersonen führen die Vorhersage basierend auf ihren Erfahrungen als Führungskraft im Support durch. Festgehalten werden die Vorhersagen in einer Textdatei, die zur Analyse verwendet werden kann.
- Einseitige Selektion der Versuchspersonen: Dieser Fehler wird dadurch vermieden, dass die Auswahl der MitarbeiterInnen aufgrund ihrer jeweiligen Position als Supportführungskraft stattfindet. Die Versuchsleiterin hat also keinen Einfluss auf die Auswahl.

Als Zeitraum für das Experiment wird der 01. Oktober 2019 bis 31. Oktober 2019 ausgewählt, da die Vorhersagen für den Monat November getätigt werden sollten. Die Auswahl der Testpersonen erfolgt aufgrund ihrer Position als Führungskraft der jeweiligen Supportgruppe.

4.1.1 Aufgabenstellung

Die Führungskräfte müssen, ausgehend von Ihrer Ressourcenplanung für den Monat November, eine Vorhersage zum Supportaufkommen - aufgeteilt in Anzahl Telefonate und Anzahl Tickets - abgeben. Es wird extra erwähnt, das Vorgehen exakt so zu wählen, wie aktuell die Ressourcen an der Hotline geplant werden. Die Vorhersagen sind schließlich für jeden Werktag im November in eine Textdatei einzutragen. Als Anhaltspunkt für die Formatgerechte Schätzung dient die Vorlage inklusive Beispieldatensatz mit 120 Telefonaten und 50 Tickets (siehe Abbil-

dung 10). Die Aufgabenstellung ist bewusst einfach und ohne weitere Vorgaben gehalten, damit die Führungskräfte tatsächlich so schätzen, wie sie das üblicherweise praktizieren.

	CRM Telefon	CRM Ticket		
Beispiel	120	50		
04.11.2019				
05.11.2019				
06.11.2019				
07.11.2019				
08.11.2019				

Abbildung 10: Textdatei inkl. Beispieldatensatz für die Eingabe der Supportvorhersagen (eigene Aufbereitung)

4.1.2 Auswertung Führungskräfte

Der folgende Abschnitt enthält die Auswertung der Vorhersagen der Führungskräfte. Das Ergebnis dieses Schrittes sind zwei Textdateien (je eine Datei für Anrufe und Tickets) mit den Vorhersagen der Führungskräfte, den tatsächlichen Zahlen und der Abweichung in absoluten Zahlen.

Paket	Anrufe IST	Anrufe Führungskräfte	Anrufe Abweichung
FIBU	9.995	13.325	3.330
KORE	1.340	1.860	520
BILANZ	2.769	2.726	-43
CRM	3.592	3.420	-172
WWS	2.878	2.003	-875

Tabelle 12: Auswertung der Führungskräfte Vorhersagen – Anrufe (eigene Aufbereitung)

In Tabelle 12 ist ersichtlich, was bereits in den Interviews erwähnt wurde. Oftmals wird die Hotline so geplant, dass jedenfalls genügend MitarbeiterInnen eingeteilt sind. Wenn sie nicht ausgelastet sind, dann erledigen sie andere Arbeiten wie Softwaretests oder die Erstellung von Dokumentationen. Im Gegenteil dazu sieht man in den Supportgruppen CRM und WWS, dass jeweils zu wenige Ressourcen eingeplant wurden. Diese Diskrepanz wird sich in der durchschnittlichen Wartezeit widerspiegeln, denn wenn eine Supportgruppe tendenziell unterbesetzt ist, werden auch die Wartezeiten steigen. Demzufolge sind natürlich beides, die Überschreitung und die Unterschreitung zu vermeiden. In Anlehnung an die DM-Projektziele in Abschnitt 3.2.2 ist jedoch eine Überschreitung der Wirklichkeit zu präferieren. Dies wird jedoch keine Auswirkung auf den späteren Hypothesentest haben.

Bei der Vorhersage der Tickets tun sich offensichtlich alle Supportgruppen schwer, denn jede Gruppe hat tendenziell zu wenig Tickets vorhergesagt. Das kann nun daran liegen, dass man sich am bisherigen Durchschnittswert orientiert hat und es im laufenden Jahr eine Steigerung gab oder dass es kein ausgereiftes Vorgehensmodell zur Vorhersage der Supporttickets gibt. Tabelle 13 zeigt die teilweise drastischen Differenzen. Einzig in der Gruppe KORE funktioniert

die Vorhersage. Offensichtlich hat sich der Vorjahresschnitt von 7 Tickets pro Tag in 2019 lediglich auf etwa 8 erhöht.

Paket	Tickets IST	Tickets Führungskräfte	Tickets Abweichung
FIBU	1.148	1.000	-148
KORE	155	140	-15
BILANZ	306	174	-132
CRM	788	480	-308
WWS	556	304	-252

Tabelle 13: Auswertung der Führungskräfte Vorhersagen – Tickets (eigene Aufbereitung)

4.1.3 Auswertung DM-Vorhersagemodell

Für die Auswertung der Data Mining-Vorhersagen müssen zuerst je zwei Vorhersagemodelle für alle fünf Supportgruppen erstellt werden. Um die Daten weiterverarbeiten zu können, müssen sie in weiterer Folge auch exportiert werden.

Wie bei der Führungskräftevorhersage werden die Ergebnisse aus zehn einzelnen Dateien in eine Datei zusammengetragen und den tatsächlichen Werten gegenübergestellt. Im nächsten Schritt werden die Differenzen gebildet und aufsummiert, um einen schnellen Vergleich gegenüber den Führungskräftevorhersagen zu schaffen. In Tabelle 14 ist auf den ersten Blick ersichtlich, dass die Data Mining-Vorhersagemodelle deutlich niedrigere Differenzen aufweisen als die Führungskräftevorhersagen. Lediglich in der Supportgruppe Bilanz schneidet das Vorhersagemodell auffallend schlecht ab. Im Vergleich zu den Führungskräftevorhersagen fällt außerdem auf, dass lediglich die Vorhersage der WWS Telefonate unterhalb der Realität liegt.

Paket	Anrufe IST	Vorhersage Anrufe Führungskräfte	Vorhersage Anrufe Abweichung
FIBU	5.380	5.612	232
KORE	714	724	10
BILANZ	1.496	1.726	230
CRM	1.941	1.945	4
WWS	1.573	1.542	-31

Tabelle 14: Auswertung der Data Mining-Vorhersagen – Anrufe (eigene Aufbereitung)

Im Vergleich von Führungskräftevorhersagen und Tickets sind die Data Mining-Vorhersagen deutlich genauer. Selbst die vergleichsweise sehr gute Schätzung der KORE-Tickets (nur -15 daneben) konnte vom DM-Modell unterboten werden. Prozentuell gesehen ist die Vorhersage der FIBU-Tickets mit Abstand die beste. Diese Vorhersage weicht in der Betrachtung des gesamten Monats um 33 Stück ab. Bei einem monatlichen Ticketaufkommen von rund 1.150 Stück ist das eine Abweichung von 3 % (siehe Tabelle 15).

Paket	Tickets IST	Vorhersage Tickets Führungskräfte	Vorhersage Tickets Abweichung
FIBU	1.148	1.115	-33
KORE	155	145	-10
BILANZ	306	338	32
CRM	788	729	-59
WWS	556	488	-68

Tabelle 15: Auswertung der Data Mining-Vorhersagen – Tickets (eigene Aufbereitung)

Bereits die ersten Analysen zu den Vorhersagen bestärken die Annahme, dass die Data Mining-Modelle vergleichbare Vorhersagen wie Support Führungskräfte treffen können. Um das auch mit Gewissheit bekräftigen zu können, werden nun Hypothesentests zu den folgenden Hypothesen durchgeführt:

- Data Mining-Vorhersagemodelle können bezogen auf den Monat November 2019 genauere Vorhersagen zum Telefonaufkommen liefern als Führungskräfte im Support.
- Data Mining-Vorhersagemodelle können bezogen auf den Monat November 2019 genauere Vorhersagen zum Ticketaufkommen liefern als Führungskräfte im Support.

4.2 Statistische Auswertung und Hypothesentest

Die Auswahl einer statistischen Methode für den Hypothesentest findet aufgrund der Tatsachen statt, dass es sich um zwei Gruppen (ergibt sich aus den zwei Ausprägungen der unabhängigen Variable) handelt und die getätigten Messungen als Stichprobe für eine Gesamtheit an DM-Modell-Vorhersagen gelten. Eine valide Methode zur Auflösung solcher Zweistichprobenprobleme bietet der Zweistichproben-t-test (Falk, Hain, Marohn, Fischer, & Michel, 2014, S. 141). Dieser bietet die Möglichkeit, signifikante Unterschiede zwischen zwei Stichprobengruppen festzustellen.

4.2.1 Zweistichproben-t-Test

Um den Zweistichproben-t-Test nach Falk (Falk et al., 2014, S. 141) durchführen zu können, müssen die folgenden Parameter gegeben sein:

- Hypothese
- Testverteilung
- Testniveau
- Teststatistik

Aus den zwei definierten Forschungshypothesen werden nun mathematische Hypothesen abgeleitet. Dadurch ergeben sich zwei Wertebereiche, einer der H_0 als gültig erklärt und einer der

H_0 als ungültig erklärt. H_0 bedeutet in diesem Kontext die aktuell gültige Aussage, textuell wäre dies: „Führungskräfte können das Supportaufkommen durch ihre Erfahrungen im Durchschnitt besser vorhersagen als Data Mining-Modelle“. Der Wertebereich, der H_0 als ungültig erklärt, wird H_1 oder Gegenhypothese genannt (Falk et al., 2014, S. 141; Hedderich & Sachs, 2018, S. 299 f.; Moser 2018).

