

Big Data im Immobilienmanagement:

Wie eine intelligente Datenauswertung
die Branche revolutionieren kann.

Masterarbeit

vorgelegt dem Prüfungsausschuss des Fachbereichs
Oecotrophologie • Facility Management
an der FH Münster

von

Niklas Wiesweg

Referent: Prof. Dr. rer. pol. Torben Bernhold

Korreferent: Prof. Dr. rer. biol. hum. Reiner Kurzhals

Juni 2017

Sperrvermerk

Veröffentlichungen – auch Teilveröffentlichen – Abänderungen, Vervielfältigungen und Weitergabe sind ohne meine ausdrückliche Genehmigung untersagt.

Münster, 02.06.17

.....

Unterschrift

Inhaltsverzeichnis

Inhaltsverzeichnis.....	I
Abbildungsverzeichnis.....	III
Tabellenverzeichnis.....	IV
Abkürzungsverzeichnis.....	V
1 Einleitung in die Thematik.....	1
1.1 Einführung und Problemabgrenzung.....	1
1.2 Gang der Untersuchung.....	3
2 Begriffliche Grundlagen.....	4
2.1 Corporate Real Estate Management.....	4
2.2 Facility Management.....	5
2.3 Abgrenzung Innovation.....	6
3 Big Data – explorative Klärung des Phänomens.....	8
3.1 Einführung in das Themenfeld der Statistik.....	8
3.2 Machine Learning.....	11
3.3 Big Data – Mehr als nur große Daten?.....	13
3.3.1 Versuch einer Definition.....	14
3.3.2 Big Data und die Vs.....	17
3.3.3 Die Big Data-Anwendung.....	20
3.3.4 Die rechtliche Perspektive.....	22
3.3.5 Einsatzbereiche, Nutzen und Potentiale.....	25
3.3.6 Herausforderungen, Treiber und Barrieren.....	31
3.3.7 Begriffe rund um Big Data.....	35
3.3.7.1 Business Intelligence.....	35
3.3.7.2 Data Warehouse.....	37
3.3.7.3 Data Analytics, Data Mining, KDD.....	40
3.3.7.4 Internet of things.....	44
3.4 Beispiele aus der Praxis – Immobilien im Einfluss von Big Data.....	46
3.5 Erkenntnisse der explorativen Vorstudie.....	50

4 Big Data im Immobilien-Kontext.....	51
5 Big Data in der Immobilienbranche – eine empirische Untersuchung....	61
5.1 Darstellung des Forschungsdesigns und Methodenauswahl.....	62
5.2 Erarbeitung und Vorstellung des Fragebogens.....	66
5.3 Vorstellung der Interviewpartner.....	70
5.4 Untersuchungsergebnisse.....	72
5.4.1 Sondierungsfragen.....	73
5.4.2 Status Quo.....	73
5.4.3 Wertschöpfungspotentiale.....	75
5.4.4 Treiber und Barrieren.....	79
5.4.5 Zukunftsperspektive.....	82
6 Beurteilung der Big Data-Reife der Branche.....	83
7 Überprüfung der Einhaltung der Gütekriterien qualitativer Forschung	87
8 Zusammenfassung und Ausblick.....	91
8.1 Kritische Zusammenfassung der Untersuchungsergebnisse.....	91
8.2 Weitere Forschungsfelder.....	93
Literaturverzeichnis.....	VII
Anhang.....	XVIII

Abbildungsverzeichnis

Abbildung 1: Reifegradmodell.....	6
Abbildung 2: Big Data-Anwendung.....	20
Abbildung 3: BI-Anwendung.....	35
Abbildung 4: ETL-Prozess.....	38
Abbildung 5: Data Analytics.....	42
Abbildung 6: Fallbeispiel Microsoft: Problemdarstellung und Lösung.....	48
Abbildung 7: Möglicher Big Data-Datenpool im FM.....	55
Abbildung 8: Ableitung der Einsatzszenarien in der Immobilienbranche.....	58
Abbildung 9: Bestandteile des Total Return.....	59
Abbildung 10: Ablaufmodell des problemzentrierten Interviews.....	63
Abbildung 11: Modell zur Beurteilung der Big Data-Reife.....	84
Abbildung 12: Angepasste Big Data-Anwendung inkl. der Reifegradstufen.....	85

Tabellenverzeichnis

Tabelle 1: Vorstellung der Interviewpartner.....	71
Tabelle 2: Darstellung der eingebetteten Untersuchungseinheiten.....	71
Tabelle 3: Darstellung des Kategoriensystems.....	72
Tabelle 4: Mögliche Datenquellen aus der Sicht der Interviewpartner.....	82

Abkürzungsverzeichnis

BI	Business Intelligence
BIM	Building Information Modelling
CAD	Computer Aided Design
CAFM	Computer Aided Facility Management
CMS	Content Management System
CREM	Corporate Real Estate Management
CRM	Customer Relationship Management
DIN	Deutsches Institut für Normung e.V.
DMS	Dokumenten-Management-System
EN	Europäische Norm
ERP	Enterprise Resource Planning
FDD	fault detection and diagnostics
FM	Facility Management
GA	Gebäudeautomation
GEFMA	German Facility Management Association e.V.
GF	Geschäftsführung
GLT	Gebäudeleittechnik
GM	Gebäudemanagement
HR	Human Resources
IaaS	Infrastructure as a Service
IGM	Infrastrukturelles Gebäudemanagement
IoT	Internet of things/Internet der Dinge
KDD	Knowledge Discovery in Databases
KGM	Kaufmännisches Gebäudemanagement

PaaS	Platform as a Service
PM	Property Management
REAM	Real Estate Asset Management
REPM	Real Estate Portfolio Management
SaaS	Software as a Service
TGA	Technische Gebäudeausrüstung
TGM	Technisches Gebäudemanagement
UrhG	Urheberrechtsgesetz

1 Einleitung in die Thematik

1.1 Einführung und Problemabgrenzung

Die zunehmende Digitalisierung der Gesellschaft ist allgegenwärtig. Laptops, Smartphones, Tablets sind kaum mehr aus dem alltäglichen Leben wegzudenken und der Trend geht weiter in Richtung so genannter Wearables, die am Körper getragen werden und jegliche Aktionen und Informationen (beispielsweise Herzfrequenzen oder Schritte) registrieren und ins weltweite Netz laden¹. Was mit Daten, die über solche Geräte, teilweise freiwillig, von den Nutzern zur Verfügung gestellt werden, und deren Analyse bereits heute möglich ist und welche Auswirkungen dies haben kann, zeigte sich Ende 2016 als die Nachricht, dass Big Data-Analysen Donald Trump zum neuen US-Präsidenten gemacht haben, um die Welt ging². Das wirtschaftliche Pendant in Deutschland nennt sich Industrie 4.0³. Vor dem Hintergrund des aktuell veröffentlichten Wettbewerbsranking des schweizerischen IMD World Competitiveness Center in Lausanne⁴, das Deutschland im Bereich der digitalen Wettbewerbsstärke nur auf Platz 17 (2016 noch Platz 15) von insgesamt 63 Staaten sieht (mit fallender Tendenz), ist eine intensivere Auseinandersetzung mit der Digitalisierung, speziell Big Data, notwendig. Die vorliegende Arbeit soll dazu einen ersten Einblick für die Branche bieten. Das heißt, dass sich die Arbeit nicht mit der technischen Ausarbeitung und Entwicklung von Algorithmen zur Mustererkennung oder dergleichen befasst, sondern viel mehr mit der Anwendbarkeit von Big Data in der Immobilienbranche und dem damit verbundenen Nutzen. Die Branche ist interdisziplinär aufgestellt, d.h. über den gesamten Lebenszyklus einer Immobilien hinweg sind Vertreter vieler Disziplinen beteiligt. Dies beginnt in der Planung mit Architekten, Investoren und Bauherren, geht über Immobiliendienstleister hin zu Mietern und Nutzern unterschiedlichster Couleur. Auch die einzelnen Lebenszyklusphasen (Planung, Bau, Betrieb etc.) bieten unterschiedliche Ansatzpunkte, sodass für eine erste branchenspezifische Auseinandersetzung mit dem Thema die folgende, recht breite Fragestellung die Forschung anleiten soll:

1 Vgl. Gabler Wirtschaftslexikon, o.J., Stichwort: Wearables.

2 Vgl. Horn, 2016.

3 Vgl. Dorschel, 2015, S. 242-244.

4 Siems, 2017.

Wie lässt sich Big Data unter der Hinzunahme möglicher Treiber und Barrieren als Instrument in der Immobilienbranche einsetzen und nutzen?

Welche Entscheidungen und Prozesse profitieren von dem Einsatz von Big Data als Unterstützungsinstrument?

1.2 Gang der Untersuchung

Die vorliegende Arbeit lässt sich in zwei Bereiche unterteilen. Der erste Bereich (Kapitel 3 und 4) beinhaltet eine explorative Vorstudie zur Klärung des Phänomens Big Data und zur Schaffung eines einheitlichen Verständnisses. Begonnen wird mit der Betrachtung der Statistik (3.1), danach wird mittels Machine Learning (3.2) eine Brücke zum Hauptthema Big Data (3.3) geschlagen. Als Einstieg in die Thematik werden unterschiedliche Definitionen (3.3.1) und die daraus ableitbaren für Big Data charakteristischen Vs (3.3.2) dargestellt. Im Anschluss folgt eine Darstellung von Big Data-Anwendung (3.3.3), der rechtlichen Rahmenbedingungen (3.3.4), von möglichen Einsatzbereichen (3.3.5), Herausforderungen (3.3.6) und Begriffen rund um das Thema Big Data (3.3.7). Das Kapitel schließt mit einigen immobilienbezogenen Praxisbeispielen (3.4). Auf der Grundlage der gewonnenen Erkenntnisse wird in Kapitel 4 ein Datenpool für den Einsatz von Big Data in der Immobilienbranche abgeleitet, anhand dessen die Eignung der Branche für einen Big Data-Einsatz geprüft wird. Der erste Bereich dient als Arbeitsgrundlage für die im zweiten Bereich (Kapitel 5) durchgeführten Experteninterviews mit Teilnehmern aus der Immobilienbranche zur Beantwortung der forschungsleitenden Fragestellung. In Kapitel 6 erfolgt eine Beurteilung der Big Data-Reife der Branche. Die Gütekriterien qualitativer Forschung nach Mayring werden in Kapitel 7 überprüft. Abschließend erfolgt eine kritische Zusammenfassung der Untersuchungsergebnisse (8.1) und eine kurze Darstellung weiterer möglicher Forschungsfelder, die sich aus der forschungsleitenden Fragestellung und den Erkenntnissen der Studie ergeben.

2 Begriffliche Grundlagen

2.1 Corporate Real Estate Management

Der Begriff des Corporate Real Estate Managements (CREM) wird im Zusammenhang mit Unternehmen (*engl. corporates*) verwendet, deren Kerngeschäft nicht die Immobilienwirtschaft umfasst. Diese Unternehmen werden auch als Non-Property-Companies bezeichnet⁵. Die Aufgabe des Corporate Real Estate Managements ist das „wirtschaftliche Beschaffen, Betreuen⁶ und Verwerten der Liegenschaften von Produktions- Handels- und Dienstleistungsunternehmen im Rahmen der Unternehmensstrategie“⁷. Aus Sicht des Corporate Real Estate Managements dienen die betrachteten Immobilien und Liegenschaften, im Sinne der porterschen Wertkette, „zur Durchführung und Unterstützung der Kernaktivitäten“⁸.

Zur Abgrenzung zwischen dem Corporate Real Estate Management und dem nachfolgend definierten Facility Management lässt sich folgendes sagen:

„Das FM und CREM besitzen einen unterschiedlichen Anwendungsbereich: CREM legt seinen Fokus auf Immobilien als physische und wirtschaftliche Vermögenswerte genutzt von einer Organisation, während FM einen breiteren Service-Fokus einschließlich Anforderungen in Bezug auf Raum und Infrastruktur sowie Menschen und Organisation besitzt. Berufe im FM und CREM können sich aufgrund verschiedener Traditionen in verschiedenen Ländern und Organisation überlappen“⁹.

5 Vgl. Pfnür, 2002, S.59; Pfnür, 2011, S. 165; Schulte, 2004, S. 46.

6 Dieses beinhaltet „das aktive, ergebnisorientierte, strategische wie operative Management betriebsnotwendiger und nicht betriebsnotwendiger Immobilien“ Schulte, 2004, S. 46.

7 Pfnür, 2011, S.165.

8 Vgl. Pfnür, 2011, S.165.

9 Eigene Übersetzung nach Jensen et. al., 2012, S. 14-30.

2.2 Facility Management

Dem Begriff Facility Management (FM) werden in Deutschland, je nach verwendeter Definition, unterschiedliche Aufgaben und Inhalte zugewiesen. Um einen kurzen Überblick über den Begriff Facility Management zu geben, werden im Nachfolgenden drei verschiedene Ansätze thematisiert.

Eine „allgemein gültige und dennoch leicht verständliche Begriffsformulierung“¹⁰ des Facility Managements hat Nävy, auf der Grundlage eines Drei-Säulen-Konzepts, bestehend aus der Ganzheitlichkeit, dem Lebenszyklus und der Transparenz, entwickelt. Facility Management ist demnach „ein strategisches Konzept zur Bewirtschaftung, Verwaltung und Organisation aller Sachressourcen innerhalb eines Unternehmens“¹¹.

Die Richtlinie 100-1 der German Facility Management Association (GEFMA) von Juli 2004 definiert das Facility Management folgendermaßen: „Facility Management ist eine Managementdisziplin, die durch ergebnisorientierte Handhabung von Facilities und Services im Rahmen geplanter, gesteuerter und beherrschter Facility Prozesse eine Befriedigung der Grundbedürfnisse von Menschen am Arbeitsplatz, Unterstützung der Unternehmens-Kernprozesse und Erhöhung der Kapitalrentabilität bewirkt. Hierzu dient die permanente Analyse und Optimierung der kostenrelevanten Vorgänge rund um bauliche und technische Anlagen, Einrichtungen und im Unternehmen erbrachte (Dienst-)Leistungen, die nicht zum Kerngeschäft gehören“¹².

Die als DIN EN 15221 veröffentlichte europäische Norm von 2007 versteht unter Facility Management die „Integration von Prozessen innerhalb einer Organisation zur Erbringung und Entwicklung der vereinbarten Leistungen, welche zur Unterstützung und Verbesserung der Effektivität der Hauptaktivitäten der Organisation dienen“¹³.

10 Nävy, 1998, S. 2.

11 Nävy, 1998, S. 2.

12 GEFMA 100-1, 2004, S. 3.

13 DIN EN 15221-1, 2007, S. 5.

2.3 Abgrenzung Innovation

Zur Beurteilung der späteren Erkenntnisse, sollte für diese Arbeit definiert werden, wann eine „echte“ Innovation vorliegt und wann es sich um eine inkrementelle Entwicklung von Altbekanntem handelt.

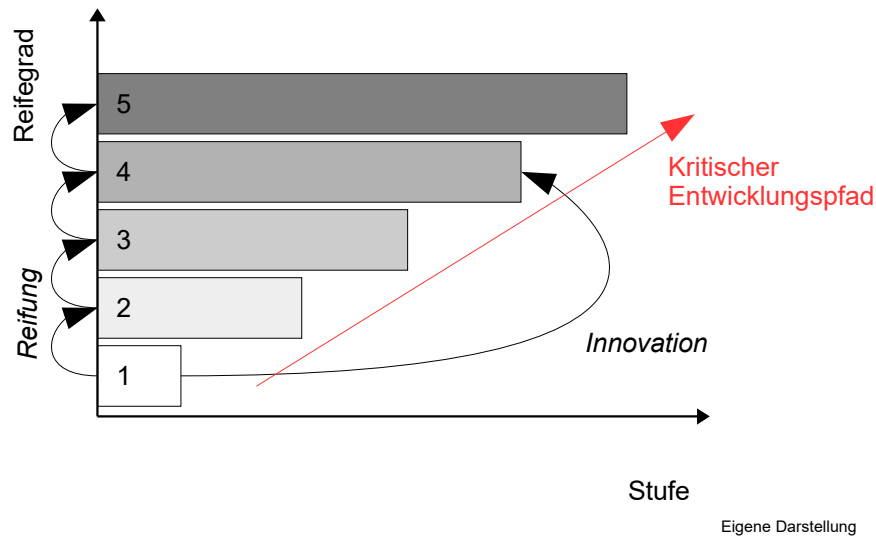


Abbildung 1: Reifegradmodell

Die Grundlage dieser begrifflichen Trennung ist die Annahme, dass sich Objekte entlang eines typischen bzw. kritischen Entwicklungspfad bewegen, wie er bei der Entwicklung von Reifegradmodellen verwendet wird¹⁴. Ganz im Verständnis eines Reifegradmodells und den damit verbundenen möglichen Entwicklungsbewegungen der betrachteten Objekte, beschreibt somit der oben genannte Begriff der Innovation eine sprunghafte¹⁵ Entwicklung, die Revolution, und die Reifung eine inkrementelle Entwicklung, die entlang jeder Reifestufe erfolgt, die Evolution. Im übertragenen Sinne bedeutet dies, dass die Reifung „eine stetige Steigerung der Leistungsfähigkeit bzw. Qualität des betrachteten Objekts“¹⁶ zur Folge hat und das im Falle einer Innovation Leistungsfähigkeiten, Qualitäten und/oder Möglichkeiten nutzbar bzw. lieferbar werden, die Selbige im Vergleich zum Status quo um ein vielfaches übersteigen¹⁷.

¹⁴ Vgl. Becker et al, 2009, S.4.