Der Zweistichproben-t-Test arbeitet mit der t-Verteilung. Diese umfasst durch das Hinzufügen der Freiheitsgrade einen größeren Gültigkeitsbereich als die vergleichbare Normalverteilung. Die t-Verteilung als Testverteilung wird als Basisverteilung der Prüfgrößen bei den folgenden Hypothesentests eingesetzt. Grundsätzlich werden die Freiheitsgrade beim t-Test durch die Formel $n - 1$ – also Anzahl der Werte n weniger Anzahl der Gruppen 1 – ermittelt. Beim Zweistichproben-t-Test erweitern sich die Gruppen, was die Formel: $n + n - 2$ ergibt (Falk et al., 2014, S. 141, (Hedderich & Sachs, 2018, S. 299 f.)

Bei Hypothesentests spricht man grundsätzlich von Fehlern –erster und zweiter Art, die vermieden werden sollen. Dabei beschreibt der Fehler erster Art, dass H_1 gültig ist, obwohl H_0 gültig wäre, es wird also etwas erkannt, was es de facto nicht gibt. Der Fehler zweiter Art beschreibt, dass H_0 nicht abgelehnt wird, obwohl H_1 gültig wäre. In diesem Fall wird etwas übersehen. Um diesen Fehlern vorzubeugen, wird ein Testniveau definiert. Vereinfacht ausgedrückt bedeutet dieses Testniveau: „Der erkannte Effekt ist zu XY % signifikant“. Für diesen Hypothesentest wird ein schwaches Testniveau von 5 % gewählt (Falk et al., 2014; S. 67, Moser 2018).

Nach Falk et al. (2014, S. 146 f.) ist die Teststatistik jene Methode, die aus den vorhergesagten Werten des Experiments eine geeignete Prüfgröße für den Zweistichproben-t-Test ermittelt. Für den Zweistichproben-t-Test bietet sich folgende – auf den Mittelwerten der Daten basierende – Formel an:

$$t = \frac{\bar{x}_{(1)} - \bar{x}_{(2)} - w_0}{\sqrt{\frac{n_{(1)}s_{(1)}^2 + n_{(2)}s_{(2)}^2}{n_{(1)} + n_{(2)} - 2}}} * \sqrt{\frac{n_{(1)} * n_{(2)}}{n_{(1)} + n_{(2)}}}$$

Formel 3: Ermittlung der Teststatistik für den Zweistichproben-t-Test (vgl. Falk et al. (2014, S. 146 f.)

Falk et al. (2014, S. 146 f.) benennen die Inhalte der Formel wie folgt:

- Der Mittelwert (\bar{x}) wird auch Durchschnitt genannt und beschreibt die Summe der Werte einer Gruppe durch die Anzahl dergleichen.
- Die Prüfvariable (w_0) wird schlagend, wenn in der Hypothese eine Bedingung formuliert wird. Ein Beispiel dazu wäre: „DM-Algorithmen sagen Supportaufkommen um 20 % besser vorher als erfahrene Führungskräfte“. Diese Variable findet in diesem Testdesign keine Anwendung, daher wird der Wert 0 eingesetzt.

- Mit der Stichprobenvarianz ($s_{(1)}^2$) wird die Streuung der Werte einer Gruppe gemessen. Sie berechnet sich durch folgende Formel: $\frac{\sum(x_n - \bar{x})^2}{n-1}$

4.2.2 Hypothesentest Vorbereitung

Falk et al. (2014, S. 146 ff.) beschreiben die Durchführung eines Hypothesentests anhand von vier Phasen:

- Aufstellen von H_0 und H_1
- Identifizierung der Testart (linksseitig oder rechtsseitig)
- Teststatistik ermitteln
- Kritischen Wert ermitteln

Um eine mathematische Hypothese aufstellen zu können, muss die Forschungshypothese aus ihrer textuellen Form mit Variablen und Vergleichszeichen versehen werden. Meist beschreibt eine Hypothese das Verhältnis ($<$, $>$, $=$) zwischen zwei Variablen x und y . In manchen Fällen wird in Hypothesen auch eine bestimmte Gewichtung des Verhältnisses definiert, dies muss zu den Variablen X oder Y ergänzt werden (Hedderich & Sachs, 2018, S. 298 - 301; Moser, 2018).

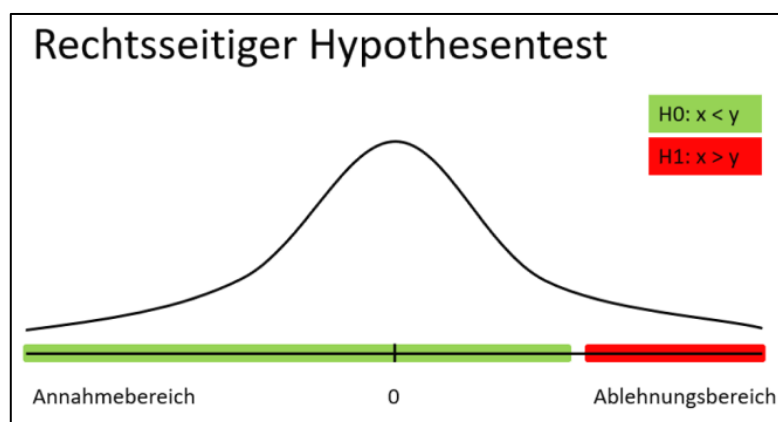


Abbildung 11: Bildliche Darstellung von H_0 und H_1 für einen rechtsseitigen Test (in Anlehnung an Hedderich & Sachs, 2018, S. 300, Graphik aus Moser, 2018)

Beispielsweise $H_0: x \geq y + 40$, wenn in der Hypothese definiert ist, dass x um mindestens 40 größer ist als y . Durch die mathematische Darstellung von H_0 ergibt sich automatisch H_1 , die Gegenhypothese, indem der Gegenwert des Vergleichszeichens herangezogen wird. Um das obige Beispiel fortzusetzen: $H_1: x < y + 40$, dies ist gleichzeitig der Ablehnungsbereich. H_1 definiert somit auch, ob ein rechtsseitiger oder ein linksseitiger Hypothesentest durchgeführt werden muss. Muss der Ablehnungsbereich signifikant größer sein, spricht man von einem rechtsseitigen Test, muss der Ablehnungsbereich signifikant kleiner sein, spricht man von einem linksseitigen Test (vgl. Abbildung 11). Im Hypothesentest werden x und y durch die Teststatistik und den kritischen Wert vertreten. Erstere errechnet sich durch Einsetzen in die oben beschriebene Formel für den Zweistichproben-t-Test. Der kritische Wert ist unter Berücksichtigung der

Freiheitsgrade aus der Tabelle zur T-Verteilung zu entnehmen (Hedderich & Sachs, 2018, S. 298 - 301; Moser, 2018).

4.2.3 Hypothesentest Durchführung

Abgeleitet von der ersten Hypothese: Data Mining-Vorhersagemodelle können bezogen auf das Monat November 2019 genauere Vorhersagen zum Telefonaufkommen liefern als Führungskräfte im Support, wobei genauere Vorhersagen bedeutet, dass die Differenz der Vorhersage zum tatsächlichen Wert kleiner ist, es entsteht die Hypothese: $H_0: \bar{x}_{(1)} < \bar{x}_{(2)}$ und die Gegenhypothese: Hypothese: $H_1: \bar{x}_{(1)} > \bar{x}_{(2)}$.

Anrufe		Tickets	
n	100	n	100
FK		FK	
Mittelwert	29,68	Mittelwert	10,15
Varianz	1144,886465	Varianz	72,16919192
DM		DM	
Mittelwert	11	Mittelwert	5
Varianz	146	Varianz	22
Teststatistik	178,6511746	Teststatistik	22,05150643
Wert a. T-Tabe	1,653	Wert a. T-Tabe	1,653

Abbildung 12: Gegenüberstellung der Teststatistiken Anrufe und Tickets der Gruppen Führungskräfte (FK) und Data Mining-Modell (DM) (eigene Aufbereitung)

Dabei bedeutet $\bar{x}_{(1)}$ die Differenz der Führungskräftevorhersage zum tatsächlichen Aufkommen und $\bar{x}_{(2)}$ die Differenz der DM Modell-Vorhersage zum tatsächlichen Aufkommen. Um H_0 zu verwerfen, muss die Differenz der Führungskräftevorhersage damit signifikant größer sein. Damit ist ein einfacher rechtsseitiger Hypothesentest notwendig.

Wie in Abbildung 12 ersichtlich, ergibt sich für $\bar{x}_{(1)}$ der Wert 29,68 und für $\bar{x}_{(2)}$ der Wert 11. Die Stichproben sind in beiden Gruppen 100, woraus sich nun die Varianz der Gruppe 1 mit 1144,89 und der Gruppe 2 mit 146 errechnen lässt. Eingesetzt in die Formel für die Teststatistik ergibt dies den Wert 178,65. Die Teststatistik wird jetzt mit dem Referenzwert aus der T-Tabelle für 200 Freiheitsgrade und einem Signifikanzniveau von 5 % verglichen. Da die Teststatistik mit 178,65 größer ist als der Wert aus der T-Tabelle mit 1,653, kann H_0 verworfen werden und H_1 gilt.

Für die zweite Hypothese „Data Mining-Vorhersagemodelle können bezogen auf das Monat November 2019 genauere Vorhersagen zum Ticketaufkommen liefern als Führungskräfte im Support“ gilt die gleiche Vorgehensweise. Aufgrund der Formulierung der textuellen Hypothese ergibt sich folgende mathematische Hypothese: $H_0: \bar{x}_{(1)} < \bar{x}_{(2)}$. Auch bei diesen Werten wird ein einfacher rechtsseitiger Hypothesentest durchgeführt. Wenn die Teststatistik größer als der Referenzwert aus der T-Tabelle ist, kann H_0 verworfen werden.

Aus Abbildung 12 können die Werte für diesen Hypothesentest entnommen werden. Aus $\bar{x}_{(1)}$ von 10,15, einem $\bar{x}_{(2)}$ von 5 sowie dem n von 100 lassen sich die Varianzen für die Gruppe 1: 72,17 sowie für Gruppe 2: 22 errechnen. Mit 200 Freiheitsgraden und einem Signifikanzniveau von 5 % gilt der Referenzwert aus der T-Tabelle von 1,653. Da die Teststatistik mit 22,05 größer ist als 1,653 kann H_0 verworfen werden und H_1 gilt.

4.3 Zusammenfassung

In diesem Kapitel wurde ein Experiment mit der Firma BMD Systemhaus GesmbH mit anschließender statistischer Auswertung inkl. Hypothesentest beschrieben. Nach einer anonymen Datenerhebung zur Vorhersage des Supportaufkommens mit erfahrenen Führungskräften im Softwaresupport wurden für dieselbe Periode (November 2019) Vorhersagen mit dem Data Mining-Modell aus der Fallstudie in Kapitel 3 durchgeführt. Die Datenerhebung fand für die Supportgruppen FIBU, KORE, BILANZ, WWS und CRM getrennt statt.

Nach der Erhebung der Daten fand eine Gegenüberstellung der Vorhergesagten Werte und der tatsächlich gemessenen Werte des Monats November 2019 statt. Bereits nach Aufsummierung der Vorhersagen verdichtete sich die Annahme, dass die Vorhersage der DM-Modelle im Vergleich zu den Führungskräften sehr gut abschneiden kann.

Für die Analyse der Daten mittels Zweistichproben-t-Test musste außerdem in diesem Kapitel noch statistischer Literaturinput zusammengetragen werden.

Im Zuge des Zweistichproben-t-Tests wurden zwei Hypothesentests für die folgenden Hypothesen durchgeführt:

- Data Mining-Vorhersagemodelle können bezogen auf das Monat November 2019 genauere Vorhersagen zum Telefonaufkommen liefern als Führungskräfte im Support.
- Data Mining-Vorhersagemodelle können bezogen auf das Monat November 2019 genauere Vorhersagen zum Ticketaufkommen liefern als Führungskräfte im Support.

Das Data Mining-Vorhersagemodell lieferte in allen Paketen gute Vorhersagen. Dieser Fakt wurde schließlich mit dem zweimaligen Verwerfen der H_0 bestätigt. In beiden Fällen kann davon ausgegangen werden, dass das DM-Vorhersagemodell unter den gegebenen Voraussetzungen, die Supportaufkommen im Durchschnitt genauer vorhersagen kann als erfahrene Supportführungskräfte.

5 FAZIT/AUSBLICK

In dieser Arbeit wurde die Anwendung von Data Mining-Algorithmen zur Informationsgewinnung im Softwaresupport mittels einer Regressionsanalyse untersucht. Dafür wurden in vier Kapiteln der Inhalt der Arbeit vorgestellt, eine Literaturrecherche durchgeführt, das Experimental Setup aufgesetzt und schließlich ein Experiment mit Hypothesentest durchgeführt.

Die Literaturrecherche mit Fokus auf die relevanten Themen Informationsgewinnung, Data Mining und Softwaresupport lieferte den Basisinput und die Begriffsabgrenzungen für die gesamte Arbeit. Vor allem die Begriffsabgrenzungen halfen unter der Flut von Buzzwords wie Data Mining, Data Science, Business Intelligence oder Artificial Intelligence den Durchblick zu bewahren. Um dies zu bewerkstelligen, musste zuerst eine Definition dafür gefunden werden, was Information oder Wissen eigentlich ist. Als erprobtes Mittel zur Veranschaulichung der Unterschiede zwischen Information und Wissen wurde die Wissenstreppe nach North herangezogen, ehe auf den Knowledge Discovery Prozess, der 1996 erstmals von Fayyad et. al. beschrieben wurde, eingegangen wurde.

Schon 1996 war den Forschern bewusst, dass die steigende Menge an Daten in Datenbanken rasch nicht mehr einfach und manuell zu analysieren sein würde. Daher wurde ein Prozess entwickelt, der zum Ziel hatte, low-level data in high level knowledge zu verwandeln. Wie erwartet, haben sich seit 1996 die jährlich produzierten Datenmengen um ein Vielfaches erhöht. Um diese Flut an Daten bewältigen zu können, mussten die Hardwarehersteller ihren Beitrag leisten. So hat sich beispielsweise die maximale Speicherkapazität einer Festplatte von zwei Gigabyte (1996) auf 8000 Gigabyte, oder auch acht Terabyte (2019) erhöht, was dem Viertausendfachen entspricht. Abgesehen von den Datenmengen, hat sich auch das Management in Unternehmen weiterentwickelt. Vor allem Teamstrukturen und Projektorganisationen fordern auch von der Datenanalyse ein projektähnliches Vorgehen. Nicht zuletzt aus diesen Forderungen entwickelte sich der Cross Industries Standard Prozess for Data Mining (CRISP-DM).

Dieses Vorgehensmodell orientiert sich zuerst an den Geschäftszielen und definiert früh Qualitätskriterien für das Deployment eines Data Mining-Modells, ehe die Umsetzung begonnen wird. Anhand der Anforderungen verlangt das Vorgehensmodell die Formulierung eines Data Mining-Problems, das im Zuge des Data Mining-Projekts gelöst werden soll. Dieses Geschäftsverständnis ist die Basis für alle folgenden Schritte wie das Definieren des Datenverständnisses und die Durchführung der Datenvorbereitung. Erst wenn dies im definierten Qualitätsausmaß stattgefunden hat, beginnt die Phase der Datenmodellierung. Diese beinhaltet die Auswahl der passenden Modellierungsmethode sowie der Testmethode, bevor die Modellerstellung und -bewertung in einem iterativen Zyklus durchgeführt werden. Wieder wird erst in die Phase der Evaluierung und Auslieferung übergeben, wenn alle relevanten Qualitätsmetriken erfüllt sind.

Bei der Auswahl der Modellierungsphase wird auf die vielen Aufgaben Bezug genommen, die Data Mining-Algorithmen durch unüberwachtes und überwachtes Lernen erfüllen können. Nur durch die korrekte Definition eines Data Mining-Problems ist somit gewährleistet, dass auch ein passender Data Mining-Algorithmus ausgewählt wird. Neben Klassifikations- und Regressionsproblemen können durch Data Mining auch Ähnlichkeitsabgleiche, Clustering oder Verbindungsvorhersagen durchgeführt werden.

Ob es auch Potenziale zum gewinnbringenden Einsatz von DM-Algorithmen auch im Support gibt, galt es gegen Ende dieses Kapitels zu klären. Dazu wurde zuerst die Struktur von Supportorganisationen durchleuchtet. Aus der Literatur ging hervor, dass im Support meist in einer multi-level Organisation, bestehend aus First, Second und Third Level Support gearbeitet wird. Auch einen Level 0 Support in Form von Produktdokumentationen und FAQ bieten Softwarehersteller üblicherweise an. Die weiteren Levels sind dadurch charakterisiert, dass ein aktiver Kundenkontakt mit MitarbeiterInnen der Organisation besteht und dass ungelöste Anfragen so lange in das nächste Level kaskadiert werden, bis die jeweilige Anfrage gelöst werden kann.

Abgesehen davon, wie die MitarbeiterInnen arbeiten, ergaben sich weitere Stellschrauben im Support, nämlich welche und wie viele MitarbeiterInnen arbeiten. Diese Stellschrauben beziehen sich einerseits auf Ausbildung und Schulung, sowie Kapazitätsplanung und -einsatz. Nach einem kurzen Exkurs in die Personaleinsatzplanung hat sich herausgestellt, dass der optimale Einsatz der Ressourcen einen großen Effekt auf die KundInnenzufriedenheit haben kann.

Kombiniert mit dem Angebot an Data Mining-Aufgaben, haben sich vor allem zwei Anwendungsgebiete herauskristallisiert, für die Data Mining im Support geeignet wären:

- Die Vorhersage von Supportaufkommen (Anrufe und Tickets)
- Unterstützung der Lösungswegfindung

Dem wurde in Kapitel 3 weiter auf den Grund gegangen. Zuerst wurden drei Experteninterviews mit erfahrenen Führungskräften im Softwaresupport geführt, um weitere Einblicke in die Domäne Support zu erlangen, aber auch den Faktor Realität wahrzunehmen. Angesprochen auf die Organisationsformen stellte sich schnell heraus, dass in der Praxis nicht unbedingt streng nach dem Kaskadensystem des multi-level Support Modells gearbeitet wird. In verschiedensten Ausprägungen werden beispielsweise Support Levels ausgelagert, zusammengefasst, erweitert oder auch gekürzt, je nachdem was die KundInnen fordern. Dies hat natürlich auch Auswirkungen auf den Ablauf und das Vorgehen bei Ticketbearbeitungen, die in jeder der befragten Organisationen unterschiedlich sind.

Was jedoch alle Organisationen gemeinsam haben, ist ein gewisser Druck beim Einhalten der Service Level Agreements (SLA). Dies sind gewisse Inhalte des Supportvertrags, die unter anderem Reaktionszeiten und Bearbeitungszeiten regeln. Offensichtlich ist es auch dieser Tatsache geschuldet, dass in diesem Bereich die meisten Datenaufzeichnungen stattfinden. Es ist naheliegend, dass Effizienzsteigerungen in diesen Bereichen vom Management gern gesehen sind und Supportorganisationen in diesen Bereichen erste Versuche für die Anwendung von Data Mining planen.

Sowohl der Fakt, dass es zu den Supportanfragen gute Datenaufzeichnungen gibt als auch die Tatsache, dass die Einhaltung der SLA von hoher Bedeutung im Support sind, haben beim Design der Fallstudie eine relevante Rolle gespielt. Gemeinsam mit dem Partner BMD Systemhaus GesmbH wurde das CRISP-DM-Vorgehensmodell mit echten Geschäftsdaten aus dem Support durchlaufen. Mit dem Ziel, die Anwendbarkeit für DM-Algorithmen im Support zu erforschen, wurde das Geschäftsziel „Vorhersage des Supportaufkommens in Form von Anzahl der Anrufe und Tickets“ definiert. Als Basis-Datenset wurden die Anruf- und Ticketzahlen ab dem 01.01.2015 herangezogen. Diese wurde um Einflussfaktoren wie Feiertage, Ferienwochen, Mondstellung und Softwareupdates erweitert. In einer ersten Modellierungsphase wurde deutlich, dass es sich nicht um ein einfaches Regressionsproblem handelt, das sich mit einer multiplen Regression lösen lässt. Dennoch hat die multiple Regressionsanalyse ergeben, dass gewisse Einflussfaktoren wie die Mondstellung, die Änderungen pro Update keinen nachvollziehbaren Einfluss auf das Supportaufkommen haben. An dieser Stelle sei erwähnt, dass eine umfangreiche Analyse der Einflussfaktoren auf das Supportaufkommen notwendig wäre, um noch detailliertere Daten in die Analyse einbeziehen zu können. Dies konnte im Umfang dieser Arbeit nicht durchgeführt werden.