¹⁵ D.h. über eine oder mehrere Reifestufen hinweg.

¹⁶ Becker et al, 2009, S.4.

¹⁷ Siehe hierzu Abbildung 1: Reifegradmodell.

Das zur Hilfe genommene Instrument des Reifegradmodells dient ursprünglich zur Identifizierung der Leistungsfähigkeit von Organisationen oder Prozessen¹⁸ und nicht zur oben erfolgten Begriffsabgrenzung.

„Reifegradmodelle gehen von der Annahme aus, dass prognostizierbare Muster in der Entwicklung einer Klasse von Objekten bestehen. Diese Entwicklungsmuster werden als evolutionäre Plateaus, Schritte, Stufen oder Level konzeptualisiert und repräsentieren die voneinander abgegrenzten Reifegrade. Entsprechend beschreibt ein Reifegrad, der einem Objekt zugeordnet wird, das Ausmaß dessen Reife. Er definiert die erreichte Stufe in dem antizipierten Entwicklungsprozess des Objektes. Ein Reifegrad ist durch festgelegte Merkmale des zu untersuchenden Objekts und durch die jeweils zur Erreichung des Reifegrads erforderlichen Merkmalsausprägungen definiert. Hierbei handelt es sich um Beschreibungen oder Benchmarking-Kennzahlen, welche die einzelnen Reifegrade charakterisieren. Ist das betrachtete Objekt beispielsweise eine Organisation, so beschreibt der Reifegrad die Leistungsfähigkeit der Organisation im Hinblick auf einen speziellen Bereich“¹⁹.

¹⁸ Vgl. Becker et al, 2009, S. 2.

¹⁹ Becker et al, 2009, S.4 f.

3 Big Data – explorative Klärung des Phänomens

3.1 Einführung in das Themenfeld der Statistik

Statistik erlaubt es, aus einer großen Datenmenge durch geeignete Verfahren die Werte zu berechnen, die als Grundlage für die Entscheidungsfindungen²⁰.

Der Ursprung des Wortes „Statistik“ ist im 17. und 18. Jahrhundert zu finden. Etymologisch fand dies seinen Anfang in dem Wort Status. Aus Status „im Sinne von ‚Staat‘ abgeleiteten Statist ‚Staatsmann, Politiker‘ [...] wird in der 2. Hälfte des 17. Jahrhunderts lateinisch Statistica ‚Staatslehre, Staatswissenschaft‘ gebildet (vgl. italienisch statistica, 17. Jahrhundert), das bald (Anfang 18. Jahrhundert) in der Form Statistik für ‚Beschreibung eines Staates, eines Landes‘ steht und seit der 2. Hälfte des 18. Jhs. zunehmend im heutigen [...] Sinne [...] auch für ‚Zusammenstellung, Darstellung der Ergebnisse von Massenuntersuchungen oder Befragungen‘ gebraucht wird²¹. Diese Entwicklung führt uns zu unserem heutigen in zweierlei Weise vorhandenem Verständnis des Wortes Statistik: Zum einen wird es als Wissenschaft verstanden, die die Erfassung von Massenerscheinungen in Natur und Gesellschaft und die Erforschung der zur Grunde liegenden Gesetzmäßigkeit beinhaltet und beschreibt²². Also als „die Lehre von Methoden der Gewinnung, Auswertung und Interpretation von Informationen über die Wirklichkeit (Empirie)²³. Und zum anderen ist es die graphische „Zusammenstellung der Ergebnisse von Untersuchungen über die zahlenmäßige Häufigkeit bestimmter Erscheinungen“²⁴. Die Funktion von Statistiken lässt sich darauf reduzieren, dass sie Informationen für eine Entscheidungsba-
sis generieren, die mögliche Alternativen für zukünftige Handlungen hinsichtlich ihrer Unsicherheit besser bewertbar machen. Statistiken sollten somit den Ent-

20 Holland, Scharnbacher, 2010, S.2

21 DWDS (Etymologisches Wörterbuch): Statistik.

22 DWDS (Wörterbuch der deutschen Gegenwartssprache, WDG, 1976): Statistik.

23 Eckey/Kosfeld/Türck, 2008, S.1

24 DWDS (Wörterbuch der deutschen Gegenwartssprache, WDG, 1976): Statistik.

scheidungsträgern als qualitative Stütze für ihre Entscheidungen dienen²⁵. Die Statistik, im wissenschaftlichen Verständnis, lässt sich in drei unterschiedliche Teilgebiete unterteilen²⁶:

(1) Die deskriptive Statistik:

Die deskriptive Statistik behandelt und liefert Methoden, mit denen einfache Datenauswertungen²⁷ und -komprimierungen²⁸ möglich sind. Darüber hinaus werden im Rahmen der deskriptiven Statistik die Daten/Merkmale mit deren Ausprägungen beschrieben und graphisch aufgearbeitet bzw. dargestellt²⁹. Die graphische Aufarbeitung und Präsentation kann dabei in Form von Tabellen, Diagrammen, Verlaufskurven o.ä. erfolgen und ist gerade bei umfangreichem Datenmaterial von hoher Bedeutung³⁰. Neben dem deskriptiven Part dient dieses Teilgebiet zusätzlich zur Validierung der Daten³¹ und einer ersten Erkenntnisgewinnung über mögliche Ansätze weiterer Analysen³². Die deskriptive Statistik verwendet hierzu jedoch, im Unterschied zur induktiven Statistik, keine Stochastik³³³⁴.

(2) Die explorative Statistik:

Die explorative Statistik beschäftigt sich im Gegensatz zum oben beschriebenen ersten Teilgebiet mit dem gezielten suchen und finden „von Strukturen und Zusammenhängen im Datenmaterial“³⁵. Basierend auf den gefundenen Strukturen oder Zusammenhängen ergeben sich häufig weiterführende Hypothesen

25 Vgl. Holland/Scharnbacher, 2010, S.2.

26 Vgl. Fahrmeir et al, 2016, S. 10.

27 Vgl. Eckey/Kosfeld/Türck, 2005, S. 1.

28 Vgl. Fahrmeir et al, 2016, S. 10.

29 Vgl. Fahrmeir et al, 2016, S. 10 f.; Henze, 2017, S. 20; Holland/Scharnbacher, 2010, S. 3.

30 Vgl. Fahrmeir et al, 2016, S. 10 f.; Holland/Scharnbacher, 2010, S. 3.

31 „Mit Hilfe der deskriptiven Aufarbeitung der Daten lassen sich relativ leicht Fehler in einem Datensatz, die beispielsweise durch eine falsche Übertragung vom Fragebogen auf den Datenträger entstanden sind, entdecken und eventuell beheben“ Fahrmeir et al, 2016, S. 11.

32 Fahrmeir et al, 2016, S. 11.

33 Definition Stochastik: „Das Wort Stochastik steht als Sammelbegriff für die Gebiete Wahrscheinlichkeitstheorie und Statistik und kann kurz und prägnant als ‚Mathematik des Zufalls‘ bezeichnet werden“ Henze, 2017, S. 1.

34 Vgl. Behnke/Behnke, 2006, S. 105; Fahrmeir et al, 2016, S. 11.

35 Cramer/Kamps, 2014, S. 1; Fahrmeir et al, 2016, S. 10 ff.

oder ganz neue Forschungsansätze, die ohne eine explorative Datenanalyse nicht erkennbar gewesen wären, sowie „deutliche Hinweise [...] für bestimmte Tatsachen oder Forschungshypothesen“³⁶.

(3) Die induktive Statistik:

Im Falle der induktiven Statistik bildet die Wahrscheinlichkeitsrechnung die Ausgangsbasis für alle weiteren Schlussfolgerungen³⁷. Dabei werden die gewonnenen Ergebnisse aus Stichproben auf eine Grundgesamtheit übertragen³⁸ und ermöglichen dadurch „über die erhobenen Daten hinaus allgemeine Schlussfolgerungen [...] zu ziehen“³⁹. Mit der induktiven Statistik sind somit „statistische Schlüsse mittels stochastischer Modelle“⁴⁰ möglich.

36 Fahrmeir et al, 2016, S. 12.

37 Vgl. Eckey/Türck, 2005, S. 2.

38 Vgl. Eckey/Türck, 2005, S.1, S. 180, S. 221; Fahrmeir et al, 2016, S. 12; Holland/Scharnbacher, 2010, S. 3.

39 Fahrmeir et al, 2016, S. 12.

40 Fahrmeir et al, 2016, S. 10.

3.2 Machine Learning

Das Machine Learning stellt gewissermaßen eine Brücke zwischen der oben thematisierten Statistik und dem nachfolgend noch behandelten Thema Big Data dar.

Zunächst ist das Machine Learning, im deutschen maschinelles Lernen, Teil einer Wissenschaft, die sich mit der künstlichen Intelligenz, beschäftigt⁴¹. Im Bereich des maschinellen Lernens liegt der Fokus auf Algorithmen, die ihre Leistungsfähigkeit selbstständig durch Erfahrung das heißt Lernen verbessern⁴². Zu unterscheiden sind dabei vier Ansätze⁴³:

(1) Der psychologische Ansatz

Das Ziel des psychologischen Ansatzes ist die Modellierung der Mechanismen, die dem menschlichen Lernen zugrunde liegen. Forscher entwickeln in diesem Ansatz Lernalgorithmen, die dem menschlichen kognitivem Aufbau nachempfunden sind, und ebenfalls dazu designt wurden spezifische Lernverhalten zu beobachten.

(2) Der empirische Ansatz

Der empirische Ansatz verfolgt das Ziel der Entdeckung von allgemeinen Grundsätzen, die die Eigenschaften von Lernalgorithmen und die Umgebung, in der sie operieren, mit dem Lernverhalten verknüpfen. Dazu bedienen sich die Forscher bei Experimentiertechniken aus der Physik und der Psychologie: Es werden entweder Experimente mit unterschiedlichen Lernalgorithmen in identischen Bereichen oder identische Lernalgorithmen in unterschiedlichen Bereichen durchgeführt um die Beeinflussungen der jeweiligen Änderungen auf das Lernen zu beobachten.

41 Vgl. Nilsson, 2005, S.1; Langley, 1996, S. ix, S.1.

42 Vgl. Langley, 1996, S. ix, S. 5.

43 Bei den nachfolgenden Erläuterungen handelt es sich um freie Übersetzungen aus: Langley, 1996, S. 4 f.

(3) Mathematische Studien

Der Entdeckung von allgemeinen Grundsätzen haben sich ebenfalls die Forscher gewidmet, die das maschinelle Lernen als einen Bereich der mathematischen Studien behandeln. In diesem Falle liegt das Ziel darin, Theorien über die Bearbeitbarkeit von ganzen Klassen von Lernproblemen und Algorithmen, die diese Probleme lösen sollen, zu formulieren und zu beweisen. Dazu werden Werkzeuge und Konzepte der theoretischen Informatik und Statistik verwendet. Typischerweise wird ein Kernproblem definiert und vermutet, dass es sich mit einer ausreichend großen Menge an Trainingsfällen verifizieren oder falsifizieren lässt. Im Anschluss ist zu beweisen, dass diese Vermutung unter sehr allgemeinen Bedingungen gilt.

(4) Der Anwendungs-Ansatz

Der vierte und letzte Ansatz hat die Anwendung des maschinellen Lernens auf reale Probleme zum Ziel. Ein Entwickler formuliert hierzu ein interessantes Problem in Bezug auf das maschinelle Lernen, sammelt die Trainingsdaten und verwendet daraufhin Methoden des maschinelle Lernens um das so entstandene System in der Praxis anzuwenden. Zur Anwendung kommen die Algorithmen des maschinellen Lernens unter anderem bei Data Mining⁴⁴ Prozessen⁴⁵.

Die oben angesprochene Brücke besteht somit insofern, als dass das maschinelle Lernen Anwendung im Bereich des Data Mining findet und sich gleichzeitig Methoden aus der Statistik bedient (u.a. der Wahrscheinlichkeitsrechnung) zur Beurteilung der zu suchenden und findenden Muster und Zusammenhänge⁴⁶.

44 Siehe hierzu 3.3.7.3:Data Analytics, Data Mining, KDD.

45 Vgl. Nilsson, 2005, S. 2; Tsai et al, 2015, S. 18-20.

46 Vgl. Nilsson, 2005, S. 3, Kapitel 5; Manyika et al, 2011, S. 99.

3.3 Big Data – Mehr als nur große Daten?

Die zunehmende Digitalisierung unseres Alltages, der Welt um uns herum und unseres Wissens in den letzten Jahren produziert ständig immer weitere und größere Datenmengen und Informationen⁴⁷. Diese Entwicklung kann als eines der Phänomene⁴⁸ des 21. Jahrhunderts betrachtet werden: Big Data. Die Bestrebung große Datenmengen auszuwerten kam dabei aus unterschiedlichen Fachbereichen. Dazu zählten unter anderem die Forschung im Allgemeinen und die Wirtschaft. Bei letzteren sind dort vor allem die großen Internetkonzerne Amazon und Facebook zu nennen⁴⁹. Die Auswertung der Daten hat dabei viele andere Einflüsse auf nach gelagerte Themen aus dem „technischen, kommerziellen, rechtlichen und sozialen Kontext“⁵⁰. Neben diesen Einflüssen lassen sich auch viele andere, aktuell in den Medien und auf Fachmessen diskutierten, Themen finden: Hier wären beispielsweise die Schlagwörter Internet of things (Iot, Internet der Dinge), Smart Cities/Buildings, bis hin zu den Entwicklungen in der Automobilbranche bezüglich intelligenten und selbst fahrenden Autos zu nennen. Gemein haben all diese Themenbereiche, dass sie entweder auf großen Datenansammlungen und deren Verarbeitung basieren (beispielsweise intelligente und selbst fahrende Autos) oder ebendiese für die Verwendung produzieren (beispielsweise Internet der Dinge). Dorschel⁵¹ umschreibt den Umstand, dass sich unter dem Begriff Big Data viele weitere Aspekte verbergen, sehr treffend mit dem Begriff der Mehrdimensionalität von Big Data:

- Technologien
- Analytische Methoden
- Modellierungs- und Designverfahren
- Kommerzielle Konzepte
- Rechtliche Rahmenbedingungen

47 Vgl. Rafferty/Rafferty/Hung, 2016, S. 2 f.; Cordon et al, 2016, S. 65.

48 Vgl. beispielsweise Olshannikova et al, 2015, S. 4; Morabito, 2015, S. vii.

49 Vgl. Simon, 2014.

50 Dorschel, 2015, S.2; Vgl. Morabito, 2015, S. v.

51 Dorschel, 2015, S.2

3.3.1 Versuch einer Definition

Ward und Barker versuchten 2013 in ihrem Paper „Undefined by Data: A Survey of Big Data Definitions“ auf Grundlage von mehreren Definitionen des Begriffes Big Data „eine klare und prägnante Definition eines ansonsten zweideutigen Begriffs“⁵² zu entwickeln. Lieferanten dieser Definitionen waren unter anderen Branchengrößen aus der IT wie Oracle, Intel und Microsoft. Die beiden Autoren arbeiteten dabei insgesamt drei Kernaussagen heraus, die charakteristisch⁵³ für alle verwendeten Definitionen waren:

- (1) „Größe: Das Volumen des Datensatzes ist ein kritischer Faktor.
- (2) Komplexität: Struktur, Verhalten und Permutationen des Datensatzes sind ein kritischer Faktor.
- (3) Technologien: Die Werkzeuge und Techniken, die zur Verarbeitung eines umfangreichen oder komplexen Datensatzes verwendet werden, sind ein kritischer Faktor.“⁵⁴

Als erste Definitionsgrundlage für Big Data sollen somit nun (1) die Größe sowie (2) Komplexität des betrachteten Datenmaterials und (3) die verwendeten Technologien zur Bearbeitung als ausschlaggebende Faktoren festgelegt werden. Inwiefern diese drei Aspekte aus 2013 in den heutigen Definitionen und Erklärungen noch Bestand haben und ob sie vor den heutigen Ansprüchen und Diskussionen noch ausreichend sind, um das nunmehr sehr komplexe Thema Big Data zu umschreiben, gilt es im weiteren Verlauf zu überprüfen. Dazu wird ähnlich vorgegangen, wie es Ward und Barker getan haben: Es werden unterschiedliche aktuelle Definitionen dargestellt und im nach hinein mit den Kernaussagen von Ward und Barker in Beziehung gesetzt. Im Verlauf der Literaturrecherche wurde zahlreiche Definitionen und Erklärungen des Begriffes Big Data gefunden. Es lassen sich nahezu in jedem für diesen Teil der Arbeit verwendeten Buch ebensolche finden⁵⁵. Da die Darstellung jeder Einzelnen nicht

52 Eigene Übersetzung nach Ward/Barker, 2013, S. 1.

53 Eine dieser Kernaussagen kam dabei immer in den betrachteten Definitionen vor, meistens trafen zwei zu.

54 Ward/Barker, 2013, S. 2.

55 Darüber hinaus liefert King, 2014, S. 34 ff. ebenfalls eine gute Übersicht.

das Ziel dieser Arbeit ist und darüber hinaus den Rahmen sprengen würde, wurde die Auswahl der Einfachheit halber auf deutsche Definitionen von renommierten, vielfach zitierten Autoren beschränkt.