Das Vorhersagemodell wurde schließlich mit dem „time-series forecasting“-Tool „prophet“ in der Entwicklungsumgebung RStudio durchgeführt. Dieses Tool analysiert das Datum nicht nur, um einen Jahrestrend zu erstellen, sondern ermittelt sogenannte „Turnpoints“, um das Auf und Ab innerhalb einer Periode festzuhalten. In einer „holdout“ Validierung konnte das prophet-Modell deutlich bessere Vorhersagen liefern als das multiple Regressionsmodell. Gut genug jedenfalls, um die Hypothese zu wagen, dass Data Mining-Vorhersagemodelle bessere Vorhersagen als erfahrene Supportführungskräfte erstellen könnten.

In einem Feldexperiment wurden zuerst Vorhersagen von erfahrenen Führungskräften im Support, die im Arbeitsalltag mit der Disposition Hotline- und Ticketressourcen beauftragt sind, für den Monat November 2019 eingeholt. Gleichzeitig wurden mit dem gleichen Vorhersagemodell der Fallstudie Vorhersagen getätigt. Im folgenden Zweistichproben-t-Test wurden die Abweichungen der Vorhersagen zu den tatsächlichen Supportaufkommen im November 2019 errechnet und für beide Bereiche, Hotline und Tickets, bestätigt, dass die Vorhersagen der Data Mining-Modelle signifikant genauer sind.

In diesem Sinne wäre eine mögliche Antwort auf die Forschungsfrage „Wie können Data Mining-Algorithmen im Softwaresupport gewinnbringend eingesetzt werden?“, dass sich durch die Vorhersage von Supportaufkommen mittels Data Mining-Algorithmen die Hotlinerressourcen zielgerichtet planen lassen und so einerseits Ineffizienzen bei Unterbeschäftigung und andererseits erhöhte Reaktionszeiten an der Hotline und bei der Ticketbearbeitung vermieden werden können. Betriebswirtschaftlich ließe sich der Mehrwert wie folgt argumentieren:

- Kostensenkung durch genauere Einteilung der Ressourcen im Support
- Umsatzsteigerung, da die frei gewordenen Ressourcen für Vorort- und Fernwartungsschulungen zur Verfügung stehen.
- Kundenzufriedenheit aufgrund angemessener Reaktionszeiten

- Angebot zusätzlicher Leistungen mit noch kürzeren Reaktionszeiten

Diese Darstellung ist nur eine von vielen möglichen Anwendungsfällen für den gewinnbringenden Einsatz von Data Mining im Support.

Einen Ausblick zur Entwicklung der schnell wachsenden Data Science im Bereich des Softwaresupports zu wagen, fällt denkbar schwer. Viele Faktoren können auf die Anwendung dieser Analysemethoden Einfluss nehmen. Beginnend mit der Datenaufzeichnung, die die Organisationen recht schnell vor große Herausforderungen stellen wird, da aktuell viele Daten unstrukturiert in textueller Form abgespeichert werden. Um DM-Modelle zur Unterstützung des Lösungsfindungsprozesses zu erstellen, muss die Lösungsfindung erst strukturiert, bestenfalls in Datenbanken, erfasst werden. Dies hat wiederum Einfluss auf den Arbeitsablauf vieler SupportmitarbeiterInnen. Die Einführung neuer DM-Modelle ist also mit viel Aufwand verbunden, wenn nicht schon zufällig strukturierte Daten vorhanden sind, die nur auf eine Analyse warten.

Gewisse DM-Modelle und -Algorithmen werden definitiv ihren Einsatz in Supportabteilungen finden, denn überall, wo MitarbeiterInnen „nur“ Entscheidungen, basierend auf den vorliegenden Daten treffen, könnte bereits ein DM-Algorithmus die Entscheidung treffen. Darüber hinaus gibt es im Support auch messbare Werte, die nicht zwingend die Interaktion von KundInnen und MitarbeiterInnen betreffen. So könnte die Lauffähigkeit einer Serverumgebung anhand der live gemessenen Kennzahlen bewertet werden oder die Logging-Protokolle einer Software ausgewertet werden, um potenzielle Fehlverhalten vorherzusagen. Abgesehen von den technischen Arbeitsinhalten können auch kaufmännische Analysen durchgeführt werden, die nicht zwingend von der Domäne Software beeinflusst werden. Damit sind allgemeine Einsatzgebiete wie KäuferInnenverhalten gemeint.

Im Kontext von Support und Softwareentwicklung können DM-Algorithmen nicht nur als Hilfsmittel im Support eingesetzt werden, sondern können auch ins Produkt selbst einfließen. Vorstellbar wären Kontrollmöglichkeiten der Eingaben, Kriminalitätsbekämpfung oder „time-series forecasts“ des Umsatzes, neuer Aufträge oder Abwanderung von KundInnen.

Inwiefern die Data Science nicht nur bei Softwareunternehmen, sondern branchenübergreifend Einzug nimmt, wird auch stark davon abhängen, ob Unternehmen dazu tendieren, selbst Data Scientists einzustellen oder diese Aufgaben an Drittanbieter auslagern möchten. Hier ergibt sich ein kritischer Interessenskonflikt bei Unternehmen, da der Aufbau von Know-how in neuen Unternehmensbereichen immer mit großen Aufwänden verbunden ist. Die Auslagerung dieser Tätigkeiten wäre jedoch mit der Ausgabe von teilweise äußerst sensiblen Unternehmensdaten und -geheimnissen verbunden.

ANHANG A - Interviewfragen

Wie sieht die Organisation Ihrer Supportabteilung aus? Wird ein multi-level Supportmodell (1st, 2nd, 3rd) gelebt?

Wird ein ITSM-Vorgehensmodell wie ITIL angewendet? Wie läuft sonst die Kommunikation zwischen 1st-, 2nd- und 3rd-Level-Support bzw. PM/Entwicklung ab?

Welches Leistungsangebot bietet ihre Supportabteilung? (Hotline, Ticket, etc.)

Nach welchem Vorgehen wird die Hotline besetzt? Gibt es dazu KPIs?

Wie entstehen diese KPIs? Welche Daten werden gesammelt und wie? Welche KPIs werden geführt und wie oft werden diese kontrolliert?

Werden dafür bestimmte Tools genutzt?

Gibt es Ansätze in Richtung Data Mining? Also nicht nur KPIs messen, sondern Vorhersagen treffen, Informationen generieren, etc.

Fragen aus Abschnitt 2.4.:

- Haben SupportmitarbeiterInnen im Arbeitsalltag genügend Zeit, um das Ergebnis einer Klassifizierungsvoraussage hinsichtlich Eskalationserwartung oder Problemursache abzuwarten?
- Gibt es bereits genügend Aufzeichnungen zur Lösungsfindung von Incidents, um einen Ähnlichkeitsabgleich oder eine Verbindungsvorhersage durchzuführen oder kann die Lösungsfindung überhaupt nachvollziehbar aufgezeichnet werden?
- Bietet die Vorhersage des Telefonaufkommens oder des Ticketsaufkommens tatsächlich einen Mehrwert in der Organisation einer Supportabteilung?

Einschätzungen zu den folgenden Ideen:

- Klassifizierung von Incidents
- Vorhersage von Supportaufkommen
- Lösungsempfehlungen für 1st Level (vgl. Kunden kaufen auch)
- Erkennung von Verhaltensmustern bei Kunden
- Programmverhaltensprofile, die Problemursachen preisgeben
- Vergleich des aktuellen Bearbeitungsverlaufs mit vergangenen Fällen (vgl. folgende Artikel werden oft gemeinsam gekauft)
- Analyse der 10 größten Kunden in einem Segment, Aussagen über das gesamte Segment
- Analyse, warum gewisse Tickets eskaliert werden mussten und vergleichbare nicht

ANHANG B - Interview Firma BMD Systemhaus GmbH

Wie sieht die Organisation Ihrer Supportabteilung aus? Wird ein multi-level Supportmodell (1st, 2nd, 3rd) gelebt?

Wird ein ITSM-Vorgehensmodell wie ITIL angewendet? Wie läuft sonst die Kommunikation zwischen 1st-, 2nd- und 3rd-Level-Support bzw. PM/Entwicklung ab?

Der BMD Support ist größtenteils im multi-level Support Modell gehalten. Vor allem im „Linien-support“ nach Fachbereich (RWC, CRM, WWS) dient der First Level Support als erste Anlaufstelle der KundInnen. Anfragen werden hauptsächlich via Telefon und Ticket (Mailverteiler) aufgenommen. Wenn Anfragen nicht sofort (Faustregel etwa 10 Minuten) gelöst werden können, wird entweder der Second Level Support direkt kontaktiert oder ein internes Second Level Ticket erstellt. In der Regel können an dieser Stelle alle Anfragen auch geschlossen werden. In seltenen Fällen, z. B. bei fachübergreifenden (RWC zu CRM, oder WWS zu RWC) oder technischen (Datenbank, Schnittstellen, etc.) Anfragen, wird schließlich der Third Level Support bemüht, der sich vor allem durch umfangreiches technisches und fachliches Wissen auszeichnet. Anfragen, die durch den Third Level Support bearbeitet werden, wandeln sich meist in einen Kundens Schulungstermin oder lösen eine sogenannte „Idee“, also einen Vorschlag zur Softwareerweiterung, aus. An dieser Stelle tritt der Third Level Support in Kontakt mit dem Produktmanagement und der Softwareentwicklung, um eine kontinuierliche Verbesserung des Produkts zu gewährleisten.