In seinem Handbuch IT-Systemmanagement: Handlungsfelder, Prozesse Managementinstrumente, Good Practices (2016) umschreibt Tiemeyer Big Data auf Seite 378 mit folgender Fragestellung:

„Bei Big Data geht es im Kern um folgende Aufgabenstellung: Wie werden große, unstrukturierte Datenmengen verarbeitet sowie verwaltet und aufbereitet, damit diese für schnelle Analysen zur Verfügung stehen?“

Kürzer hält es ebenfalls Stefan Müller in seinem Beitrag „Erweiterung des Data Warehouse um Hadoop, NoSQL & Co“ in Meier und Fasel, Big Data: Grundlagen, Systeme und Nutzungspotentiale (2016), S. 143:

„Man spricht von Big Data, wenn die traditionellen IT-Systeme an ihre Grenzen geraten und Schwierigkeiten bei der Speicherung und Verarbeitung dieser Datenberge bekommen.“

Schön liefert in Planung und Reporting: Grundlagen, Business Intelligence, Mobile BI und Big-Data-Analytics (2016) eine etwas umfangreichere Umschreibung zu dem Themengebiet auf Seite 298:

„Big Data bietet [...] Werkzeuge und Techniken an, mit denen das Erfassen, Speichern und Analysieren von großen unstrukturierten, strukturieren und semi-strukturierten [...] Datenmengen technisch möglich und wirtschaftlich interessant wird. Big Data soll hiermit neue Erkenntnisse aus der Informationsnutzung (z.B. Abweichungen, Zusammenhänge oder Trenderkennung) zur Verbesserung der Entscheidung auf allen Führungsebenen liefern, um somit zur Wertsteigerung des Unternehmens beizutragen.“

Abschließend sei noch die Definition aus Fasels Artikel Big Data – Eine Einführung Seite 392, zu finden in HMD Praxis der Wirtschaftsinformatik, Ausgabe 51, auf den Seiten 381-520 zu nennen:

„Big Data beschreibt keine neuartige Art von Daten. Es fasst vielmehr Charakteristiken zusammen, die vermehrt bei heutigen Informationsverarbeitungen auftauchen. [...] Im Zusammenhang mit Big Data treten Technologien und Techniken in Erscheinung, welche für die Speicherung und Verarbeitung von Big Data optimiert sind.“

Summa summarum liefern die hier aufgeführten Definitionen aus unterschiedlicher Fachliteratur ein eher einseitiges Bild der Thematik Big Data, sofern man den Horizont erweitert und die unterschiedlichen Perspektiven aus Dorschel, 2015⁵⁶ hinzu zieht⁵⁷: Die in den Definitionen immer wieder angesprochene Verarbeitung von großen Datenmengen ist „kein neues Phänomen“⁵⁸ und betrachtet Big Data in diesem Zusammenhang, aus rein technischer Sicht. Interessanterweise decken diese sich somit immer noch mit den drei Kernaussagen Size, Complexity und Technologies von Ward und Barker, die sich ebenfalls auf rein technische Aspekte beziehen. Rechtliche und soziokulturelle Sichten, wie in Dorschel dargestellt, bleiben bei allen Definitionen gänzlich unbeachtet. Die ökonomische Sicht, wird bis auf eine Ausnahme (Schön, 2016), ebenfalls nicht mit einbezogen. Gerade vor dem Hintergrund der aktuellen Entwicklungen und Veröffentlichungen, wie in der Einleitung dargestellt, sollten vor allem datenschutzrechtliche Aspekte⁵⁹ mit in die Erklärung des Gesamtphänomens Big Data aufgenommen werden. Nach der detaillierten Literaturrecherche sieht der Autor dieser Arbeit Big Data vielmehr als ein Phänomen an⁶⁰, unter dem sich zahlreiche technologische, rechtliche, soziokulturelle und ökonomische Entwicklungen, Probleme und Aspekte zusammenfassen lassen⁶¹.

56 S. 8-10; Vgl. Morabito, 2015, S. 84.

57 Was vor dem Hintergrund der Aktualität des Themas sowie den aktuellen Entwicklungen erfolgen sollte. Siehe die Ausführungen weiter unten.

58 Dorschel, 2015, S. 3.

59 Siehe 3.3.4: Die rechtliche Perspektive.

60 Wie in den vorherigen Ausführungen schon stellenweise getan.

61 Für eine weitere Ausführung wird dem Leser die Keynote, Einführung und Überblick sowie der Punkt 1.2.2 Perspektiven aus Dorschel, 2015 empfohlen.

3.3.2 Big Data und die Vs

*"Big data is high-volume, high-velocity and/or high-variety information assets that demand cost-effective, innovative forms of information processing that enable enhanced insight, decision making, and process automation"*⁶².

Gemeinsam haben dennoch alle oben genannten Definitionen, dass sie dem Begriff Big Data (je nach verwendeter Literatur) drei bis fünf sogenannte „Vs“ zur Spezifizierung zu Grunde legen. Konkret handelt es sich dabei um⁶³:

(1) Volume

(2) Variety

(3) Velocity

(4) Veracity

(5) Value

(1) Volume

*„Although it seems that big data makes it possible for us to collect more data to find more useful information, the truth is that more data do not necessarily mean more useful information"*⁶⁴.

Volume beschreibt die Datenmenge im Unternehmenssystem und wird durch traditionelle sowie neue Datentypen beeinflusst. Auf der einen Seite steigt die Möglichkeit der Identifikation von Zusammenhängen in den vorhandenen Daten mit der steigende Masse an Daten an, unter Umständen auch die Verlässlichkeit dieser⁶⁵, aber auf der anderen Seite auch der zu treibende Aufwand um eben diese steigende Anzahl an Daten analysieren zu können. Die Charakteri-

62 Gartner IT Glossary: Big Data.

63 Die nachfolgenden Erläuterungen wurden frei ins deutsche übersetzt aus:

Pettey/Goasduff, 2011 und ergänzt um: Ward/Barker, 2013, S. 1; Dorschel, 2015, S. 7; Furht/Villanustre, 2016, S. 3; Lomotey/Deters, 2016, S. 110 f.; King, 2014, S. 35; Müller, 2016, S. 6, S.143; Meier/Kaufmann, 2016, S. 13; Schön, 2016, S. 298, S. 302-304; Tiemeyer, 2016, S. 378.

64 Tsai et al, 2015, S. 10.

65 Siehe hierzu: 3.3.2 (4) Veracity.

sierung von Volume erfolgt auf der Grundlage, dass das gesamte Datenvolumen auf der Erde stetig stark anwächst. Weitere aktuelle Themen wie Internet der Dinge und Industrie 4.0 werden diese Entwicklung noch weiter bestärken⁶⁶. Wichtig ist an dieser Stelle, dass in Volume und Big Data keine direkte Korrelation hinein interpretiert wird: Nur weil ein Unternehmen große Datenmengen verarbeitet und verwendet, muss es sich nicht zwangsläufig um Big Data handeln.

(2) Variety

Variety beschreibt die Datenvielfalt und damit das Vorhandensein von unterschiedlichen zu analysierenden Informationen die in jeglicher Datenart und damit Datenendung sowie -struktur vorliegen können. Zu unterscheiden sind dabei strukturierte Daten (beispielsweise Tabellen und Datenbanken aus CRM- oder ERP-Systemen), unstrukturierte Daten (beispielsweise Video-, Audio-, Bild- und Textdateien, Sensordaten) sowie semi-strukturierte Daten. Dabei handelt es sich um eine Mischform aus strukturierten sowie unstrukturierten Daten (beispielsweise E-Mails). Eine Kombination aus strukturierten als auch semi- und unstrukturierte Daten bezeichnet man als poly-strukturierte Daten.

(3) Velocity

Velocity beschreibt insgesamt drei unterschiedliche Aspekte, bedingt durch die jeweilige Wahl der hinzugezogenen Literatur. Nachfolgend werden alle drei Interpretationsmöglichkeiten erläutert. Zum einen kann es die Geschwindigkeit der Datenerzeugung bedeuten und wäre somit sehr eng mit Volume verknüpft. Zum anderen kann darunter auch der Anspruch verstanden werden, der an die Geschwindigkeit der Datenverarbeitung, die im Optimalfall in Echtzeit erfolgen soll, gelegt wird. Zuletzt kann es auch eine Form von Schnelllebigkeit sein und meint „die kurze Halbwertszeit des Erkenntniswertes von Daten. Die durch digitale Daten beschriebenen Sachverhalte ändern sich immer schneller, sodass dem vorhandenen Datenbestand neue oder veränderte Daten hinzugefügt werden müssen“⁶⁷.

66 Vgl. Schön, 2016, S. 298; Seufert, 2014a, S.23-45.

67 Dorschel, 2015, S. 7.

(4) Veracity

Veracity beschreibt die Wahrhaftigkeit oder Richtigkeit der vorhandenen Daten. Die Datensammlungen beinhalten sowohl strukturierte als auch unstrukturierte Daten, die aus unterschiedlichen anderen Systemen und Quellen stammen. Um eine bessere und verlässlichere Qualität der Ergebnisse bei steigender Datenmenge sicherstellen zu können, müssen die verwendeten Daten bereinigt und hinsichtlich ihrer Aussagekraft und Qualität bewertet werden. Diese Bewertung des Datenmaterials ist im Rahmen der Auswertung zu berücksichtigen.

(5) Value

Value steht für die Charakteristik von Big Data auch einen Mehrwert für die Unternehmung zu bieten und somit die Daten für zielgerichtete und wertschöpfende Geschäftsfälle zu verwenden.

3.3.3 Die Big Data-Anwendung

Das Zusammenkommen aller zuvor thematisierten Vs ist dabei entscheidend, ob es sich um eine Big Data Anwendung handelt oder nicht. Daher können diese als erste Indikatoren für die Anwendbarkeit von Big Data im praktischen Kontext herangezogen werden⁶⁸. Werden alle hier erwähnten Informationen zusammen gezogen, lässt sich eine Big Data Anwendung wie in Abbildung 2 darstellen. Die Rohdaten, in poly-strukturierter Form, stammen beispielsweise aus dem unternehmenseigenen ERP-, unter dem Facility Management Gesichtspunkt, CAD- und/oder CAFM-System oder aus der Gebäudeautomation (GA)⁶⁹. Daten, die in strukturierter Form vorliegen, werden über ETL-Prozesse⁷⁰ in das Data Warehouse geladen und um unstrukturierte Daten ergänzt, abgelegt in nicht-relationalen Datenbanken⁷¹.

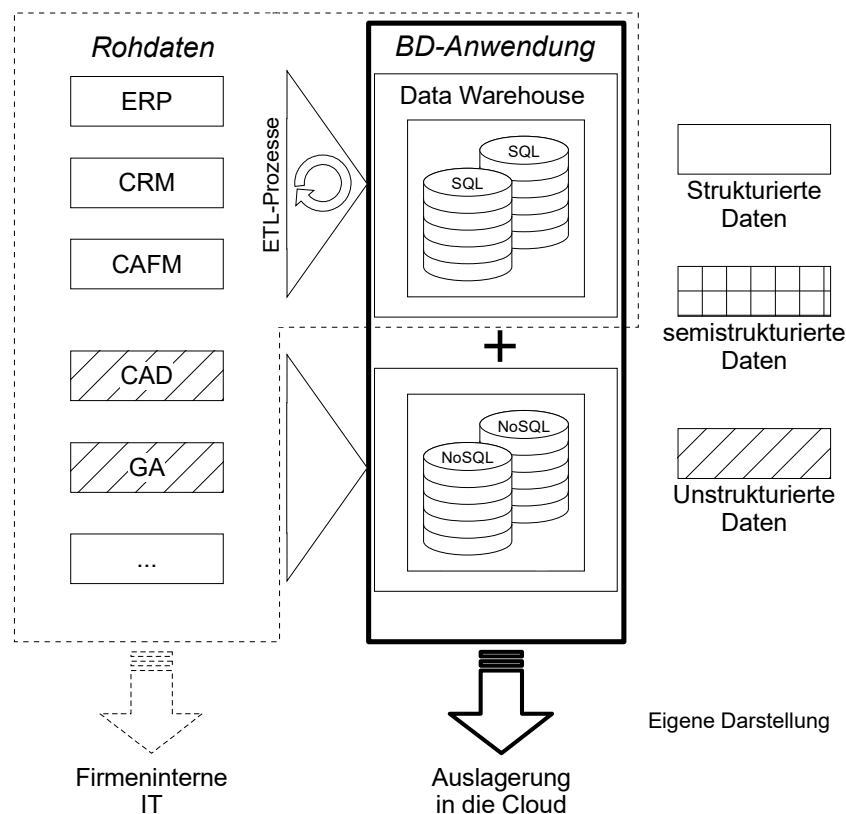


Abbildung 2: Big Data-Anwendung

68 Vgl. Schön, 2016, S. 304.

69 D.h. Sensordaten.

70 Siehe 3.3.7.2:Data Warehouse.

71 Auch als NoSQL-Datenbank zu bezeichnen. Vgl. Fasel/Meier, 2016, S. 11-13.

Diese eignen sich deutlich besser zur Speicherung von unstrukturierten Daten als das Data Warehouse, das auf relationalen Datenbanktechnologien basiert⁷². Darüber hinaus eignen sich nicht-relationale Datenbanken gut für eine parallelierte Verarbeitung von Auswertungen und Analysen über mehrere Server-Cluster, wodurch die Verarbeitungsgeschwindigkeit beschleunigt wird⁷³. Solche Server-Cluster können beispielsweise in Form von Infrastructure as a Service (IaaS), Platform as a Service (PaaS) oder Software as a Service (SaaS) bereitgestellt und genutzt werden⁷⁴. Im Rahmen des IaaS „werden IT-Infrastrukturressourcen, z. B. Rechner-/Server, Speicherplatz, Netzwerk- und andere Basisressourcen und damit verbundene Dienste (Wartung etc.), zur Verfügung gestellt“⁷⁵.

PaaS stellt „Betriebssysteme und Systeme für Entwicklungen (inkl. der hierfür notwendigen IaaS) sowie damit verbundene Dienste zur Verfügung [...], auf denen der Kunde eine eigene Entwicklungsumgebung für die Erstellung und Ausführung von Anwendungen nutzen kann“⁷⁶. Bei der Möglichkeit des SaaS „wird eine vollwertige Applikation/Anwendung (inkl. der hierfür notwendigen IaaS) sowie damit verbundene Dienste zur Verfügung gestellt“⁷⁷.

72 Vgl. Fasel/Meier, 2016, S. 6-9; Schön, 2016, S. 298 und siehe 3.3.7.2:Data Warehouse.

73 Vgl. Fasel/Meier, 2016, S. 12.

74 Schön, 2016, S. 316-319.

75 Schön, 2016, S. 317; Vgl. Duisberg, 2011, S. 49.; Mell/Grance, 2011, S. 3.

76 Schön, 2016, S. 317 ; Vgl. Duisberg, 2011, S. 49.; Mell/Grance, 2011, S. 2-3.

77 Schön, 2016, S. 318 ; Vgl. Duisberg, 2011, S. 49.; Mell/Grance, 2011, S. 2.

3.3.4 Die rechtliche Perspektive

„Mastering big data means mastering privacy too“⁷⁸.

Aus der rechtlichen Perspektive sind im Rahmen von Big Data Anwendungen zahlreiche Gesetze zu beachten und einzuhalten, deren politische Diskussion und eindeutige Definition gerade erst in den allgemeinen Fokus rückt⁷⁹. Unternehmen im deutschen Raum sehen sich in diesem Zusammenhang gleich mit mehreren Schutzrechten konfrontiert⁸⁰:

(1) Dem Datenschutz⁸¹:

„Das Grundgesetz gewährleistet jeder Bürgerin und jedem Bürger das Recht, über Verwendung und Preisgabe seiner persönlichen Daten zu bestimmen (Grundrecht auf informationelle Selbstbestimmung)“. Unter den gesetzlichen Schutz fällt somit die Freiheit der Menschen, selbst darüber entscheiden zu können, „wer was wann und bei welcher Gelegenheit über sie weiß“. Der deutsche Datenschutz schützt die Privatsphäre der Bürger, vor Datenmissbrauch und sichert das Recht auf informationelle Selbstbestimmung⁸². Konkret soll in diesem Zusammenhang die Rechtmäßigkeit der Verwendung der Daten der jeweils betroffenen Person geklärt werden. Da sich die erhobenen Daten auf den Betroffenen beziehen, können diese Daten auch Rückschlüsse auf ihn zulassen⁸³. Aufgrund der Möglichkeit Aussagen über die Person tätigen zu können wird „die Freiheit der Menschen, selbst zu entscheiden, wer was wann und bei welcher Gelegenheit über sie weiß“ eingeschränkt und somit Thema des Bundesdatenschutzgesetzes⁸⁴.

78 Kroes, 2013.

79 Vgl. Schulzki-Haddouti, 2017, S. 6.

80 Dorschel, 2016, S. 167-245.

81 Für eine umfassendere Auseinandersetzung mit dem Datenschutz im Big Data Kontext sei Morgenroth et al, 2017 empfohlen.

82 BfDI, o.J.

83 Vgl. Rafferty/Rafferty/Hung, 2016, S. 10 f.; Tsai et al, 2015, S. 26; Morabito, 2015, S. 14.

84 Vgl. Dorschel, 2016, S. 213; Heuberger-Götsch, 2016, S. 85.

(2) Dem Leistungsschutz/Verwandte Schutzrechte:

„Für Leistungsschutzrechte (oder auch „verwandte Schutzrechte“) ist [...] allgemein kennzeichnend, dass der Schutz nicht an einer persönlichen geistigen Schöpfung anknüpft – wie dies sonst zum urheberrechtlichen Schutz nach § 2 Abs. 2 Urheberrechtsgesetz (UrhG) erforderlich ist – sondern an einer Leistung anderer Art, die jedoch der schöpferischen Leistung des Urhebers ähnlich ist oder im Zusammenhang mit urheberrechtlich geschützten Werken erbracht wird“⁸⁵. Unter den verwandten Schutzrechten werden zahlreiche, den Urheberrecht ähnliche, Schutzrechte zusammengefasst. Hierzu zählt auch der Schutz des Datenbankherstellers⁸⁶. Mit diesen gesetzlichen Regelungen wurden wiederum dem Big Data Anwender⁸⁷ Möglichkeiten geschaffen, seinen immateriellen Besitz, in Form von Daten und Wissen, gegen Dritte zu schützen.

(3) Dem Integritätsschutz:

„Integrität bezeichnet die Sicherstellung der Korrektheit (Unversehrtheit) von Daten und der korrekten Funktionsweise von Systemen. Wenn der Begriff Integrität auf Daten angewendet wird, drückt er aus, dass die Daten vollständig und unverändert sind. In der Informationstechnik wird er in der Regel aber weiter gefasst und auf "Informationen" angewendet. Der Begriff "Information" wird dabei für "Daten" verwendet, denen je nach Zusammenhang bestimmte Attribute wie z. B. Autor oder Zeitpunkt der Erstellung zugeordnet werden können. Der Verlust der Integrität von Informationen kann daher bedeuten, dass diese unerlaubt verändert, Angaben zum Autor verfälscht oder Zeitangaben zur Erstellung manipuliert wurden“⁸⁸. Unter Integritätsschutz ist somit der Schutz der Daten vor Manipulation durch Dritte zu verstehen und zielt damit auf die Datensicherheit ab bzw. auf die Absicherung der Datenbank vor ungewolltem Zugriff durch Dritte⁸⁹.

85 Dorschel, 2016, S. 224 und vgl. Bundestagsdrucksache 4/270, 1962, S. 33 f.

86 Vgl. §§ 87 a-e UrhG.

Datenbankhersteller im Sinne des Gesetzes ist derjenige, der die Investition für die Sammlung von Werken, Daten oder anderen unabhängigen Elementen getätigt hat. Vgl. §87 a, Abs. 1 und 2 UrhG.

87 Ist hier im Sinne von Datenbankhersteller zu verstehen, d.h. Hersteller der eigentlichen Datenbank und Anwender, der wiederum seine „eigene“ Datenbank aufbaut/mit Daten füllt, sind in diesem Falle identisch.

88 BSI Online Glossar und Begriffsdefinitionen: Integrität.

89 Ein Negativbeispiel: Rafferty/Rafferty/Hung, 2016, S. 11.

Die hier allgemein dargestellten rechtlichen Aspekte stellen lediglich übergeordnete Punkte in der gesamten rechtlichen Thematik dar. Allen dreien liegen eine Vielzahl an weiteren Gesetzen verknüpft mit technischen Maßnahmen zur Absicherung zur Grunde, deren Erwähnung und Erläuterung schlichtweg den Rahmen dieses Abschnittes sprengen würden. Von daher sollen die hier ausgeführten kurzen Erläuterungen genügen: Big Data im rechtlichen Kontext ist einer separaten Arbeit, um es in der notwendigen Tiefe und mit allen Aspekten beleuchten zu können, würdig. Dieser kleine Einblick in die rechtliche Perspektive dient zur Herausstellung der Wichtigkeit und Bedeutung des Datenschutzes und der Sicherheit⁹⁰.

⁹⁰ Siehe dazu auch: Gluchowski, 2014, S. 410.

3.3.5 Einsatzbereiche, Nutzen und Potentiale

„Data has a tremendous potential to drive innovation, the economy, productivity and future growth“⁹¹.

Es gibt viele Big Data Projekte in der Anwendung (u.a. im US-amerikanischen Gesundheitswesen, im öffentlichen Sektor der EU, im US-Einzelhandel, in der Fertigung etc.⁹²), die das Potential und die Möglichkeiten durch Big Data nutzen. Neben den praktischen Anwendungsfällen⁹³ liegen auch bereits einige wissenschaftliche Studien zu den möglichen Potentialen von Big Data vor und auch die Literatur diskutiert über diese Thematik.

Die nachfolgenden Erläuterungen, für dieses und das nächste Kapitel Herausforderungen, Treiber und Barrieren, sind in zwei Bereiche eingeteilt: Den Anfang machen die Ergebnisse aus der Literaturrecherche, die im Anschluss um die empirischen Erkenntnisse aus den Studien ergänzt werden. Die Grundlage der empirischen Erkenntnisse bildet zum einen der Artikel „Empirische Ergebnisse zu Big Data“ von Gluchowski, aus der Fachzeitschrift HMD – Praxis der Wirtschaftsinformatik, 2014 Nr. 51, in welchem „unabhängige, frei verfügbare Studien zum Thema Big Data herausgegriffen und gleichartige sowie abweichende Ergebnisse in kondensierter Form präsentiert“⁹⁴ werden. Konkret handelt es sich dabei um die Studien⁹⁵

- des The Data Warehousing Institute (TDWI) Germany e.V. in Kooperation mit der SAP AG, durchgeführt im Jahr 2012 von Gluchowski⁹⁶,
- der BITKOM Big-Data-Studie „Big Data im Praxiseinsatz – Szenarien, Beispiele, Effekte“, ebenfalls aus dem Jahr 2012⁹⁷,

91 Rafferty/Rafferty/Hung, 2016, S. 3.

92 Siehe hierzu beispielsweise Manyika et al, 2011; Cavanillas/Curry/Wahlster, 2016, Part III; Rafferty/Rafferty/Hung, 2016, S. 3.

93 Siehe 3.4: Beispiele aus der Praxis – Immobilien im Einfluss von Big Data

94 Gluchowski, 2014, S. 402.

95 Vgl Gluchowski, 2014, S. 402.

96 Abrufbar unter: <http://www.tdwi.eu/wissen/studien/>

97 Abrufbar unter: <https://www.bitkom.org/Bitkom/Publikationen/Leitfaden-Big-Data-im-Praxiseinsatz-Szenarien-Beispiele-Effekte.html>

- der Innovationspotenzialanalyse „Big Data – Vorsprung durch Wissen“ (2012) des Fraunhofer-Instituts für intelligente Analyse- und Informationssysteme (IAIS)⁹⁸,
- Steria Mummert Consulting mit ihrer biMA-Studie aus dem Jahr 2013⁹⁹.

Zum anderen wird der Beitrag von Seufert, aus selbiger Fachzeitschrift, „Entwicklungsstand, Potentiale und zukünftige Herausforderungen von Big Data“ verwendet. Dieser analysiert aufbauend auf der Studie „Competing on Analytics – Herausforderungen, Potentiale und Wertbeiträge von Business Intelligence und Big Data“, veröffentlicht 2014, vom Institut für Business Intelligence (IBI), „den Status Quo von Business Intelligence und Big Data im deutschsprachigen Raum. Im Fokus dabei stehen nicht einzelne Technologien, sondern Fragestellungen über den Entwicklungsstand und Anwendungspotentiale“¹⁰⁰.

Der Einsatz von Big Data bietet direkten, aber auch indirekten Nutzen¹⁰¹ für eine Organisation. Als eines der Kernpotentiale von Big Data wird die Verwendung von Big Data zur Entscheidungsunterstützung angeführt. Durch empirische Untersuchungen und Ergebnisse sollen Bedürfnisse ermittelt, Varianzen aufgezeigt und die Leistung verbessert werden¹⁰². Mit der Analyse von Kundenbedürfnissen verspricht man sich beispielsweise die Verbesserung des Kundenservices und der Kundenerfahrungen¹⁰³. Neben der Entscheidungsunterstützung soll auch eine verbesserte und schnellere Entscheidungsfindung möglich sein. Durch qualitativ höherwertige, aber dennoch kostengünstigere Informationsanalysen, denen größeren Datenmengen zur Grunde liegen, werden organisatorische Vorteile erzielt¹⁰⁴. Zum Bereich der Entscheidungsunterstützung zählt ebenfalls die Entscheidungsautomation: Big Data soll menschliche Entscheidungen durch automatisierte Algorithmen unterstützen oder gar komplett erset-

98 Abrufbar unter: <https://www.iais.fraunhofer.de/de/geschaeftsfelder/big-data-analytics/referenzprojekte/big-data-studie.html>

99 Bei soprasteria Consulting (<https://www.soprasteria.de/>) zu erhalten.

100 Seufert, 2014b, S. 412.

101 Für den indirekten Nutzen siehe die Ausführungen zum Datenpool.

102 Vgl. Manyika et al, 2011, S. 98 f.; Morabito, 2015, S. 14; Tiemeyer, 2016, S. 380/381.

103 Vgl. Chen, Zhang, 2014, S. 317.

104 Vgl. Morabito, 2015, S. 13; Tiemeyer, 2016, S. 380.

zen. Dies trägt zur Verbesserung der Entscheidungen, Risikominimierung und dem aufdecken von wichtigen Erkenntnissen, die andernfalls unentdeckt geblieben wären, bei, indem durch Big Data entweder das Rohmaterial zur Entwicklung solcher Algorithmen bereitgestellt wird oder diese Algorithmen genutzt werden¹⁰⁵. In eine ähnliche Richtung greift das Potential durch Segmentierung: Mittels Big Data lässt sich die Gesamtheit in kleinere Segmente, identischer Eigenschaften, unterteilen und somit eine individuellere Anpassung/Verbesserung von Prozessen, Abläufen und Funktionen umsetzen. Die praktische Anwendung erfolgt beispielsweise im Target-Marketing¹⁰⁶. Mit dem Aufbau einer Big Data Anwendung sind massive Daten verknüpft. Der entstehende organisierte Datenpool, bestehend aus poly-strukturierten Daten, muss mit Daten gefüttert werden, das heißt die im Unternehmen vorliegenden Informationen werden digitalisiert und im Datenpool gesammelt. Durch die Digitalisierung und die zentrale Sammlung der Daten steigt die Informations- und Datentransparenz im Unternehmen an, diese sind einfacher und schneller zu finden und werden effizienter über das gesamte Unternehmen hinweg verteilt. Schlussendlich resultiert dies in einer besseren und schnelleren Datenverarbeitung und -analyse sowie einer verbesserten Zusammenarbeit innerhalb der Organisation¹⁰⁷. Darüber hinaus wird in Big Data das Potential gesehen neue Geschäftsmodelle, Produkte und Services zu entwickeln beziehungsweise bestehende zu verbessern¹⁰⁸ sowie die strategische Ausrichtung des Unternehmens zu verbessern und an neue Marktsituationen anzupassen¹⁰⁹.

„When organizations can make use of the full potential of big data analytics rather than just a segment, they gain a truly powerful tool to boost their Return on Investment“¹¹⁰.

105 Vgl. Manyika et al, 2011, S. 99.

106 Vgl. Manyika et al, 2011, S. 99; Morabito, 2015, S. 6 f.

107 Vgl. Manyika et al, 2011, S. 97/98; Morabito, 2015, S. 13/14; Tiemeyer, 2016, S. 381.

108 Vgl. Chen/Zhang, 2014, S. 317; Manyika et al, 2011, S. 99/100; Morabito, 2015, S. 8 f.

109 Vgl. Chen/Zhang, 2014, S. 317.

110 Rafferty/Rafferty/Hung, 2016, S. 3.

Neben den eingangs schon erwähnten Branchen des Gesundheitswesens und der öffentlichen Verwaltung bzw. der Politik bieten auch Banken und Versicherungen sowie im Bereich der Umwelt-/Klimaforschung Anwendungsmöglichkeiten für Big Data. Diese reichen von Bonitätsprüfungen¹¹¹ und Betrugserkennungen bis zu besseren Prognosen für Klima- und Wetter, Meinungen und Wahlen sowie Lebenserwartungen und Krankheitsverläufen¹¹². Werden die Möglichkeiten auf Unternehmensebene heruntergebrochen profitierenden maßgeblich folgende Bereiche¹¹³:

- Marketing, Vertrieb und E-commerce:
 - Verbesserung der kundenbezogenen Prozesse.
- Produktion und Logistik:
 - Verbesserung der Prozessteuerung und Effizienzsteigerungen durch einen besseren Einblick in die Prozessabläufe über IoT¹¹⁴.
- Forschung und Entwicklung:
 - Verbesserung der Informationsfähigkeit; Entwicklung neuer Produkte und Services durch Analyse und Identifikation der Kundenbedürfnisse.
- Management, Risikomanagement, Finanzen und Rechnungswesen, Controlling:
 - Verbesserte Prognosefähigkeit, Reaktionsfähigkeit, Risikoabschätzung und Controllingfähigkeiten durch gezielte Analysen.

111 Siehe hierzu auch Fußnote 81.

112 Vgl. Schön, 2016, S. 301 Tab. 5.4.

113 Vgl. Schön 2016, S. 299 f. Tab. 5.4; Tiemeyer, 2016, S. 379.

114 Siehe 3.3.7.4: Internet of things.

Die von Seufert durchgeführte Studie zeigt, dass im deutschen Raum vor allem analytische Potentiale im „verstehen des eigenen Geschäftsumfeldes“¹¹⁵ gesehen werden. Als meist genannte Punkte werden dort die Identifikation

- von Einflussgrößen/Treibern (auf Kaufentscheidungen),
- von bislang unentdeckter Muster (z.B. Ähnlichkeiten bei Kunden),
- der Stärke von Einflussgrößen/Treibern,
- von Wechselwirkungen der Einflussgrößen/Treibern

aufgeführt. Die Möglichkeit Vorhersagen und Prognosen aufzustellen sowie Entscheidungsmodelle zu simulieren scheint zunächst zweitrangig zu sein, obwohl dies Teile der Kernanalysen/-aufgaben von Data Analytics sind¹¹⁶. Im Gegensatz zu den Erkenntnissen aus Manyika et al, in denen die automatisierte Entscheidungsunterstützung als eine der fünf Potentiale durch Big Data herausgestellt wurden, scheint die Generierung von autonomen Entscheidungsvorlagen „noch nicht im Fokus der Studienteilnehmer“ zu stehen¹¹⁷. In Bezug auf die betriebswirtschaftliche Anwendung werden in den Bereichen Management/Unternehmenssteuerung/ Controlling, Vertrieb, Marketing und Forschung und Entwicklung Potentiale gesehen. Je nach betrachteter Studiengruppe (Kleine und mittlere Unternehmen vs. Großunternehmen) fällt das Potential der Bereiche die zur Wertschöpfung beitragen (Produktion und Logistik), höher aus¹¹⁸. Mögliche Einsatzbereiche hat ebenfalls die BITKOM-Studie schwerpunktmäßig untersucht¹¹⁹. Dabei kam sie, genauso wie die Frauenhofer-Studie, zu dem Ergebnis, dass die Anwendungsfelder für Big Data „höchst branchen- teilweise sogar [...] unternehmensspezifisch“¹²⁰ sind. Unter prozessseitiger Betrachtung stehen kundenseitige und Innovationsprozesse an erster Stelle. Mit deutlichem Abstand folgen Produktions/ Leistungserstellungsprozesse, lieferantenseitige Prozesse, Finanzprozesse und IT-Prozesse. Das geringste Potential wird in HR-Prozessen gesehen¹²¹. Zu einem ähnlichen Ergebnis kommen auch die biMA- sowie

115 Seufert, 2014b, S. 417.

116 Siehe hierzu: 3.3.7.3:Data Analytics, Data Mining, KDD

117 Seufert, 2014b, S. 417.

118 Vgl. Seufert, 2014b, S. 418.

119 Vgl. Gluchowski, 2014, S. 403.

120 Gluchowski, 2014, S. 409.

121 Vgl. Seufert, 2014b, S. 419.

BITKOM-Studie: Die Verbesserung kundenbezogener Prozesse ist maßgeblich¹²². Im Bereich der Geschäftsziele steht, wie auch zu Beginn bei den analytischen Potentialen, das bessere Verständnis der eigenen Geschäfte im Fokus. Hierzu zählen unter anderem Chancen und Risiken im Geschäft sowie Umsatzsteigerungs- und Kostensenkungspotentiale zu identifizieren oder die allgemeine Transparenz zu erhöhen. Nahezu gleichauf liegen Entscheidungen, in Zusammenhang mit den Prognosefähigkeiten, zu verbessern und die Geschwindigkeit, konkret ist an dieser Stelle die Reaktionsfähigkeit des Unternehmens gemeint, zu erhöhen. Die Sichtweise „Information as an asset“ scheint sich im deutschsprachigen Raum noch nicht durchgesetzt zu haben, da die Kategorie Informationen als Produkt den letzten Platz einnimmt¹²³. Die Fraunhofer Studie deckt sich an dieser Stelle mit den genannten Ergebnissen sehr gut. Auch sie identifizierte Umsatzsteigerungen und Kosteneinsparungen als einer der Ziele des Big Data Einsatzes. Darüber hinaus nennt sie noch Produktivitätssteigerungen, die gleichbedeutend mit dem besseren Verständnis des eigenen Geschäfts aus der IBI-Studie gesehen werden können, und den Aufbau strategischer Wettbewerbsvorteile¹²⁴.

Die Ergebnisse aus der Literaturrecherche und aus den empirischen Studien gehen Hand in Hand. Es werden sich allgemein zahlreiche Vorteile durch den Einsatz von Big Data versprochen, die in Performance-Verbesserungen und Steigerungen der betrieblichen Effizienz münden.

„The more companies characterized themselves as data-driven, the better they performed on objective measures of financial and operational results. In particular, companies in the top third of their industry in the use of data-driven decision making were, on average, 5% more productive and 6% more profitable than their competitors“¹²⁵.