In sogenannten „fachübergreifenden Kundenteams“ wird der Linien-support nach Fachbereichen aufgebrochen und auch die Grenze zwischen First und Second Level Support verschwimmt. Diese Teams sind auf bestimmte Kundensegmente (nach Branchen) abgestimmt und versuchen so, optimal auf die Kundenbedürfnisse einzugehen. Da bei diesem System meist erfahrenere KollegInnen den Helpdesk besetzen, werden kaum Anfragen zu einem Second Level Ticket umgewandelt und aufgrund der fachübergreifenden Kompetenz ist auch der Rat des Third Level Supports weniger oft notwendig. Aufgrund der breiteren Anforderungen ist die interne Ausbildung in dieser Organisation aufwendiger, was zur Folge hat, dass diese Stellen meist intern durch erfahrene SupportkollegInnen aus der Linienorganisation besetzt werden.

Welches Leistungsangebot bietet Ihre Supportabteilung? (Hotline, Ticket, etc.)

Der BMD Support bietet den KundInnen zu den Hotlinezeiten stets kompetente AnsprechpartnerInnen, darüber hinaus ist jeder Fachbereich über einen E-Mail Verteiler, der in ein Ticketsystem mündet, erreichbar. Neben verschiedensten Dienstleistungsangeboten zu Schulungen und Seminaren setzt BMD auch auf Selbsthilfemaßnahmen. Neben FAQ, umfangreicher Onlineproduktbeschreibungen, Lernvideos und vielem mehr wird aktuell auch an einem Supportchatbot gearbeitet, der auf Basis der FAQ und der Onlineproduktbeschreibungen möglichst viele Anfragen bereits löst, bevor KundInnen zum Hörer greifen.

Nach welchem Vorgehen wird die Hotline besetzt? Gibt es dazu KPIs?

Grundsätzlich wird die Hotline vom jeweiligen Fachbereich disponiert, da pro Bereich unterschiedliche Spitzen auftreten. Beispielsweise ist das Rechnungswesen vor dem 15. eines Monats mit erhöhtem Supportaufkommen konfrontiert, da zu diesem Zeitpunkt die monatliche UVA fällig ist. Zum Ende eines Monats steigt dann das Aufkommen im Lohnsupport. Neben den gesetzlich bedingten Einflüssen spielen natürlich Faktoren wie der Jahreswechsel, Feiertage und Schulferien, sowie das Wetter eine relevante Rolle im Supportaufkommen. Manche KollegInnen behaupten sogar, dass der Vollmond einen Einfluss auf das Supportaufkommen hätte. In die Planung wird aber meist nur auf die gesetzlich gegebenen Faktoren, sowie Jahreswechsel und Feiertage/Ferientage Rücksicht genommen. Bei BMD ergibt sich durch den Jahreswechsel ein weiterer Faktor, da zu diesem Zeitpunkt auch das sogenannte Jahresupdate stattfindet. Unter allen Softwareupdates, die unter dem Jahr zur Verfügung stehen, beinhaltet dies die meisten Neuerungen und Änderungen.

Nachfrage: Was bedeutet bei BMD Supportaufkommen?

Supportaufkommen bedeutet bei BMD die Kombination aus dem Telefonaufkommen und den neuerstellten Tickets. Dabei sei aber zu beachten, dass sich das Telefonaufkommen nicht nur aus der Anzahl der Telefonate, sondern auch aus deren Dauer ergibt.

KPI Hotline: Durchschnittliche Wartezeit von KundInnen, Anzahl der Anrufe sowie Gesprächszeiten

Tickets: Anzahl neuer Tickets, durchschnittliche Dauer bis zur ersten Kontaktaufnahme sowie durchschnittliche Durchlaufzeit bis zum Schließen des Tickets

Wie entstehen diese KPIs? Welche Daten werden gesammelt und wie? Welche KPIs werden geführt und wie oft werden diese kontrolliert? Werden dafür bestimmte Tools genutzt?

Tickets werden im eigenen Tickettool getrackt, alle Telefonate an der Hotline werden einerseits durch die Queuing-Software und andererseits durch Telefonprotokolle im eigenen System festgehalten. Visualisiert werden diese KPIs im BI Tool QlikView®. Die Lösung der Anfragen wird in den Telefonprotokollen textuell dokumentiert. Eine strukturierte Sicherung dieser Lösungswege gibt es nicht.

In regelmäßigen Abständen werden diese Kennzahlen in den Supportgruppen analysiert, sie dienen folglich der weiteren Planung in den jeweiligen Fachbereichen

Gibt es Ansätze in Richtung Data Mining? Also nicht nur KPIs messen, sondern Vorhersagen treffen, Informationen generieren, etc.

Aktuell wird kein Data Mining im Support betrieben, es werden also auch keine Vorhersagen auf Basis von Daten oder ähnlichem getroffen

Haben SupportmitarbeiterInnen im Arbeitsalltag genügend Zeit, um das Ergebnis einer Klassifizierungsvorhersage hinsichtlich Eskalationserwartung oder Problemursache abzuwarten?

Parallel zum Telefonat müssen die SupportmitarbeiterInnen ohnehin ein Telefonprotokoll befüllen (dauert ca. 2 Minuten). Dies beinhaltet Informationen zur Kundin oder zum Kunden, zum

Inhalt des Telefonats und eine textuelle Beschreibung der Lösungsfindung. Eine Integration eines DM-Tools in dieses Protokoll, das die MitarbeiterInnen mit Informationen versorgt, wäre keine Zeitbelastung und damit auf jeden Fall wünschenswert.

Gibt es bereits genügend Aufzeichnungen zur Lösungsfindung von Incidents, um einen Ähnlichkeitsabgleich oder eine Verbindungsvorhersage durchzuführen oder kann die Lösungsfindung überhaupt nachvollziehbar aufgezeichnet werden?

Da die Lösungswege aktuell nur textuell und somit nicht strukturiert gespeichert werden, ist dies derzeit nicht möglich.

Bietet die Vorhersage des Telefonaufkommens oder des Ticketaufkommens tatsächlich einen Mehrwert in der Organisation einer Supportabteilung?

Je genauer das Supportaufkommen vorhergesagt werden kann, desto gezielter kann die Hotline eingeplant werden. Bei uns hat der First Level Support jedoch mehrere Aufgaben, daher wird meist etwas großzügiger eingeteilt, da die MitarbeiterInnen in Ruhezeiten den anderen Tätigkeiten wie Softwaretestung nachkommen können. Der Nachteil an diesem System ist, dass Ineffizienzen entstehen, da die MitarbeiterInnen immer aus ihrer aktuellen Tätigkeit herausgerissen werden, wenn das Telefon läutet, und sich nach dem Telefonat wieder neu in die Arbeit hineindenken müssen.

Einschätzungen zu den folgenden Ideen:

- Vorhersage, ob eine Anfrage durch den First Level Support lösbar ist → **grundsätzlich möglich, jedoch nimmt der First Level Support (wenn eine Anfrage nicht direkt gelöst werden kann) bereits weitere Informationen wie Logging-Protokolle oder Screenshots auf, um für den Second Level Support eine gewisse Vorarbeit zu leisten.**
- Vorhersage von Supportaufkommen → **Gute Möglichkeit zur Einteilung im Support bzw. zur Budgetierung neuer MitarbeiterInnen**
- Lösungsempfehlungen für 1st Level (vgl. Kunden kaufen auch) ... MitarbeiterIn erfasst diverse Infos zur Anfrage und bekommt Lösungsvorschläge auf Basis ähnlicher, gelöster Fälle → **dafür müssten die Lösungsdaten zukünftig strukturiert erfasst werden. Dies könnte jedoch die SupportmitarbeiterInnen bei der Arbeit gut unterstützen!**
- Erkennung von Verhaltensmustern bei Kunden → **Gute Möglichkeit, um aktuell noch unbekannte Informationen zu gewinnen**
- Programmverhaltensprofile die Problemursachen preisgeben ... aus einem bestimmten Verhalten ein bestimmtes Problem ableiten → **Dafür müsste natürlich wieder eine eigene Datenbank angelegt werden. Auch hier gibt es Potenzial zur Supportunterstützung.**
- Vergleich des aktuellen Bearbeitungsverlaufs mit vergangenen Fällen, um nächste Schritte vorzuschlagen (vgl. folgende Artikel werden oft gemeinsam gekauft) → **Vergleiche Lösungsempfehlungen!**

- Analyse der 10 größten Kunden in einem Segment, Aussagen über das gesamte Segment → **Findet manuell statt.**
- Analyse, warum gewisse Tickets eskaliert werden mussten und vergleichbare nicht → **Dazu müsste die Lösungsfindung auch strukturiert erfasst werden. Meistens lassen sich die Unterschiede wohl durch die unterschiedliche Erfahrung der MitarbeiterInnen erklären. Einzig um einen Nachschulungsbedarf zu identifizieren, wäre diese Idee vorstellbar. Eine Bewertung von MitarbeiterInnen ist jedoch definitiv nicht gewünscht.**

Fazit:

Die strukturierte Erfassung der Lösungswege ist ein Mehraufwand, der im täglichen Hotline-Betrieb nur schwer realisierbar ist. Gerade zu Spitzenzeiten bleibt kaum Zeit für die textuelle Erfassung. Die Umsetzung dieser Maßnahmen wäre nur mit einem groben Eingriff in die bisherige Arbeitsweise der KollegInnen möglich.

Die Vorhersage von Supportaufkommen ist mit der aktuellen Datenerfassung möglich. Alle relevanten Daten werden bereits gemessen und können jederzeit analysiert werden. Durch die bessere Vorhersage des Supportaufkommens könnte der First Level Support zielgerichtet auf die Kundenbedürfnisse hin arbeiten und insgesamt effizienter werden.

ANHANG C - Interview Firma BearingPoint GmbH

Wie sieht die Organisation Ihrer Supportabteilung aus? Wird ein multi-level Supportmodell (1st, 2nd, 3rd) gelebt?