122 Vgl. Gluchowski, 2014, S. 409.

123 Vgl. Seufert, 2014b, S. 420.

124 Vgl. Gluchowski, 2014, S. 409.

125 McAfee/Brynjolfsson, 2012, S. 64.

3.3.6 Herausforderungen, Treiber und Barrieren

„While businesses across industries recognize the imperative of big data, there are many challenges that face the research and evolution in this field. The most prevalent are skill set shortages, cultural barriers, processes and structures, and technology maturity levels“¹²⁶

Rund um das Thema Barrieren und Lösungen im Big Data Kontext hat sich King in ihrer Dissertation „Big Data – Potential und Barrieren der Nutzung im Unternehmenskontext“ gewidmet. Im Rahmen der Literaturstudie hat sie zahlreiche Barrieren und Lösungen identifiziert und liefert somit eine sehr gute Übersicht und einen guten Einblick in die zu bewältigenden Barrieren. Im weiteren Verlauf werden die von King herausgearbeiteten sechs Oberkategorien/-barrieren (1) Daten, (2) Ethik, (3) Gesellschaft/Kultur, (4) Organisation, (5) Rechtslage und (6) Technologie kurz dargestellt¹²⁷:

(1) Daten:

Unter den Daten-Barrieren verbergen sich mehrere Aspekte: Zwei davon sind der Datenzugang und „die große Unsicherheit im Hinblick auf die Bedeutung und Genauigkeit“¹²⁸. Im Falle des Datenzugangs ist nach Art des Unternehmens zu unterscheiden: Traditionelle Unternehmen, deren Basis „klassische Strukturen und Geschäftsmodelle“¹²⁹ ausmachen, haben einen großen Nachteil gegenüber Firmen, deren Basis aus Daten bestehen (beispielsweise Internetkonzerne), weil sie die fehlenden Daten entweder zeit- und kostenintensiv selbst sammeln oder, falls vorhanden, teuer Daten von Anbietern hinzukaufen müssen. Im Falle der Datenunsicherheit haben Unternehmen zum einen mit dem Punkt Ver-

126 Morabito, 2015, S. 11.

127 Vgl. King, 2014, S. 117-122.

128 King, 2014, S. 117.

129 Meier/Fasel, 2016, S. 4.

acity zu kämpfen¹³⁰, zu anderen mit der erhöhten Gefahr von Scheinkorrelationen¹³¹, die die Notwendigkeit von Fachwissen beziehungsweise Spezialisten erfordert, um aus den Daten richtige und aussagekräftige Inhalte abzuleiten¹³².

(2) Ethik:

Als weitere Barriere führt King ethische Aspekte an. Dies ist im Zusammenhang mit dem ethisch korrekten Umgang von datenschutzwürdigen Informationen zu sehen und den Konsequenzen, die aus einem unkorrekten Handeln resultieren.

(3) Gesellschaft/Kultur:

Im gesellschaftlichen Kontext ist vor allem die Bereitschaft der Kunden Daten mit dem Unternehmen zu teilen eine Barriere. Insgesamt sind die gesellschaftlichen Barrieren „abhängig von der Herkunft beziehungsweise Kultur der Internetnutzerinnen und -nutzer, der Art der Daten und dem Zweck der Datennutzung“¹³³.

(4) Organisation:

Wird die Organisation an sich betrachtet gibt es eine Vielzahl an Barrieren¹³⁴. Eine ist beispielsweise die mangelnde Akzeptanz der gewonnenen Informationen zur Entscheidungsunterstützung auf der Führungsebene oder die ungleiche Ausrichtung des Big Data Projektes und der Unternehmensstrategie.

(5) Rechtslage:

Im Falle der Rechtslage stellt die unzureichende und inkonsistente Regelung des Datenschutzes, und der damit zusammenhängenden Privatsphäre, im Big Data Kontext, die Barriere dar. „Im Gegensatz zu anderen Vermögenswerten eines Unternehmens bestehen für Daten nur wenige rechtliche Handlungsrichtlinien“¹³⁵.

130 Siehe 3.3.2: Big Data und die Vs.

131 „Man spricht von einer Scheinkorrelation, wenn eine absolut hohe Korrelation ermittelt wird, ohne dass die beiden betrachteten Merkmale in einem kausalen Zusammenhang stehen.“
Eckey, Kosfeld, Türck, 2008, S. 186.

132 Vgl. Fasel, 2014, S. 399; Franks, 2012, S. 10-12; King, 2014, S. 117.

133 King, 2014, S. 118.

134 Siehe hierzu: King, 2014, S. 121/122 Tab. 3.

135 King, 2014, S. 119.

(6) Technologie:

Als letzten Punkt nennt King technologische Barrieren. Diese hängen stark vom jeweiligen Unternehmen (Größe, Branche, Unternehmensziele, Big Data Erfahrungen) ab: Je nach Ausprägung der Einflussfaktoren können die Charakteristika von Big Data¹³⁶ zur Barrieren werden.

Die im Rahmen des Kapitels Einsatzbereiche, Nutzen und Potentiale verwendeten Studien liefern auch Informationen bezüglich möglicher Barrieren für den Big Data Einsatz. Sowohl die BITKOM-, Fraunhofer-, IBI-, auch als TDWI-Studie kamen zu der Erkenntnis, dass das fehlende Know-How in der eigenen Organisation zur Einführung, Umsetzung und Nutzung von Big Data eine der Hauptbarrieren für den Einsatz von Big Data ist¹³⁷. Ebenfalls deckungsgleich waren die Erkenntnisse der Fraunhofer-, IBI- und TDWI-Studie bei den, mit dem Einsatz von Big Data verbundenen, hohen Kosten beziehungsweise dem nicht ausreichenden Budget¹³⁸. Eine weitere Übereinstimmung ist bei der biMA- und TDWI-Studie zu finden: Beide stellen die schwierige Identifikation eines Business Cases für Big Data heraus. Neben diesen lieferte die TDWI-Studie noch das Problem der falschen Auslegung der BI-Architektur sowie der großen Komplexität einer Big Data Analytics-Lösung. Als einzige Studie nannte die Fraunhofer-Studie den Datenschutz sowie die Datensicherheit als eine entscheidende Barriere für den Big Data Einsatz¹³⁹.

Somit ergibt sich durch die empirischen Studien, in Abhängigkeit der Nennungen, folgendes Bild: Als größte Hürde wird das mangelnde Know-How in den Unternehmen gesehen, dicht gefolgt von den damit verbundenen Kosten und der Schwierigkeit ein passendes Business Case zu identifizieren. Im Vergleich zu den Erkenntnissen aus King liegen Übereinstimmungen im Falle des Know-How Mangels sowie den finanziellen Problemen vor und erscheinen somit als

136 Siehe: 3.3.2: Big Data und die Vs.

137 Vgl. Gluchowski, 2014, S. 404; Seufert, 2014b, S. 416 und S.421.

138 Vgl. Gluchowski, 2014, S. 404; Seufert, 2014b, S. 416.

139 Vgl. Gluchowski, 2014, S. 404.

die Hauptbarrieren, die es zu bewältigen gilt. Interessanterweise scheint die konkrete Anwendungsfähigkeit, das heißt ein passendes Business Case zu finden, bei King außer Frage zu stehen. Gesetzt dem Fall dies wäre so: Was treibt ein Unternehmen dazu Big Data einzusetzen, das heißt alles daran zu setzen ein für sich passendes Business Case zu finden? Einer ähnlichen Fragestellung ist ebenfalls Seufert in seiner Studie nachgegangen und konnte insgesamt fünf Faktoren herausstellen, die die Unternehmen dazu bewegen zukünftig Big Data stärker zu nutzen. Zum einen liegt es in den neuen technologischen Möglichkeiten begründet, mit denen sich immer größerer Datenmassen in immer kürzerer Zeit verarbeiten lassen, aber auch einfach an der Tatsache, dass immer mehr neue auswertbare Daten generiert werden. Neben den technologischen Auswirkungen wird auch die zunehmende Wettbewerbsintensität ihren positiven Beitrag dazu leisten. In der steigenden Komplexität und Dynamik im Marktumfeld werden ähnliche starke Treiber gesehen, sodass summa summarum die Nutzung von Big Data erheblich zunimmt¹⁴⁰.

140 Seufert, 2014b, S. 421.

3.3.7 Begriffe rund um Big Data

3.3.7.1 Business Intelligence

Business Intelligence (BI) ist im Sinne von Unternehmenswissen bzw. Unternehmensinformationen¹⁴¹ zu verstehen. Es „ist ein unternehmensweites Konzept für die Analyse respektive das Reporting von relevanten Unternehmensdaten¹⁴²“ und beinhaltet einen Analyseprozess, von im Unternehmen vorhandener Daten, zur Herstellung von Fakten, die als Entscheidungsbasis für das Management dienen¹⁴³ sowie „betriebswirtschaftliche Managementmethoden und Steuerungsaufgaben¹⁴⁴“. „Strategisches Ziel von Business Intelligence ist es, bessere und schnellere Entscheidungen als der Wettbewerb zu treffen. Ein BI-System hilft Antworten auf kritische Fragen zu erhalten, indem Daten in Wissen verwandelt werden“¹⁴⁵. Dieses Wissen tritt sich in Form von Informationen über die „Produkte, Lagerbestände, Kundinnen und Kunden, Konkurrenz sowie Branchenangaben¹⁴⁶“ eines Unternehmens auf, gewonnen aus den unternehmensinternen Daten, die im sogenannten Data Warehouse¹⁴⁷ gesammelt und analysiert werden. Beispielsweise stammen die Daten aus ERP- und CRM-Systemen¹⁴⁸.

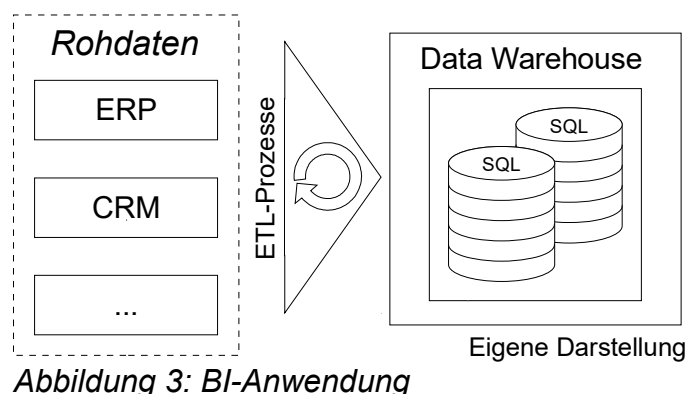


Abbildung 3: BI-Anwendung

141 Vgl. Hanning, 2008, S. 77; Schön, 2016, S. 291.

142 Kaufmann/Meier, 2016, S. 241.

143 Vgl. Kaufmann/Meier, 2016, S: 199 f.

144 Schön, 2016, S. 291.

145 Müller, 2016, S. 140.

146 King, 2014, S. 38.

147 Siehe: 3.3.7.2:Data Warehouse.

148 Müller, 2016, S. 140.

Der Umfang solcher Daten ist dabei deutlich geringer als im Rahmen von Big Data und beinhaltet ausschließlich Daten in strukturierter Form¹⁴⁹. Neben weiteren Faktoren¹⁵⁰ sind somit sowohl die Art der vorhandenen Datenstruktur (strukturiert vs. poly-strukturiert) als auch die Datenmenge zwei wesentliche Unterscheidungsmerkmale zwischen Business Intelligence und Big Data.

149 Vgl. Müller, 2016, S. 157 Tab. 7.2.

150 Siehe Fußnote 149.

3.3.7.2 Data Warehouse

Als Vater des Data Warehouses wird häufig W.H. Bill Inmon bezeichnet¹⁵¹, der folgende Definition geprägt hat:

„A data warehouse is a subject-oriented, integrated, nonvolatile, time-variant collection of data in support of management's decision“¹⁵².

Was unter den sich daraus ergebendes vier Charakteristika des Data Warehouse, namentlich (1) Subjektorientierung, (2) Integriertheit, (3) Nicht-Volatilität und (4) Zeitvarianz, zu verstehen ist, wird nachfolgend geklärt¹⁵³:

(1) Mit der *Subjektorientierung* spricht Inmon dabei die Fach- beziehungsweise Themenorientierung des Data Warehouse an. Das heißt die Trennung und Extraktion der für Entscheidungen relevanten Daten, wie Kunden, Verträge und Produkte, von beziehungsweise aus den vorgeschalteten, operativen Basissystemen (Quellen) des Unternehmens in einer separaten neuen Datenbank. So dass diese Daten vollständig an einem Ort zur Verfügung stehen.

(2) Unter *Integriertheit* ist die Integration der Daten in die Datenbank¹⁵⁴ des Data Warehouse zu verstehen. Daten aus unterschiedlichen Ursprungssystemen werden über ETL-Prozesse so aufgearbeitet, dass sie in einem vereinheitlichten System vorliegen. Die sogenannten Extraktions-, Transformations- und Lade-Prozesse dienen zum automatisierten und zeitgesteuerten Laden der Unternehmensdaten in das Data Warehouse¹⁵⁵. Im Extraktions-Prozess „werden die relevanten Datenformate und -strukturen der Quellsysteme identifiziert und in einem Arbeitsbereich des Data Warehouse Systems als Extrakt abgelegt“¹⁵⁶.

151 Vgl. Behme, 1996, S. 31.

152 Inmon, 1996, S. 33.

153 Vgl. hierzu: Kaufmann/Meier, 2016, S. 200 f.; Schaffranietz/Neumann, 2009, S. 164; Schön, 2016, S. 233-235.

154 Diese basieren im Falle eines Data Warehouse üblicherweise auf relationalen Datenbankmodellen. Vgl. Mazumder, 2016, S. 85.

155 Vgl. Müller, 2016, S. 141.

156 Schön, 2016, S. 242.

Im anschließenden Transformationsprozess erfolgt die Integration der Daten aus den unterschiedlichen Quellsystemen ins Data Warehouse System. Die Extrakte im Arbeitsbereich werden hinsichtlich ihrer Datenstruktur und ihrer Datenformate so gefiltert, eliminiert, harmonisiert, ergänzt und angereichert, dass sie den Zielvorgaben (Struktur und Format) der Datenbank im Data Warehouse System entsprechen. Im dritten und letzten Schritt werden die Daten ins Data Warehouse übertragen und gespeichert¹⁵⁷.

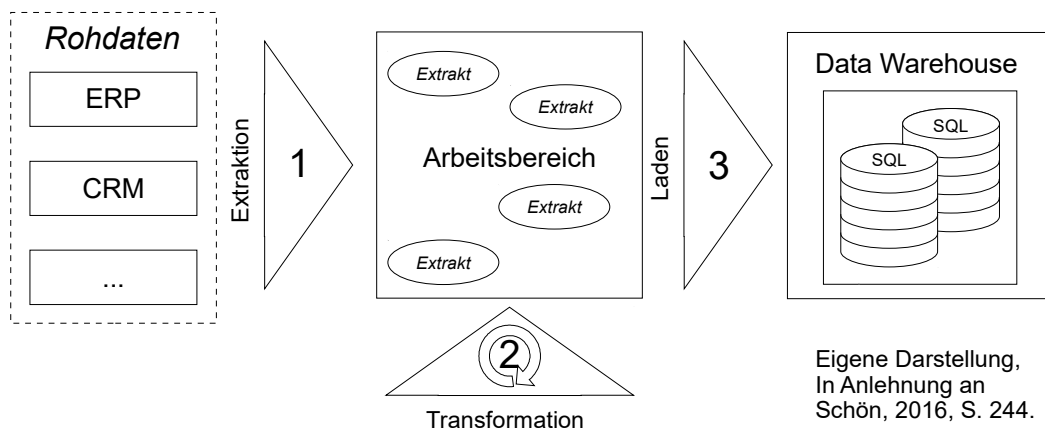


Abbildung 4: ETL-Prozess

(3) Der Aspekt *Nicht-Volatilität* thematisiert die Langlebigkeit der gespeicherten Daten. Die im Data Warehouse gelagerten Daten werden über die typische Nutzungszeit von operativen Daten hinaus gespeichert und können somit länger für Controlling Zwecke verwendet werden. Aufgrund der größeren Menge und Änderungsrate der operativen Quelldaten werden diese früher archiviert als die komprimiert vorliegenden Daten im Data Warehouse.

(4) Die Daten im Data Warehouse besitzen einen zeitlichen Bezug (*Zeitvarianz*), das heißt, dass ihnen eine Historie zur Grunde liegt, die eine Zeitrumbetrachtung der vergangenen Unternehmensentwicklung ermöglicht und Grundlagen für zukünftige Prognosen schafft. Mittels Data Mining¹⁵⁸ und seinen Werkzeugen (Klassifikation, Clusterung, Assoziationen etc.¹⁵⁹) lassen sich aus den Daten Kunden- und Kaufverhalten analysieren¹⁶⁰.

157 Vgl. Schön, 2016, S. 242 f.

158 Siehe 3.3.7.3: Data Analytics, Data Mining, KDD.

159 Vgl. Beierle/Kern-Isberner, S. 146 ff.

160 Kaufmann/Meier, 2016, S. 202.

Die Zielsetzung des Data Warehouse ist der „Aufbau einer Datenbasis, welche die steuerungsrelevanten Informationen aus allen operativen Quellen eines Unternehmens integriert. Während die operativen Systeme sich auf die Unterstützung der Tätigkeiten im Tagesgeschäft konzentrieren, liegt der Fokus des Data Warehouse auf Analysen und Berichten zur Steuerung des Unternehmens“¹⁶¹ und Unterstützung der Managemententscheidungen¹⁶². Neben der besseren Entscheidungsfindung, durch eine größere und qualitativ höherwertigen Datenmenge sowohl aktueller als auch historischer Daten, wird in Summe ebenfalls eine Zeitersparnis erzielt: der Einsatz eines Data Warehouse automatisiert die Auswahl, Filterung und Bereitstellung von Daten und Analysen. Der Zugriff auf die Daten für Auswertungen muss durch die Automatisierung nicht mehr manuell erfolgen, was den gesamten Datenbeschaffungsprozess vereinfacht und vom IT-Personal unabhängig macht¹⁶³.

161Müller, 2016, S. 141.

162 Siehe Fußnote 152.

163 Vgl. Müller, 2016, S. 142; Tiemeyer, 2016, S. 338.

3.3.7.3 Data Analytics, Data Mining, KDD

„The data available are often unstructured - not organized in a database - and unwieldy, but there's a huge amount of signal in the noise, simply waiting to be released“¹⁶⁴.

Damit aus den gesammelten Daten Informationen und Wissen wird, müssen selbige nutzbringend analysiert und ausgewertet werden. Im Rahmen dieser Arbeit wird „Data Analytics“¹⁶⁵ als Sammelbegriff für ebensolche Analysen und Auswertungen verwendet; das heißt unter Data Analytics ist die Gesamtheit des Data Minings, in Anwendung auf Big Data, namentlich descriptive analytics, predictive analytics und prescriptive analytics, zu verstehen¹⁶⁶. In der Literatur ist neben dem Begriff Data Mining oftmals auch Knowledge Discovery in Databases (KDD) zu finden: Im deutschen Raum erfolgt eine synonyme Verwendung beider Begriffe, die englische Literatur sieht jedoch eine strikte Trennung zwischen Data Mining und KDD¹⁶⁷. Nach englischem Verständnis ist KDD „das systematische Entdecken und Extrahieren unbekannter, nicht trivialer und wichtiger Informationen aus großen Datenmengen“¹⁶⁸, also übergeordnet zu verstehen und das Data Mining, dem KDD untergeordnet, als „Teilprozess [...], der zur Anwendung von (statistischen) Methoden und dem Auffinden von interessanten Mustern und Beziehungen dient“¹⁶⁹. Im weiteren Verlauf wird dem deutschen Verständnis entsprochen und keine explizite Trennung zwischen KDD und Data Mining vorgenommen, sondern als Synonyme verstanden, die ganz dem bergbaulich angehauchten Terminus vom Data Mining folgen und mit dem Schürfen nach Informationen, Wissen und unbekannter Datenmuster sowie Zusammenhängen in großen Datenansammlungen übersetzt werden können¹⁷⁰. Dabei erfolgt im Rahmen des Suchprozesses, also des eigentlichen Data Minings, ein

164 McAfee/Brynjolfsson, 2012, S.63.

165 Die Begriffsfestlegung erfolgte in Anlehnung an Schön, 2016, S. 312 f.

166 Vgl. Delen/Demirkan, 2013, S. 361.

Die Erläuterung der einzelnen Analytics Verfahren erfolgt weiter unten.

167 Vgl. Fayyad, 1996, S. 24 f., Schaffranietz/Neumann, 2009, S. 159; Siehe auch Beierle/Kern-Isberner, 2014, S. 143.

168 Schaffranietz/Neumann, 2009, S. 159.

169 Ebenda.

170 Vgl. Müller, 2016, S. 142; Meier/Kaufmann, 2016, S. 242; Schön, 2016, S. 268.

interdisziplinärer Einbezug von Themengebieten der Informatik und Mathematik, unter anderem durch die Verwendung des maschinellen Lernens und der Statistik¹⁷¹. Anwendung finden diese Themengebiete vorrangig bei predictive und prescriptive analytics: Die descriptive analytics benutzt hingegen Daten zu Beantwortung der Fragen „Was passierte?“ oder „Was passiert aktuell?“. Diese Analyse ermöglicht somit einen Blick in die Vergangenheit und auf den Status Quo mit dem Ergebnis der Identifizierung von Möglichkeiten und Problemen durch das Aufdecken von Datenmustern und -strukturen¹⁷². predictive analytics verwendet, neben den Daten, Methoden aus dem Themengebiet der Mathematik zur Identifizierung von Trends, Verbindungen und Ähnlichkeiten, die zwischen den Daten bestehen. Dadurch können die Fragen „Was wird passieren?“ und „Warum wird es passieren?“ beantwortet werden. Mit predictive analytics wird ein Blick in die Zukunft mit der genauen Darstellung/Prognose zukünftiger Szenarien/Ereignisse ermöglicht und der Erklärung des Warum¹⁷³.

„If data can be collected in real-time from more locations, it is possible that automated prediction could contribute to advancing total preventative maintenance from the reduction of break-downs to the improvement of overall operational performance“¹⁷⁴.

Ein gutes Anwendungsbeispiel für predictive analytics ist predictive maintenance, basierend auf Big Data. Auf Basis von Sensor- und Kontext-Daten (beispielsweise Umgebungs- und Wetterdaten, sowie der Art der Anlagennutzung¹⁷⁵) können Abweichungen vom Standardwartungszyklus ermittelt werden. Konkret bedeutet dies: Bei Anlagen, deren Sensor-Daten ein intaktes und gut funktionierendes System zeigen, verlängern sich die Wartungsintervalle und reduzieren so die Wartungskosten. Im anderen Fall können die ermittelten Daten schon frühzeitig¹⁷⁶ auf Probleme in der Anlage hinweisen. Ein dadurch ausge-

171 Vgl. Beierle/Kern-Isberner, 2014, S. 144; Chen/Zhang, 2014, S. 322; Ester/Sander, 2000, S. 1.

Eine Auflistung von Methoden, die im Rahmen des Data Minings Anwendung finden, lässt sich unter anderem in Schön, 2016, S. 270 f. finden.

172 Vgl. Delen/Demirkan, 2013, S. 361; Schön, 2016, S. 269.

173 Ebenda.

174 Do/Fox, 2013, S. 747; Vgl. Kumar Sharma/Kumar/Kumar, 2006, S. 256-280.

175 Entnommen beispielsweise aus dem ERP-System.

176 Das heißt vor der geplanten Wartung.

löster Wartungseinsatz kann größere Schäden, Reparaturen, Ausfallzeiten und dadurch entstehende Kosten reduzieren oder verhindern. Die Grundannahme, die dem Ganzen dabei zur Grunde liegt, besteht darin, dass die Zeit bis zum Ausfall der Maschine, mit einer ausreichend hohen Anzahl an Sensorinformationen einer spezifischen Maschine und Datenbank von Sensor- und Ausfalldaten dieser Maschine oder dem Maschinentyp, genauer vorhergesagt werden kann¹⁷⁷.




Abbildung 5: Data Analytics

„Using big data leads to better predictions, and better predictions yield better decisions“¹⁷⁸.

Die dritte und letzte Untergruppe der Data Analytics sind die prescriptive analytics: Sie benutzen Daten und mathematische Algorithmen zur Bestimmung alternativer Handlungsoptionen und Entscheidungen, auf deren Basis optimierte Entscheidungen und Maßnahmen abgeleitet werden, die zur Verbesserung der Geschäftsentwicklung beitragen. Als Ergebnis stehen letztendlich die bestmögliche Vorgehensweise für eine vorgegebene Situation oder eine Fülle an Informationen und Wissen zur Verfügung, die zu bestmöglichen Entscheidungen oder

177Vgl. Cavanillas/Curry/Wahlster, 2016, S. 145, 150, 164.

178 McAfee/Brynjolfson, 2012, S. 64.

Handlungen führen können. Mit prescriptive analytics werden die Fragen „Was soll ich tun?“, „Warum soll ich es machen?“ und „Wie können wir das Wissen bestmöglich in Anwendungen umsetzen?“ beantwortet¹⁷⁹.

Neben den oben thematisierten Teilgebieten, lassen sich zudem, in Abhängigkeit des jeweils betrachteten Datentyps, noch das Text Mining (Textdokumente), Multimedia Mining (Audio-, Video- und Bilddateien) und Web Mining (Webinhalte) unterscheiden¹⁸⁰.

179 Vgl. Delen/Demirkan, 2013, S. 361; Schön, 2016, S. 269.

180 Vgl. Furht/Villanustre, 2016, S. 7 f.; Schön, 2016, S. 268.

3.3.7.4 Internet of things

Das Internet der Dinge wird in Zukunft zur Hauptgrundlage von Data Analytics¹⁸¹ und bietet Möglichkeiten zur automatischen Überprüfung von Entscheidungsprozessen durch die von ihnen zur Verfügung gestellten Daten und deren Analyse bei predictive und eventuell prescriptive analytics¹⁸². Das Grundkonzept ist die vernetzte Integration und zielgerichtete Zusammenarbeit von Sensoren, zur Messung ihrer Umgebung, Aktoren, die aktiv ihre Umgebung beeinflussen, und weiteren technischen Komponenten in die Umwelt¹⁸³. Neue und zusätzlich adressierbare Systeme und Komponenten ermöglichen auch neue Big Data Einsatzszenarien zur Unterstützung von Geschäftsentscheidungen, da Daten vom Kern der Wertschöpfungsprozesse zur Verfügung stehen¹⁸⁴. Der Einsatz von IoT ermöglicht dadurch die Beobachtung, Überwachung, Umgestaltung und Verbesserung der gesamten Wertschöpfungskette. Durch die Bidirektionalität der eingesetzten Geräte (sowohl Sensoren als auch Aktoren) können nicht nur Informationen geteilt, sondern auch neue bzw. andere Anweisungen oder Einstellungen, zur Modifizierung der Anlage, übermittelt werden¹⁸⁵. Auf der anderen Seite wird durch den Einsatz von IoT jedoch auch eine neue Abhängigkeit, genau von ebendieser Technologie, ihrer Hardware, Entwicklungen und Einschränkungen, geschaffen. Vorteile lassen sich nur solange erzielen, wie die Systeme ordnungsgemäß funktionieren und aktuell sind¹⁸⁶.

Gerade im Hinblick auf das Potential von Big Data für die Immobilienbranche kann in dem Internet der Dinge, und dem dadurch profitierenden predictive maintenance, ein großer Treiber gesehen werden. Neben der technischen Sichtweise in Punkto Wartung und Instandsetzung können auch andere Service-Leistungen im FM von Sensoren profitieren: Vorstellbar wären Sensoren, die die Fluktuation von Mitarbeitern oder Kunden in großen Einkaufszentren

181 Vgl. Rafferty/Rafferty/Hung, 2016, S.5; Morabito, 2015, S. 27 f.

182 Vgl. Cavanillas/Curry/Wahlster, 2016, S. 145; Siehe hierzu auch den Exkurs predictive maintenance unter 3.3.7.3:Data Analytics, Data Mining, KDD.

183 Vgl. Cavanillas/Curry/Wahlster, 2016, S. 145+156;
Vargas-Solar/Espinosa-Oviedo/Zechinelli-Martini, 2016, S. 9;
Rafferty/Rafferty/Hung, 2016, S. 5; Morabito, 2015, S. 27 f.

184 Vgl. Cavanillas/Curry/Wahlster, 2016, S. 156.

185 Vgl. Cordon et al., 2016, S. 76.

186 Vgl. Cavanillas/Curry/Wahlster, 2016, S. 156.

messen und, in Abhängigkeit dieser, werden die Reinigungsintervalle für bestimmte Bereiche automatisch angepasst¹⁸⁷ oder Bürobelegungen automatisch buchen. Nicht genutzte Räume werden durch das Gebäude automatisch in den Leerstand gefahren. Konkret können mit dem Internet der Dinge Daten generiert werden, die für den Einsatz von Big Data benötigt würden.

„With the advent of big data, hyperconnectivity allows each party within the chain to connect more dynamically with the others, pushing aside rigid models and moving toward a more complex value chain that functions as an ecosystem. In an ecosystem, companies are connected to one another. They occupy a common space in which they can compete and cooperate at the same time. As a result of this permanent contact, their relationships evolve constantly, turning the value chain into a dynamic environment“¹⁸⁸.

In enger Kombination mit der Gebäudeautomation ließen sich so intelligente und selbststeuernde Immobilien schaffen¹⁸⁹, die über Unternehmen und Wertschöpfungsketten hinweg, als in sich geschlossene Ökosysteme, agieren¹⁹⁰.

187 Siehe hierzu 3.4:Beispiele aus der Praxis – Immobilien im Einfluss von Big Data.

188 Cordon et al., 2016, S. 66; Vgl. dazu auch Fox/Do, 2013, S. 739 f.

189 Siehe hierzu auch: <http://www.intel.com/content/www/us/en/smart-buildings/overview.html>

190 Vgl. Morabito, 2015, S. 11.

3.4 Beispiele aus der Praxis – Immobilien im Einfluss von Big Data

Dieses Kapitel widmet sich unterschiedlichen Anwendungsbeispielen im Immobilienkontext, die die zahlreichen Möglichkeiten durch eine aktive Verwendung von Daten aufzeigen. Die folgenden Beispiele beinhalten praktische Studien und konkrete Anwendungsfälle mit einem direkten Immobilienbezug.

Die Vorhersage von Immobilienpreisen und deren Entwicklung war schon öfters im Fokus von wissenschaftlichen Forschungen¹⁹¹. Das nachfolgende Anwendungsbeispiels versucht selbiges, jedoch mit einem etwas anderen Ansatz: Sun et al. kombiniert das Verhalten von Online-Nutzern mit aktuellen Meinungen aus Online-Nachrichten und Abfragedaten für die Vorhersage von Immobilienpreisen in China. Das Verhalten der Nutzer wird dabei aus der Untersuchung von Suchmaschinen-Abfragedaten abgeleitet, die hinsichtlich der Häufigkeit von gesuchten Wörtern von Online-Nutzern analysiert wurden. Bis dato sind beide Ansätze nur separat von einander und nicht in kombinierter Form zur Anwendung gekommen¹⁹². Suns Methode übertraf in drei von vier Fällen die Vorhersagen nicht-kombinierter Modelle¹⁹³. Ein möglichen Erklärungsgrund wird in der Hinzunahme einer weiteren Quelle gesucht, was ihrem Modell einen Vorteil gegenüber den Vergleichsmodellen schafft¹⁹⁴. Eine höhere Anzahl an unterschiedlichen Datenquellen kann somit zu besseren Ergebnissen führen.

Einen ganz anderen Bereich beleuchteten Uotila und Skogster in ihrer Arbeit: Sie ermittelten über W-LAN Triangulation die Wegen von Kunden in einem großen DIY-Store und kombinierten diese Daten mit einem Geoinformationssystem. Dadurch war es ihnen möglich ein detailliertes Bild der Kundenbewegungen innerhalb des Geschäftes abzubilden und es hinsichtlich der Flächennutzung zu analysieren¹⁹⁵. Die von Uotila und Skogster angesprochenen Probleme bei der Datensammlung (Hawthorne-Effekt und subjektive Beeinflussung durch den Datensammler¹⁹⁶) sind mit der heutigen verwendbaren Technik nicht mehr vorhanden. Beispielsweise bietet das Unternehmen Cisco Meraki sogenannte

191 Vgl. Sun et al., 2014, S. 21.

192 Vgl. Sun et al., 2014, S. 19-23.

193 Vgl. Sun et al., 2014, S. 30-32.

194 Vgl. Sun et al., 2014, S. 33.

195 Vgl. Uotila/Skogster, 2007, S. 367-371.

196 Vgl. Uotila/Skogster, 2007, S. 372.

Location Analytics an: Diese funktionieren genauso wie im hier dargestellten Beispiel über Triangulation, mit dem Unterschied, dass heute jeder freiwillig ein, über W-LAN verfolgbares, Gerät mit sich führt: das Smartphone. Sofern die W-LAN Schnittstelle des Smartphones aktiviert ist, kann über Cisco Merakis Software der Weg jedes Geräts und damit Kunden in einem Laden, ohne dessen Kenntnis¹⁹⁷, aufgezeichnet und nachverfolgt werden¹⁹⁸. Da kein separater Tracker mitgeführt werden muss sind die Probanden in Unkenntnis und der Hawthorne-Effekt kann vernachlässigt werden. Die Datenermittlung erfolgt komplett automatisch, sodass auch die subjektive Beeinflussung durch den Menschen entfällt¹⁹⁹. Die Methode kann somit nicht nur für die Verbesserung des Flächenmanagements genutzt werden, wie es Uotila und Skogster anstrebten, sondern ebenfalls zur einfachen Ermittlung von beispielsweise Kundenfluktuationen in Kaufhäusern oder Bewegungen in Büroimmobilien in Verbindung mit einer davon abhängigen Steuerung der infrastrukturellen Gebäudemanagement-Servicelösungen²⁰⁰.

Erste Anfänge zur Entscheidungsautomatisierung, basierend auf Daten, im FM sind im Building Information Modelling (BIM)-Kontext zu finden: Beispielsweise entwickelten Golabchi/Akula/Kamat in ihrem 2016 veröffentlichten Beitrag „Automated building information modeling for fault detection and diagnostics in commercial HVAC systems“ in Facilities, Vol. 34 Iss 3/4 Seiten 233-246, ein BIM Plug-In zur automatisierten Erkennung von potentiell beschädigten Heizungs-, Lüftungs- und Klimageräten auf Grundlage von Nutzerberichten, Wetter- und Temperaturdaten sowie Geräteinformationen²⁰¹. Das Plug-In nutzt dazu einen Fehlererkennungs- und Diagnose-Algorithmus (fault detection and diagnostics, FDD). Teil des Fehlererkennungsprozesses ist die Verwendung von Beschwerdeberichten der Nutzer aus der Ticketdatenbank. Anhand dieser erstellt das FDD-Tool automatisch eine Fehlerdiagnose, die die wahrscheinlichste

197 Ungeachtet jeder datenschutzrechtlichen Vorschrift.

198 Siehe: <https://meraki.cisco.com/solutions/location-analytics>

199 An dieser Stelle ist wiederum der Aspekt der Selbstselektion zu beachten. Es gibt Kunden, die das W-LAN in ihrem Gerät immer ausgeschaltet haben, aber auch andere, die es immer eingeschaltet haben.