Wird ein ITSM-Vorgehensmodell wie ITIL angewendet? Wie läuft sonst die Kommunikation zwischen 1st-, 2nd- und 3rd-Level-Support bzw. PM/Entwicklung ab?

Der Support findet nicht in einem klassischen Callcenter statt. Auch wenn eine 24/7 Hotline angeboten wird, findet der Kontakt hauptsächlich via Tickets statt. Früher waren die Teams größer und waren durchaus in einer multi-level Supportstruktur geführt. Aufgrund geänderter Kundenanforderungen wurden kleinere (acht Personen) Teams installiert. In dieser Organisationsform ist kein multi-level Support notwendig/sinnvoll. Im Servicevertrag ist definiert, wer ein Ticket beim Support aufgeben kann, daher treten die KundInnen meist als kompetente Partner in der Lösungsfindung auf. In diesem Sinne lässt sich sagen, dass die KundInnen selbst als First Level Support auftreten. Die Supportteams führen Second und Third Level Support-Aufgaben aus. Eine 4th Level Supportebene bildet die Softwareentwicklung, die in besonders schwierigen Fällen oder bei notwendigen Codeanpassungen eingeschaltet wird. Die Teamstruktur geht in Richtung DevOps, wo Entwicklungs- und SupportmitarbeiterInnen zusammenarbeiten und einerseits neue Lösungen erstellen und diese andererseits auch gemeinsam warten. So gesehen gibt es kein bestimmtes Vorgehensmodell, nach welchem der Support arbeitet, lediglich gewisse Templates bzw. einen Workflow nach dem die Lösungsfindung stattfinden soll.

Welches Leistungsangebot bietet Ihre Supportabteilung? (Hotline, Ticket, etc.)

Es wird kein klassisches Callcenter angeboten, da hauptsächlich auf Ticketebene mit den KundInnen kommuniziert wird. Dennoch steht eine 24/7-Hotline für Notfälle zur Verfügung.

Ticket hochladen ist auch direkt in der Anwendung möglich, um Screenshots und Protokolle einfach mitzusenden. Die Tickets werden nach vier Stufen priorisiert, wobei Stufe eins und zwei am dringlichsten sind und eine Antwort der SupportmitarbeiterInnen innerhalb von 15 Minuten verlangen. Stufe drei und vier fordern zumindest eine Antwort innerhalb eines Geschäftstages.

Level 0 Support: Kundenportal, News, FAQ, Dokumentation

Nach welchem Vorgehen wird die Hotline besetzt? Gibt es dazu KPIs?

Tagsüber ist das Supportteam anwesend und arbeitet Tickets ab. Nachtsüber gibt es ein Bereitschaftssystem. Grundsätzlich wird kein besonderes Vorgehen bei der Besetzung des Telefondienstes eingesetzt. Lediglich bei besonderen Anlässen wie größeren Updates, Inbetriebnahmeterminen und von KundInnen geplanten Aktionen wird die Bereitschaftsplanung gegebenenfalls angepasst.

Auf die Planung fließen keine KPIs ein. Die Teamgröße liegt bei etwa acht MitarbeiterInnen, die für etwa zehn KundInnen mit Supportverträgen verantwortlich sind. Pro Kundin bzw. Kunden gibt es ca. 25 MitarbeiterInnen, die Tickets senden „dürfen“ bzw. sollen. Es wird auch eine Zertifizierung dieser KundInnen angeboten. → in Summe etwa 20 - 25 MitarbeiterInnen im Support.

Wie entstehen diese KPIs? Welche Daten werden gesammelt und wie? Welche KPIs werden geführt und wie oft werden diese kontrolliert?

KPI: Reaktionszeit, Reparaturzeit, Workaround Time → Zeit bis eine Umstandslösung bereitgestellt werden kann. Fokus auf Workaround. Schritt zwei ist die tatsächliche Behebung der Ursache. Anrufe fließen in ein Ticket hinein, weil es sich um ein zentrales Tool handelt.

Supportaufkommen: Anzahl der Tickets reaktiv !

Monitoringsysteme: führen zu proaktiven Tickets und treibt den gesamten Supportaufwand.

Werden dafür bestimmte Tools genutzt?

Open Source OTRS System, das an die Organisationsanforderungen angepasst wurde. Auch Jira von Atlassian wird genutzt (Entwicklung als Treiber). Wird auch für Darstellung genutzt.

Monitoringsystem: DataDog

Gibt es Ansätze in Richtung Data Mining? Also nicht nur KPIs messen, sondern Vorhersagen treffen, Informationen generieren, etc.

Erste Schritte: Trends analysieren im laufenden System. Vorhersage, wie lang das System noch lauffähig ist. Neues Monitoringsystem geplant: Vorhersage wann etwas passiert.

Fragen aus Abschnitt 2.4.:

- **Haben SupportmitarbeiterInnen im Arbeitsalltag genügend Zeit, um das Ergebnis einer Klassifizierungsvoraussage hinsichtlich Eskalationserwartung oder Problemursache abzuwarten?**

Stress generiert nur die Priorität → Zeit bis zum Workaround. Alles, was zur Lösungsfindung beiträgt, ist erlaubt.

- **Gibt es bereits genügend Aufzeichnungen zur Lösungsfindung von Incidents, um einen Ähnlichkeitsabgleich oder eine Verbindungsvorhersage durchzuführen oder kann die Lösungsfindung überhaupt nachvollziehbar aufgezeichnet werden?**

Tickets durchlaufen Workflows. Statuswerte gibt's und diese werden auch gesetzt, das wird auch protokolliert. Zusätzliche Information über das Problem wird dokumentiert.

Vorgangsbeschreibung während der Analyse ist hauptsächlich Freitext und ist somit nicht strukturiert.

- **Bietet die Vorhersage des Telefonaufkommens oder des Ticketaufkommens tatsächlich einen Mehrwert in der Organisation einer Supportabteilung?**

Ja, bietet Mehrwert. Wenn die Organisation noch weiter wächst, wird's sicher wieder interessanter.

Einschätzungen zu den folgenden Ideen:

- *Klassifizierung von Incidents* → definitiv interessant und hilfreich
- *Vorhersage von Supportaufkommen* → Wenn die Organisation wieder wächst, definitiv interessant.

- *Lösungsempfehlungen für 1st Level (vgl. Kunden kauften auch) → Ähnliche Issues kommen rein, dafür hatte man aber schon eine Lösung, diese vorschlagen. Wäre sehr interessant.*
- *Erkennung von Verhaltensmustern bei Kunden → nice to have*
- *Programmverhaltensprofile, die Problemursachen preisgeben → Sehr relevant, was hat der Kunde tatsächlich getan? → automatisch abgreifen und daraus Ursachen ableiten.*
- *Vergleich des aktuellen Bearbeitungsverlaufs mit vergangenen Fällen (vgl. folgende Artikel werden oft gemeinsam gekauft) → Sehr sehr spannendes Thema, einerseits innerhalb eines Tickets, andererseits auch bei Modulabhängigkeiten. Im Billing geht was schief, dann kommt auch was zum Invoicing. → Problemvorhersage teamübergreifend.*
- *Analyse der 10 größten Kunden in einem Segment, Aussagen über das gesamte Segment → Aktuell kein Thema, da Supportteams ohnehin auf diese Größe zugeschnitten sind.*
- *Analyse, warum gewisse Tickets eskaliert werden mussten und vergleichbare nicht → Spannendes Thema für größere Organisationen – vor allem, wenn multi-level Support eingesetzt wird. Gibt's Muster und bestimmte Ursachen? Gibt's Schulungsbedarf?*

ANHANG D - Interview Firma C

Wie sieht die Organisation Ihrer Supportabteilung aus? Wird ein multi-level Supportmodell (1st, 2nd, 3rd) gelebt?

Wird ein ITSM-Vorgehensmodell wie ITIL angewendet? Wie läuft sonst die Kommunikation zwischen 1st-, 2nd- und 3rd-Level-Support bzw. PM/Entwicklung ab?

Kein klassischer 1st und 2nd. Im Customerservice werden eins, zwei und drei abgedeckt. DevOps Team, dann 2nd Level und dann Entwicklungsteam.

Jemand der Applikations-Know-how und Entwicklungs-Know-how hat. 3rd Level auf Anwendung spezialisiert.

Komplett strukturierte Abläufe durch SLAs und strenge Prozesse. Workflow in Jira abgebildet.

Ticketing mit Jira. Ticket ist das A und O.

Tickets werden immer angelegt. Vorgehensmodell an ITIL orientiert.

Welches Leistungsangebot bietet ihre Supportabteilung? (Hotline, Ticket, etc.)

Tickets und Bereitschaftsregelung (3rd Level nicht) → 06:00 - 22:00 Uhr

Ein bis vier Stufen → ca. 30 Minuten je nach SLA, Stufe vier – ein bis zwei Werktage

Keine spezielle Fokussierung auf Workaround

FAQ und Dokumentation → Wird aktuell etwas vernachlässigt.

Nach welchem Vorgehen wird die Hotline besetzt? Gibt es dazu KPIs?

Immer ein CSS und ein Operations. Reicht für normal. Unterstützung bei Bedarf, wird nicht extra geplant.

Supportaufkommen: Anzahl an Tickets, kombiniert mit Prio pro Kunde

Wie entstehen diese KPIs? Welche Daten werden gesammelt und wie? Welche KPIs werden geführt und wie oft werden diese kontrolliert?

Gelöste und erstellte Tickets mit den Zeiten, durchschnittliche Lösungs- und Bearbeitungszeiten.

Wie viele werden gleich im 1st Level-Support gelöst und wie viele gehen weiter.

Verrechenbarer und nicht verrechenbarer Aufwand – Gewährleistung/Wartung

Werden dafür bestimmte Tools genutzt?

Jira, eigens gebaute Tools

Gibt es Ansätze in Richtung Data Mining? Also nicht nur KPIs messen, sondern Vorhersagen treffen, Informationen generieren, etc.