200 Wie beispielsweise die Reinigung.

201 Vgl. Golabchi/Akula/Kamat, 2016, S. 233.

Ursache für die Fehlfunktion des Systems enthält, und einen Aktionsplan für den Dienstleister. Mit ihm soll er die defekte Komponente zeitsparend, ohne eine aufwändige manuelle Fehlersuche, identifizieren.

Was bereits heute mit Bestandsimmobilien alles möglich ist, zeigt Microsoft mit seinem Hauptcampus in Redmond: Die Situation in der sich Microsoft vor einigen Jahren sah, ist typisch für historisch stark gewachsene Unternehmen: Ein schnelles Unternehmenswachstum und die damit stark ansteigende Mitarbeiterzahl macht eine schnelle Flächenbeschaffung notwendig. So ist bei Microsoft der Immobilienbestand von zu Beginn 4 Gebäuden (1986) auf nun mehr 125 Gebäude, mit über 1,4 Mio. Quadratmeter Fläche, angewachsen (Stand 2013). Dies entspricht einem Anstieg von ca. 4,5 Gebäuden pro Jahr. Die über die Jahre gebauten, gekauften oder angemieteten Immobilien besitzen unterschiedliche Ausstattungen, Qualitäten, technische Standards²⁰² und Eigentumsverhältnisse.

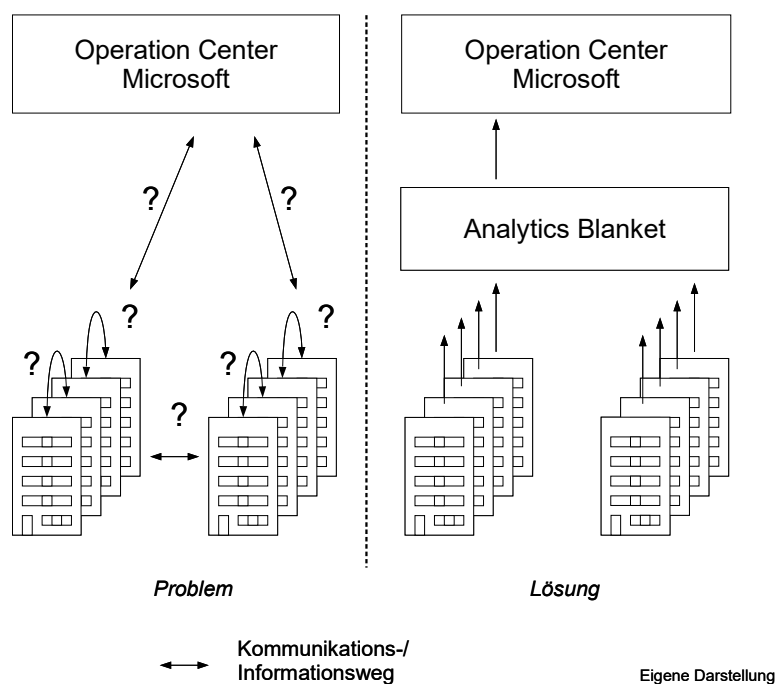


Abbildung 6: Fallbeispiel Microsoft: Problemdarstellung und Lösung

202 Hinsichtlich der verbauten Gebäudeautomationsysteme, Kommunikationstechniken etc.

Diese heterogene Immobilienstruktur machte es für Microsoft sehr problematisch das Immobilienportfolio als Gesamtes zu managen. Eine Veränderung sollte stattfinden, mit dem Ziel das damalige reaktive FM durch ein proaktives, teils automatisiertes zu ersetzen. Damit proaktiv gehandelt werden konnte, waren jedoch Informationen notwendig, auf deren Basis die zutreffenden Entscheidungen beruhen. Da die Vielzahl an Immobilien auch unterschiedliche IT-Systeme innerhalb des Gebäudes mit sich bringen, war es Microsoft unmöglich die Informationen aller 125 Gebäude gemeinsam abzurufen und zu nutzen, geschweige sie hinsichtlich ihrer Performance zu bewerten und vergleichen. Die Systeme konnten weder untereinander noch mit dem zentralen Operation Center von Microsoft kommunizieren um Informationen auszutauschen. Microsofts Lösung des Problems bestand darin eine Kommunikationsschnittstelle zu schaffen²⁰³. So entstand eine Schicht auf Basis von FDD-Algorithmen, zwischen den einzelnen Immobilien und dem Operation Center von Microsoft. Dieser ermöglicht zwar nicht den Kommunikationsweg unter den einzelnen Immobilien, schafft dafür aber eine zentrale Plattform in der alle Informationen aus den Immobilien auflaufen und ans Operation Center weitergegeben und dort genutzt werden können. Durch die zentrale, digitale Steuerung und Überwachung wurden große zeitliche Einsparungen im operativen Betrieb erreicht. Das Reporting ist hinsichtlich der Qualität und des Zeitaufwandes verbessert, Berichte können nun nahezu in Echtzeit erstellt werden. Der Einsatz von FDD ermöglicht die gewünschte proaktive Verwaltung aller Microsoft Immobilien am Campus: Die sofortige Ausgabe von Fehlermeldungen der Gebäudeautomation (GA) und Gebäudeleittechnik (GLT) gibt einen immer aktuellen Überblick über die Immobilien inklusive durchzuführender Arbeiten und den damit verbundenen Kosten. So können Reparaturen eingeleitet werden, schon bevor ein Problem gemeldet wird²⁰⁴.

203 In Abbildung 6: Fallbeispiel Microsoft: Problemdarstellung und Lösung als „Analytics Blanket“ dargestellt.

204 Vgl. Laughman, 2013.

3.5 Erkenntnisse der explorativen Vorstudie

Big Data ist ein Themengebiet das unterschiedliche Disziplinen miteinander vereint und verschiedenste Anwendungsszenarien bietet. Neben mehreren Definitionsansätzen haben sich vor allem die drei bis fünf Big Data Vs Volume, Variety, Velocity, Veracity und Value zur Charakterisierung herauskristallisiert. Anhand von diesen ist ebenfalls eine erste Abschätzung über die Anwendbarkeit von Big Data in einem bestimmten Kontext möglich. Das verfolgte Ziel ist die vom Computer eigenständige Erkennung und Interpretation von Dateninhalten, welche „übergreifende Erkenntnisse aus unterschiedlichen Quellen und Formaten“ liefert²⁰⁵. „Dabei geht Big Data über Data-Warehousing und BI-Konzepte hinaus“²⁰⁶. Das detaillierte rechtliche Gefüge für eine solche Anwendung wird in Deutschland gerade erst geschaffen. Zu beachten gilt es, dass der Schutz der persönlichen Daten eines Jeden in jedem Falle gewahrt bleibt. Gerade die genannten Anwendungsbeispiele zeigen, dass das Thema auf internationaler Ebene weiter vorangeschritten ist als in Deutschland. Diese Tatsache ist jedoch weniger als Nachteil zu betrachten, sondern vielmehr als Möglichkeit bereits vorhandene und funktionierende Konzepte und Regelungen aufzugreifen und zu verbessern. Der Einsatz von Big Data bietet viele mögliche Potentiale, aber auch Herausforderungen und Barrieren. Zu einer der großen zu nehmenden Hürden zählt das notwendige IT-Know-How. Werden diese aber gemeistert, sind denkbar viele Vorteile und Anwendungsfälle vorhanden. Inwiefern die Immobilienbranche für den Big Data Einsatz geeignet ist und folglich von Vorteilen partizipieren kann, wird im nachfolgenden Kapitel geklärt.

205 Dorschel, 2015, S. 8.

206 Ebenda.

4 Big Data im Immobilien-Kontext

Zur Klärung der, unter 3.5 angeführten, Fragestellung wird auf, die in Abschnitt 3.3.2: Big Data und die Vs angesprochene und von Schön aufgestellte, folgende These zurückgegriffen:

*Big-Data-Lösungen sind dann für Unternehmen und Einrichtungen interessant, wenn die vier Big Data Kriterien Volume, Variety, Velocity und Veracity auf die zu nutzenden Daten zutreffen.*²⁰⁷

Damit die Erfüllung der Kriterien überprüft werden kann, sind zunächst die zu nutzenden Daten zu identifizieren. Die Identifikation von nutzbaren Daten erfolgt zum Einen anhand der eingesetzten Systeme in den klassischen Unternehmensabteilungen, die sich aus Porters Wertschöpfungskette²⁰⁸ ergeben, und zum Anderen anhand der, für die Immobilien- und FM-Branche typischen, Software und Informationstechniken, immer vor dem Hintergrund der Verwendbarkeit der Daten im hier betrachteten Kontext. Auf eine scharfe Perspektiventrennung zwischen CREM, auf Seite des Auftraggebers, und FM-Dienstleister, auf Seite des Auftragnehmers, wird an dieser Stelle bewusst verzichtet: Der Einfachheit halber besteht zwischen dem Dienstleister und seinem Auftraggeber eine Symbiose, d.h. beide Parteien teilen jegliche Informationen²⁰⁹ miteinander. Darüber hinaus ergeben sich im Bereich der unterstützenden Prozesse (Personalwirtschaft, Beschaffung, ...) zahlreiche Dopplungen zwischen Corporate und Dienstleister, die nicht in zweierlei Weise ausgeführt werden sollen. Im Falle einer Dopplung erfolgt die Perspektivendarstellung direkt beim behandelten System. Die nachfolgende Darstellung²¹⁰ der Systeme beginnt mit denen der klassischen Unternehmensabteilungen und widmet sich im Anschluss der immobilien-spezifischen Software und Technik.

207 Vgl. Schön, 2016, S. 304.

Kriterium fünf (Value) wird an dieser Stelle außen vor gelassen, da Schön seine Kriterien auf die vier genannten beschränkt.

208 Porter, 2010, S. 66. Für die Darstellung siehe Anhang 2.

209 Erfahrungswerte etc.

210 Die Auflistung ist nicht als endgültig zu betrachten, je nach Unternehmenszweck lassen sich weitere Systeme hinzufügen oder entfernen.

Im Bereich der klassischen IT-Systeme lässt sich das ERP-System als zentrales System identifizieren, welches nahezu in jedem Bereich der primären und unterstützenden Aktivitäten zum Einsatz kommen kann: „Ein Enterprise-Resource-Planning-System [...] dient der funktionsbereichsübergreifenden Unterstützung sämtlicher in einem Unternehmen ablaufenden Geschäftsprozesse. Entsprechend enthält es Module für die Bereiche Beschaffung/Materialwirtschaft, Produktion, Vertrieb, Forschung und Entwicklung, Anlagenwirtschaft, Personalwesen, Finanz- und Rechnungswesen, Controlling usw., die über eine (in Form einer relationalen Datenbank realisierte) gemeinsame Datenbasis miteinander verbunden sind“²¹¹. Für den Corporate kann beispielsweise aus dem Finanz- und Rechnungswesen die Instandhaltungshistorie seiner Immobilie und technischen Gebäudeausrüstung (TGA) sowie den damit verbundenen Kosten, aus den getätigten Zahlungen, ableiten werden. Die Daten aus der Anlagenwirtschaft und dem Personalwesen liefern wichtige Informationen über die Nutzungsart und -intensität der Anlagen. Das ERP-System des Dienstleisters ermöglicht Einblicke in seine Personalplanung und -steuerung, die in den Kontext der Immobilienbewirtschaftung auf Corporate-Seite gesetzt werden können um mögliche Parallelen zwischen vergangenen Ereignissen (Maschinenausfällen o.ä.) zu identifizieren und für die Zukunft vorherzusagen. Aus einem ERP-System lassen sich somit zahlreiche unternehmensbezogene Daten, sowohl im Fall des Corporates als auch Dienstleisters, für den Big Data Einsatz nutzen.

In den Unternehmensbereichen Marketing, Vertrieb und Kundendienst kommen sogenannte Customer Relationship-Management-Systeme (CRM) zum Einsatz: „CRM-Systeme liefern [...] die technologische Unterstützung, um die anfallenden Aufgaben in Marketing, Vertrieb und Kundenservice schneller und besser zu bewältigen. Sie dienen dazu, Informationen über Kunden effizienter in der Unternehmensorganisation zu verteilen und sie im Rahmen der Bearbeitung der Kundenbeziehungen effektiver zu nutzen“²¹². Ein CRM-System steuert kundenbezogene Daten zur Big Data Analyse hinzu, die bei der Verbesserung der kundenbezogenen Prozesse helfen sollen. Da in der betrachteten Kunden-Lieferanten-Beziehung der Corporate Kunde des Dienstleisters ist, werden diese Daten

211 Gabler Wirtschaftslexikon, o.J., Stichwort: Enterprise-Resource-Planning-System.

212 Helmke/Uebel/Dangelmaier, 2017, S. 7.

ausschließlich auf Dienstleister-Seite von Nutzen sein, um eben hier Verbesserungen in den Kundenbeziehungen zu erreichen. Die Kunden-Lieferanten-Beziehung des Corporates ist in diesem Szenario gänzlich unabhängig vom Dienstleister, weshalb die CRM-Daten des Corporates keinerlei Mehrwert generieren würden und in der Betrachtung außen vor bleiben.

Aus dem Bereich der Unternehmensinfrastruktur sind vor allem Dokumenten-Management-Systeme (DMS) zu betrachten: „Unter Dokumenten-Management-Systemen werden IT-Systeme zur strukturierten Erzeugung, Ablage, Verwaltung und Wiederverwendung von elektronischen Dokumenten verstanden“²¹³. DMS stehen auf Seiten des Corporates in einer engen Verbindung zur CAD- und CAFM-Software. Zum einem besteht die Möglichkeit sie als Archivierungswerkzeug für CAD-Dateien zu nutzen²¹⁴ und zum anderen kann mittels Anbindung des DMS ans CAFM-System über letzteres die Verwaltung der Betriebs- und Bestandsdokumentation erfolgen²¹⁵. Darüber hinaus ermöglicht ein DMS den Zugriff auf vorhandene Verträge, Normen, Richtlinien, Verordnungen und weiteren relevanter Dateien²¹⁶, die beim Corporate und Dienstleister vorliegen.

Im Bereich der immobilienpezifischen IT-Systeme wird im nachfolgenden zwischen der eingesetzten Software und der einbaubaren Technik unterschieden. Im Software-Bereich sind zwei relevante Anwendungen zu nennen: (1) die Computer-Aided-Design-Software (CAD-Software) und (2) die Computer-Aided-Facility-Management-Software (CAFM-Software).

CAD-Anwendungen dienen zum rechnerunterstützten Konstruieren von Produkten oder Gebäuden und liefern beispielsweise Grundrisse, TGA-Pläne und/oder 3D-Modelle²¹⁷, die im Falle der Fertigstellung eines Gebäudes an den Bauherrn zu übergeben sind²¹⁸ und somit beim Corporate liegen.

„CAFM-Software ist eine Anwendungssoftware, die Facility Prozesse im gesamten Lebenszyklus von Facilities umfänglich unterstützt. Die Verarbeitung grafischer und alphanumerischer Daten wird dabei ebenso als unverzichtbares

213 Bodendorf, 2006, S. 108.

214 Vgl. Schauer et al, 2013, S. 293.

215 Vgl. Opic et al, 2013, S. 47. Siehe dazu auch Koch/May/Schauer, 2013.

216 Textdokumente, Tabellenkalkulationen, Grafiken, E-Mails etc.

217 Vgl. Vajna et al, 2009, S. 11+17.

218 Vgl. GEFMA 190, 2004, S. 24 f. .

Merkmal verstanden wie die systematische Steuerung im Sinne eines Workflow Managements. CAFM ist also die Umsetzung und Unterstützung des Facility-Management-Konzepts mit Hilfe moderner Informations- und Kommunikationstechnik über den gesamten Lebenszyklus von Facilities hinweg²¹⁹. Das Gerüst der CAFM-Software bildet die Bestandsdokumentation. Diese umfasst sämtliche Informationen bezüglich Grundstücken, Gebäuden, Anlagen, Ausrüstungen und Ausstattungen sowie den damit verbundenen FM-Serviceleistungen des Corporates²²⁰. Neben der Bestandsdokumentation wird ein CAFM-System zum Aufbau und zur Pflege der Betriebsdokumentation verwendet²²¹. Diese beinhaltet „sämtliche Unterlagen [...], die spezifische Informationen über den Betreiber und seine Organisation enthalten oder erst im Zuge des Gebäudebetriebs laufend entstehen“²²². Somit liefern CAD- und CAFM-Anwendungen wichtige Daten und Inhalte für den Big Data Einsatz.

Eine noch höhere Bedeutung sollte der in Immobilien einbaubaren Technik, in Form der Gebäudeautomation und Gebäudeleittechnik, zu kommen: „Die Gebäudeautomation ist die digitale Mess-, Steuer-, Regel- und Leittechnik für die technische Gebäudeausrüstung“²²³. „Das Verbinden mehrerer Systeme der Mess-, Steuer- und Regelungstechnik mit einem übergeordneten, zentralen System über ein Datenübertragungsnetz bezeichnet man als Gebäudeleittechnik“²²⁴. Das Hauptziel der Gebäudeautomation ist ein effizienter und energiearmer Anlagenbetrieb (Energiemanagement). Darüber hinaus dient sie auch zur „automatisierten Regelung, Steuerung und Überwachung“²²⁵ der Gewerke Heizung, Kälte, Lüftung, Licht etc. beispielsweise mittels belegungsabhängiger Anpassung der Soll-Zimmertemperatur über Anwesenheitssensoren oder automatischer Abschaltung von Heizung und Kühlung bei offenem Fenster²²⁶. Die Ge-

219 GEFMA 400, 2013, S. 1 f.

220 Vgl. Opic et al, 2013, S. 46 f.

221 Vgl. Opic et al, 2013, S. 221.

222 GEFMA 190, 2004, S. 24 f. .

223 Vgl. VDI 3814, 2005, Blatt 1 bis 5. Zitiert nach Merz/Hansemann/Hübner, 2010, S. 19.

224 Bohne, 2014, S. 559.

225 Merz/Hansemann/Hübner, 2010, S. 27.

226 Vgl. Merz/Hansemann/Hübner, 2010, S. 27 + 33 f. .

bäudeautomation und Gebäudeleittechnik liefern, in Verbindung mit dem oben thematisierten Internet der Dinge, wichtige Informationen und Daten aus der TGA, aus denen sich unter anderem Anlagenzustände ableiten lassen²²⁷.