In der Planung, Anfragen kategorisieren, Vorhersagen

Fragen aus Abschnitt 2.4.:

- Haben SupportmitarbeiterInnen im Arbeitsalltag genügend Zeit, um das Ergebnis einer Klassifizierungsvoraussage hinsichtlich Eskalationserwartung oder Problemursache abzuwarten?

Für normal ist genügend Zeit vorhanden, ca. 15 Minuten ist immer Zeit.

- Gibt es bereits genügend Aufzeichnungen zur Lösungsfindung von Incidents, um einen Ähnlichkeitsabgleich oder eine Verbindungsvorhersage durchzuführen oder kann die Lösungsfindung überhaupt nachvollziehbar aufgezeichnet werden?

Es gibt beides – bei Ausfällen textuelle Protokolle

Workflow deckt ab, welche MitarbeiterInnen beteiligt sind, über Kommentare kann man nachlesen, was passiert.

- Bietet die Vorhersage des Telefonaufkommens oder des Ticketaufkommens tatsächlich einen Mehrwert in der Organisation einer Supportabteilung?

Eher nicht, weil Hotline immer gleich besetzt ist.

Einschätzungen zu den folgenden Ideen:

- Klassifizierung von Incidents

Sehr interessant, daran wird auch schon gearbeitet.

- Vorhersage von Supportaufkommen

Nicht so interessant

- Lösungsempfehlungen für 1st Level (vgl. Kunden kaufen auch)

Ist interessant und wird schon verwendet. Vom selben Kunden, wird halb manuell ausgeführt.

- Erkennung von Verhaltensmustern bei Kunden

ServicemanagerInnen haben das quasi im Gefühl, wäre auch interessant, wenn das in weitere Punkte einfließt.

- Programmverhaltensprofile, die Problemursachen preisgeben

Passiert theoretisch schon, projektübergreifend schwierig, Projekte sind unterschiedlich.

- Vergleich des aktuellen Bearbeitungsverlaufs mit vergangenen Fällen (vgl. folgende Artikel werden oft gemeinsam gekauft)

Vorschlag für nächsten Bearbeitungsschritt, weil Projekte zu individuell sind.

- Analyse der 10 größten Kunden in einem Segment, Aussagen über das gesamte Segment

Jeder Kunde hat sein eigenes Projekt und eigene Projekte. Nicht möglich.

- Analyse, warum gewisse Tickets eskaliert werden mussten und vergleichbare nicht

Sehr interessant. War schon mal da. Ist eingeschlafen ... sollte eigentlich laufend erledigt werden.

Ca. 25 auf 3 Teams, 15-20, Wer kundenseitig Tickets erstellt, ist geregelt.

ANHANG E - RStudio Code

R Skript für das Erstellen eines linearen Regressionsmodells, inklusive Summary:

```
df <- read.csv('df_support.csv')

train.df <- df[1:1193,]
test.df <- df[1194:1216,]

train.df$Datum.fact <- as.Date.factor(train.df$Datum)
test.df$Datum.fact <- as.Date.factor(test.df$Datum)

train.df$Vollmond = relevel(train.df$Vollmond, ref = 'Nein')
train.df$Ferien = relevel(train.df$Ferien, ref = 'Nein')
train.df$Feiertag = relevel(train.df$Feiertag, ref = 'Nein')
train.df$Halbtag = relevel(train.df$Halbtag, ref = 'Nein')

model1 <- lm(FIBU.Anrufe ~ Datum.fact +
             Ferien + Feiertag + Halbtag + Vollmond +
             WWS.SCR + CRM.SCR + BIL.SCR + KORE.SCR + FIBU.SCR
             ,data=train.df)

Summary(model1)
```

R Skript für die Vorhersage mit einem linearen Modell, inklusive der Gegenüberstellung der Vorhersage und den Tatsächlichen Werten:

```
y.hat <- c(predict(model2, data.frame(Datum.fact=
c(as.Date.factor("2019-10-01"), as.Date.factor("2019-10-02"),
as.Date.factor("2019-10-03"), as.Date.factor("2019-10-04"),
as.Date.factor("2019-10-07"), as.Date.factor("2019-10-08"),
as.Date.factor("2019-10-09"), as.Date.factor("2019-10-10"),
as.Date.factor("2019-10-11"), as.Date.factor("2019-10-14"),
as.Date.factor("2019-10-15"), as.Date.factor("2019-10-16"),
as.Date.factor("2019-10-17"), as.Date.factor("2019-10-18"),
as.Date.factor("2019-10-21"), as.Date.factor("2019-10-22"),
as.Date.factor("2019-10-23"), as.Date.factor("2019-10-24"),
```

```
as.Date.factor("2019-10-25"), as.Date.factor("2019-10-28"),
as.Date.factor("2019-10-29"), as.Date.factor("2019-10-30"),
as.Date.factor("2019-10-31") ),
Feiertag=c("Nein", "Nein", "Nein", "Nein", "Nein", "Nein", "Nein", "Nein", "Nein",
"Nein", „Nein", "Nein", "Nein", "Nein", "Ja", "Ja", "Ja", "Ja", "Ja", "Ja", "Ja",
"Ja"),
Ferien="Nein",
Halbtag=c("Nein", "Nein", "Nein", "Ja", "Nein", "Nein", "Nein", "Nein", "Ja", "Nein",
"Nein", "Nein", "Nein", "Ja", "Nein", "Nein", "Nein", "Nein", "Ja", "Nein",
"Nein", "Nein", "Nein")) , type="response"))

sum(matrix(y.hat) - matrix(test.df$FIBU.Anrufe))
```

R Skript für die Erstellung des prophet-Modells:

```
df <- read.csv('forecast_prophet.csv')

df.model<- df[1:1733,]

df.model.fit <- df.model[,c(1,2,4,5)]

feiertag <- df[2:1765,4]

ferien <- df[2:1765,5]

m <- prophet()
m <- add_regressor(m, c('feiertag', 'ferien'))
m <- fit.prophet(m, df.model.fit)
```

R Skript für die Vorhersage mit dem prophet-Modell, inklusive der Gegenüberstellung der Vorhersage und den Tatsächlichen Werten:

```
future <- make_future_dataframe(m, periods = 31)
future$feiertag <- feiertag
future$ferien <- ferien

forecast <- predict(m, future)
forecast.matrix <- forecast[c('ds', 'yhat', 'yhat_lower', 'yhat_upper')]
forecast.maxtix.yhat <-forecast.matrix[1734:1764,]$yhat
forecast.matrix.yhat.zero <- ifelse(forecast.maxtix.yhat > 0,forecast.maxtix.yhat,0)
```

```
sum(forecast.matrix.yhat.zero - df[1734:1764,]$y)
```

R Skript für die Vorhersage der WWS Tickets mittels prophet, inklusive dem Export der Daten in eine CSV Datei:

```
df <- read.csv('exp_dataset_prophet.csv')

df.model <- df[1:1765,]

df.model.fibu.anrufe <- df.model[,c(1,5,12,13)]
names(df.model.fibu.anrufe)[names(df.model.fibu.anrufe) == "y.3"] <- "y"

feiertag <- df[1:1795,12]
ferien <- df[1:1795,13]

m <- prophet()
m <- add_regressor(m, c('Feiertag', 'Ferien'))
m <- fit.prophet(m, df.model.fibu.anrufe)

future <- make_future_dataframe(m, periods = 30)
future$Feiertag <- feiertag
future$Ferien <- ferien

forecast <- predict(m, future)
forecast.matrix <- forecast[c('ds', 'yhat', 'yhat_lower', 'yhat_upper')]
vorhersage <- forecast.matrix[1765:1795,]

write.csv2(vorhersage, "vorhersage_dm_wws_tickets.csv")
```

ABBILDUNGSVERZEICHNIS

Abbildung 1: Aufbau der Arbeit (eigene Darstellung, 2019).....	6
Abbildung 2: Wissenstreppe nach North (vgl. North, 2011, S. 35).....	8
Abbildung 3: KDD-Prozess (vgl. Fayyad et al., 1996, S. 41)	9
Abbildung 4: Data Science im Zusammenhang mit datenbasierenden Prozessen im Unternehmen (vgl. Provost & Fawcett, 2013, S. 5).....	13
Abbildung 5: Das CRISP-DM-Referenzmodell (vgl. Chapman et al., 2000, S. 13).....	16
Abbildung 6: multi-level Support Modell angereichert mit dem Supportangebot der Firma BMD Systemhaus GesmbH (BMD Systemhaus GesmbH, 2019; Knapp, 2010, S. 37).....	24
Abbildung 7: Cross Validation (vgl. Ng & Soo, 2018, S. 18)	48
Abbildung 8: Darstellung des Jahrestrends mittels prophet-Modell (eigene Aufbereitung)	52
Abbildung 9: Prophet Vorhersage Plot mit Wochendaten und Jahresdaten (eigene Aufbereitung)	53
Abbildung 10: Textdatei inkl. Beispieldatensatz für die Eingabe der Supportvorhersagen (eigene Aufbereitung)	63
Abbildung 11: Bildliche Darstellung von H_0 und H_1 für einen rechtsseitigen Test (in Anlehnung an Hedderich & Sachs, 2018, S. 300, Graphik aus Moser, 2018)	67
Abbildung 12: Gegenüberstellung der Teststatistiken Anrufe und Tickets der Gruppen Führungskräfte (FK) und Data Mining-Modell (DM) (eigene Aufbereitung).....	68

TABELLENVERZEICHNIS

Tabelle 1: Aufgaben und Ziele des Wissensmanagements (vgl. North, 2011, S. 3).....	11
Tabelle 2: Darstellung von Festplattengrößen und -preisen (vgl. John C. McCallum, 2019)	14
Tabelle 3: Kategorien von Algorithmen (Ng & Soo, 2018, S. 8).....	18
Tabelle 4: Anwendungsfälle für den Einsatz von Data Mining im Support (eigene Darstellung).....	28
Tabelle 5: Auszug aus dem Ursprungsdatensatz für das Softwarepaket CRM für die KW 41, 2019 (Telefondatenaufzeichnung Firma BMD)	42
Tabelle 6: Auszug aus dem Ursprungsdatensatz für das Softwarepaket BILANZ für die KW 41, 2019 (Ticketdatenaufzeichnung Firma BMD).....	43
Tabelle 7: Darstellung der Neuerungen und Änderungen aus dem „NTCS Versionsbericht“ der relevanten Softwarepakete von KW 39 bis KW 43 (Datenaufzeichnung Firma BMD)	44
Tabelle 8: Schulferien in Österreich 2019 (vgl. BMBWF, 2019).....	44
Tabelle 9: Auszug aus dem tatsächlichen Datensatz für die Datenmodellierung (eigene Aufbereitung) .	45
Tabelle 10: Auszug aus der Modellzusammenfassung aus dem ersten linearen Modell (eigene Aufbereitung).....	50
Tabelle 11: Ergebnis der Funktion drop1, sortiert aufsteigend nach AIC (eigene Aufbereitung).....	51
Tabelle 12: Auswertung der Führungskräfte Vorhersagen – Anrufe (eigene Aufbereitung).....	63
Tabelle 13: Auswertung der Führungskräfte Vorhersagen – Tickets (eigene Aufbereitung)	64
Tabelle 14: Auswertung der Data Mining-Vorhersagen – Anrufe (eigene Aufbereitung).....	64
Tabelle 15: Auswertung der Data Mining-Vorhersagen – Tickets (eigene Aufbereitung).....	65

6 LITERATURVERZEICHNIS

- Aggarwal, C. C. (2015). *Data mining: The textbook*. Cham: Springer. Retrieved from <http://dx.doi.org/10.1007/978-3-319-14142-8>
- Beyer, B., Jones, C., Petoff, J., & Murphy, N. R. (Eds.). (2016). *Site reliability engineering: How Google runs production systems*. Retrieved from <http://proquest.tech.safaribooksonline.de/9781491929117>
- BMBWF Österreich (2017). Experiment. Retrieved from http://www2.lernplattform.schule.at/ahs-vwa/pluginfile.php/2982/mod_page/content/140/Experiment_AKT.pdf
- BMD Systemhaus GmbH (2019). Angebot BMD-Support. Retrieved from <https://www.bmd.com/technik-support/anwender-support.html>
- Bruce, P., & Bruce, A. (2017). *Practical statistics for data scientists: 50 essential concepts*. Sebastopol, CA: O'Reilly Media. Retrieved from <http://proquest.tech.safaribooksonline.de/9781491952955>
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). CRISP-DM 1.0: Step-by-step data mining guide. Retrieved from https://pdfs.semanticscholar.org/5406/1a4aa0cb241a726f54d0569efae1c13aab3a.pdf?_ga=2.229776732.1519274637.1571254561-1351641152.1571254561
- Chatfield, C. (2001). *Time-series forecasting*. Boca Raton: Chapman & Hall/CRC. Retrieved from <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10143032>
- Cleff, T. (2012). *Deskriptive Statistik und moderne Datenanalyse: Eine computergestützte Einführung mit Excel, PASW (SPSS) und STATA (2., überarbeitete und erweiterte Auflage)*. Wiesbaden: Gabler. Retrieved from <http://dx.doi.org/10.1007/978-3-8349-7071-8>
- Dolić, D. (2004). *Statistik mit R: Einführung für Wirtschafts- und Sozialwissenschaftler*. München: Oldenbourg.
- Dorschel, J. (Ed.). (2015). *Praxishandbuch Big Data: Wirtschaft -- Recht -- Technik*. Weisbaden: Springer Gabler. Retrieved from <http://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&AN=980340>
- EDUCBA (2019). Data Science Languages: Top Programming Languages in Data Science. Retrieved from <https://www.educba.com/data-science-languages/>
- Falk, M., Hain, J., Marohn, F., Fischer, H., & Michel, R. (2014). *Statistik in Theorie und Praxis: Mit Anwendungen in R. Mathematik für das Lehramt*. Berlin, Heidelberg: Springer Spektrum.

- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. From Data Mining to Knowledge Discovery in Databases. In *AI Magazine Volume 17 Number 3* (pp. 37–54). Retrieved from <https://www.aaai.org/ojs/index.php/aimagazine/article/view/1230/1131>
- Fröschle, H.-P. (2017). DevOps. *HMD Praxis der Wirtschaftsinformatik*, 54(2), 171–172. <https://doi.org/10.1365/s40702-017-0296-3>
- Gentsch, P. (2018). *Künstliche Intelligenz für Sales, Marketing und Service: Mit AI und Bots zu einem Algorithmic Business - Konzepte, Technologien und Best Practices*. Wiesbaden: Springer Gabler. Retrieved from <http://dx.doi.org/10.1007/978-3-658-19147-4>
- Hedderich, J., & Sachs, L. (2018). *Angewandte Statistik: Methodensammlung mit R* (16., überarbeitete und erweiterte Auflage). Berlin, Germany: Springer Spektrum.
- Higday-Kalmanowitz, C., & Simpson, E. S. (2005). *Implementing service and support management processes: A practical guide* (430 s). [Zaltbommel]: Van Haren Publishing.
- Jacob, M. (2012). *Informationsorientiertes Management: Ein Überblick für Studierende und Praktiker*. Wiesbaden: Gabler Verlag. Retrieved from <http://dx.doi.org/10.1007/978-3-8349-3909-8>
- Jannaschk, K., & Thalheim, B. (2017). *Infrastruktur für ein Data Mining Design Framework* (Dissertation). Christian-Albrechts-Universität zu Kiel; Springer Fachmedien Wiesbaden GmbH.
- John C. McCallum (2019). Data Drive Prices (1955-2019). Retrieved from <https://jcmmit.net/diskprice.htm>
- Klostermann, T. (2008). *Optimierung kooperativer Dienstleistungen im Technischen Kundendienst des Maschinenbaus. Gabler Edition Wissenschaft*. Wiesbaden: Betriebswirtschaftlicher Verlag Dr. Th. Gabler / GWV Fachverlage GmbH Wiesbaden. Retrieved from <http://dx.doi.org/10.1007/978-3-8349-9701-2>
- Knapp, D. (2010). *A guide to service desk concepts* (3rd ed.). Boston, MA: Course Technology, Cengage Learning.
- Löffler, C. (2011). *Service-Externalisierung: Ein wettbewerbsstrategisches Konzept im Management IT-basierter Dienstleistungen*. Zugl.: Erlangen-Nürnberg, Univ., Diss., 2010 (1. Aufl.). Wiesbaden: Gabler Verlag / Springer Fachmedien Wiesbaden GmbH Wiesbaden. Retrieved from <http://dx.doi.org/10.1007/978-3-8349-6759-6>
- Mitrakis, N. (2019). *Die Ausrichtung des IT-Service-Managements auf die Digitalisierung*. Wiesbaden: Springer Fachmedien Wiesbaden. Retrieved from <https://doi.org/10.1007/978-3-658-25380-6>
- Moser, M. (2018). Effizienzsteigerung durch die Umstellung auf Digitalisierte Rechnungswesen-Prozesse bei Buchführungs-Dienstleistern.

- Ng, A., & Soo, K. (2018). *Data Science - was ist das eigentlich?! Algorithmen des maschinellen Lernens verständlich erklärt*. Berlin, Heidelberg: Springer Berlin Heidelberg. Retrieved from <https://doi.org/10.1007/978-3-662-56776-0>
- North, K. (2011). *Wissensorientierte Unternehmensführung: Wertschöpfung durch Wissen* (5., aktualisierte und erw. Aufl.). *Gabler Lehrbuch*. Wiesbaden: Gabler Verlag / Springer Fachmedien Wiesbaden GmbH Wiesbaden. Retrieved from <http://dx.doi.org/10.1007/978-3-8349-6427-4>
- Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking* (1st ed.). Sebastopol, CA: O'Reilly Media. Retrieved from <http://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=619895>
- R Documentation (2019). Akaike's An Information Criterion (AIC). Retrieved from <https://stat.ethz.ch/R-manual/R-devel/library/stats/html/AIC.html>
- Ravichandran, A., Taylor, K., & Waterhouse, P. (2016). *DevOps for Digital Leaders: Reignite Business with a Modern DevOps-Enabled Software Factory*. Berkeley, CA: Apress. Retrieved from <http://dx.doi.org/10.1007/978-1-4842-1842-6>
- Schubert, K., & Bandelow, N. C. (Eds.). (2014). *Lehrbuch der Politikfeldanalyse* (3., aktualisierte und überarb. Aufl.). *Lehr- und Handbücher der Politikwissenschaft*. Berlin: De Gruyter Oldenbourg. Retrieved from http://www.degruyter.com/search?f_0=isbnissn&q_0=9783110408072&searchTitles=true
- Sharafi, A. (2013). *Knowledge Discovery in Databases: Eine Analyse des Änderungsmanagements in der Produktentwicklung*. Zugl.: München, Techn. Univ., Diss., 2012. *Springer Gabler Research*. Wiesbaden: Springer Gabler.
- Taylor, S., & Letham, B. (2017). *Forecasting at Scale*.
- Wenger, W., Geiger, M. J., & Kleine, A. (Eds.). (2011). *Business Excellence in Produktion und Logistik: Festschrift für Prof. Dr. Walter Habenicht* (1. Aufl.). *Gabler Research*. Wiesbaden: Gabler.
- Yang, L. (2019). A Quick Start of Time Series Forecasting with a Practical Example using FB Prophet. Retrieved from <https://towardsdatascience.com/a-quick-start-of-time-series-forecasting-with-a-practical-example-using-fb-prophet-31c4447a2274>
- Zhong, N. (Ed.). (2007). *Web intelligence meets brain informatics: First WICI International Workshop, WImBI 2006, Beijing, China, December 15 - 16, 2006 ; revised selected and invited papers. State-of-the-art survey: Vol. 4845*. Berlin: Springer. Retrieved from <http://www.springerlink.com/openurl.asp?genre=issue&issn=0302-9743&volume=4845>