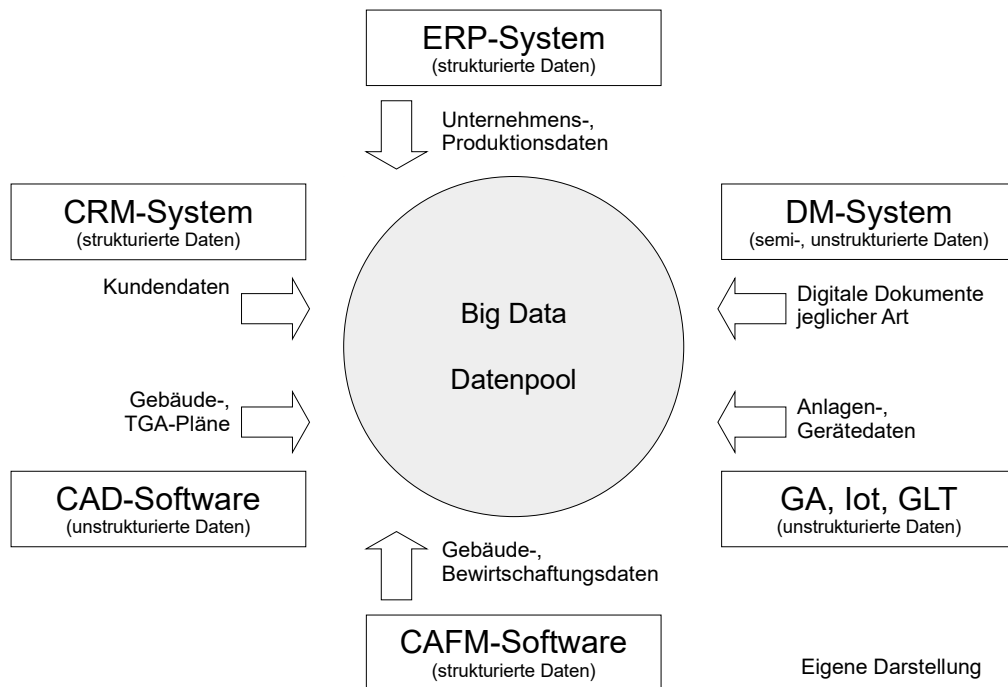


Abbildung 7: Möglicher Big Data-Datenpool im FM

Nach der Betrachtung der einzelnen Systeme ergibt sich somit ein verwendbarer Datenpool aus ERP-, CRM-, DM-, CAD- und CAFM-Daten, die um Informationen aus der Gebäudeautomation, in Verbindung mit lot, und der Gebäudeleittechnik angereichert werden. Die Datenmenge des identifizierten Datenpools skaliert mit der Anzahl an verwendeten Immobilien. Durch die Verwendung von GA-, lot- und GLT-Daten entsteht einem Portfolio ein ausreichend großer Datenbestand, da aus der GA, GLT sowie lot, ständig, teilweise sekundengenaue, Daten geliefert werden²²⁸. Das erste Kriterium Volume trifft somit auf die zu nutzenden Daten zu. Auch das zweite Kriterium Variety wird erfüllt: Der Datenpool

²²⁷ Vgl. Fußnote 174.

²²⁸ Als Berechnungsgrundlage soll das Beispiel von Microsoft aus 3.4 dienen: Unter der Annahme das 70% der Gesamtfläche von 1,4 Mio. m² als Nutzfläche zur Verfügung steht (Verhältnis BGF/NGF aus BKI 2015, S. 100) und ein Büro durchschnittlich 30 m² groß ist, ergibt sich eine Raumanzahl von ca. 33.000. Berechnungsannahmen für das Datenaufkommen: 4 Sensoren pro Raum (beispielsweise Anwesenheit, Temperatur, Luftfeuchtigkeit, Luftwechselrate), Datenmenge pro Messung: 128 Bit, Anzahl an Messungen: 1x pro Minute, Betriebszeit der Immobilie: 10 Stunden über 365 Tage. Über die festgelegte Betriebsdauer in einem Jahr entstehen ca. 460 GB an Daten alleine aus der Gebäudeautomation für den Campus.

wird mit Daten aus unterschiedlichen Quellen gespeist, die sowohl in strukturierter, semi-strukturierter und unstrukturierter Form als auch in verschiedenen Dateitypen vorliegen. Die CAFM-Software setzt beispielsweise überwiegend auf relationale Datenbankensysteme²²⁹ genauso wie ERP-Systeme²³⁰ (strukturierte Daten). Die Gebäudeautomation und Iot liefern beispielsweise Sensordaten in unstrukturierter Form²³¹. Die Betrachtung von Velocity erfolgt, aufgrund der verschiedenen Interpretationsmöglichkeiten, in dreifacher Weise: Im Verständnis der Erzeugungsgeschwindigkeit neuer Daten ist das Kriterium zutreffend. Es kommen beispielsweise Daten aus ERP-Systemen zu Einsatz, die bei jeder neuen Transaktion auch neue Daten erstellen, und aus der GA, GLT sowie Iot, die ständig, teilweise sekundengenaue, Daten erzeugen. Bedingt durch die kurzen Erfassungsintervalle letzterer Daten, müssen diese ständig im Datenbestand verändert bzw. ergänzt werden, sodass Velocity, auch im Sinne von Schnelllebigkeit, zutrifft. Hinsichtlich der Verarbeitungsgeschwindigkeit gilt der Anspruch der Echtzeitverarbeitung, denn nur so können schnelle Reaktionszeiten bei potentiellen Störungen und Ausfällen eingehalten oder ein stets aktuelles Reporting erzeugt werden. Folglich trifft auch die dritte Interpretationsmöglichkeit zu. Alle erzeugten Sensordaten sind kontextbezogen zu betrachten und auch so in der Bewertung zu berücksichtigen. Daneben gilt es zu beachten, dass Gebäude- und TGA-Pläne sowie Bewirtschaftungsdaten²³² nicht immer gepflegt und auf aktuellem Stand sind. Letztendlich ist die Richtigkeit der Daten einzuschätzen, womit auch das vierte und letzte Kriterium Veracity auf die zu nutzenden Daten zutrifft. Gemäß Schöns These ist demnach ein Einsatz von Big Data in der Immobilienbranche von Interesse und möglich.

Die Herausforderungen und Potentiale des Einsatzes von Big Data hat Thomas Beyerle unter anderem in der 2015 von Catella Research veröffentlichten quantitativen Umfrage „Big Data in der Immobilienwirtschaft - Chance oder Branchenbedrohung?“ untersucht²³³. Er kam zu Ergebnissen, die im Bereich der Potentia-

229 VGL: GEFMA 400, 2013, S. 3+10.

230 Siehe Fußnote 211.

231 Siehe Abbildung 7: Möglicher Big Data-Datenpool im FM.

232 D.h. beispielsweise hinterlegte Reinigungsintervalle, Prüfintervalle, zu bewirtschaftende Flächen und Anlagen etc.

233 Abrufbar unter: http://www.catella.com/PageFiles/44061/Catella_Research_Big_Data_%202015_en.pdf?epslanguage=en.

le deckungsgleich mit den obigen branchenübergreifenden Ergebnissen sind. Die Verbesserung der Entscheidungsfindung, Risikominimierung, Anwendung von Predictive Analytics und Verbesserung der eigenen Geschäftsmodelle²³⁴ tauchen auch bei Beyerle wieder auf²³⁵. Der einzige Unterschied, bei den fünf häufigsten Nennungen, liegt im Bereich der Transparenz. Im Allgemeinen wird sich in beiden Fällen eine Verbesserung versprochen, der Betrachtungsgegenstand ist jedoch ein anderer: Im Fall der Immobilienbranche liegt nicht die Transparenz innerhalb des Unternehmens im Fokus, sondern die Schaffung eines Wettbewerbsvorteils durch die eigene, im Vergleich zur Konkurrenz bessere, Markttransparenz.

Hinsichtlich der zu meisternden Herausforderungen zeigt sich ein etwas anderes Bild²³⁶. Gemeinsam haben beide die Nennung des Datenschutzes, Probleme hinsichtlich der bestehenden IT-Struktur und die, mit dem Einsatz verbundenen, hohen Kosten. Interessanterweise ist die oben identifizierte größte Herausforderung, das fehlende Know-How, keinerlei Thema in der Immobilienbranche. Stattdessen werden Punkte wie die Verfügbarkeit der Daten²³⁷ und fehlende Standards in der Branche als zwei der Top drei Herausforderungen angesehen. Was der Leser jedoch unter „fehlende Standards“ zu verstehen hat, bleibt von den Autoren ungeklärt. Prinzipiell lassen die Ergebnisse von Beyerle die Vermutung zu, dass das Big Data Verständnis der Immobilienbranche noch nicht so weit vorangeschritten ist, wie das der Studienteilnehmer aus den branchenübergreifenden Studien. Der Begriff wird überwiegend mit „extremen Datenmengen“ verbunden²³⁸ und nur von sehr wenigen Teilnehmern²³⁹ mit Data Analytics oder selbstlernenden Systemen. Dieser Umstand könnte auch das Nicht-Vorkommen des mangelnden Know-Hows im Bereich der Herausforderungen erklären.

234 Bei Beyerle ist nicht explizit die Rede von Geschäftsmodellen, sondern von Immobilieninvestmentmodellen. Da es sich im Fall der Investmentmodelle jedoch teilweise um das Kerngeschäft der Studienteilnehmer handelt, wird es gleichbedeutend mit dem Begriff der Geschäftsmodelle verstanden.

235 Vgl. Beyerle/Müller, 2015, S. 16.

236 Vgl. Beyerle/Müller, 2015, S. 17.

237 Dies ist vermutlich im Zusammenhang mit der Datenmenge zu verstehen. D.h. die Studienteilnehmer sehen die Herausforderung nicht in der reinen Verfügbarkeit, sondern in der Menge an Daten, die sie für notwendig halten.

238 Mit 68 von 110 Nennungen, vgl. Beyerle/Müller, 2015, S. 15.

239 Mit 14 bzw. 9 von 110 Nennungen, vgl. Beyerle/Müller, 2015, S. 15.

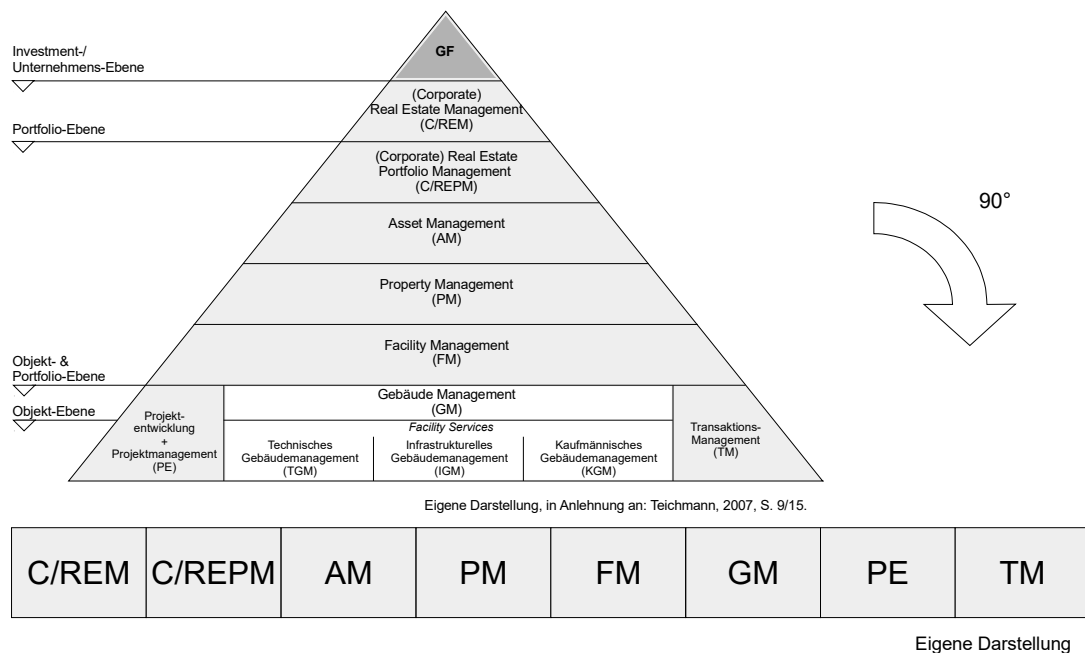


Abbildung 8: Ableitung der Einsatzszenarien in der Immobilienbranche

Nach dem Eignungsfeststellung sowie der Darstellung von Potentialen und Herausforderungen stellt sich nun die Frage nach möglichen Einsatzszenarien. Als Ausgangsbasis soll dafür die Übersicht der Managementdisziplinen im Immobilienbereich dienen²⁴⁰. Jeder, in der Pyramide dargestellte, Bereich hat für sich spezifische Anforderungen, in Abhängigkeit des jeweiligen Aufgaben- und Verantwortungsbereichs. Beispielsweise werden die Fragestellungen im FM und Gebäudemanagement (GM) eher operativer Natur sein, solche im CREM jedoch strategischer Aspekte beleuchten. Durch die Diversität der Fragestellungen stellt jede Managementdisziplin im Immobiliensektor ein separates Einsatzszenario dar²⁴¹. Jeder Sektor liefert darüber hinaus einen unterschiedlichen Wertschöpfungsbeitrag im Unternehmen. Zur Messung und Steuerung der Immobilien-Performance, d.h. des Wertschöpfungsbeitrages, dient unter anderen der Total Return²⁴². Die Bestandteile des Total Returns werden in Abbildung 9 verdeutlicht. Sowohl Änderungen im Bereich der Netto-Cash-Flow-Rendite, als auch der Wertänderungsrendite haben Auswirkungen auf den Total Return²⁴³.

240 Für eine größere Darstellung der Pyramide siehe Anhang 3.

241 Siehe Abbildung 8:Ableitung der Einsatzszenarien in der Immobilienbranche.

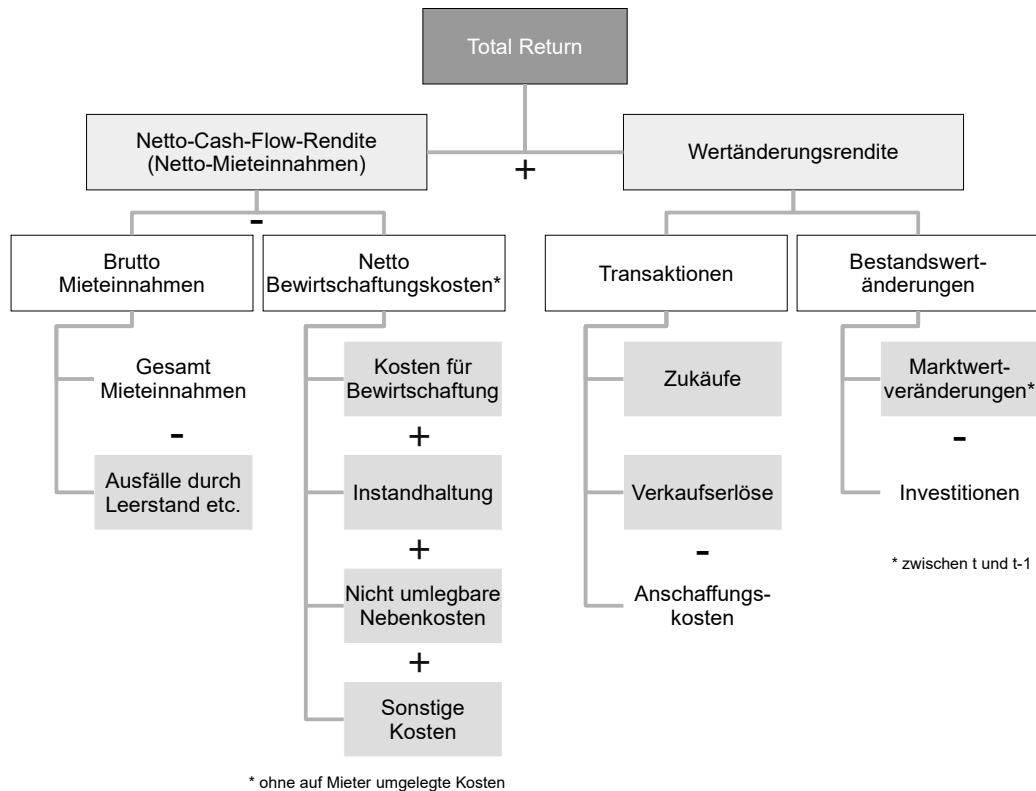
242 Vgl. Kurzrock, 2016, S. 64.

Der Total Return ist ebenfalls in aggregierter Form auf Portfolios anwendbar.

Vgl. Kurzrock, 2016, S. 51.

243 „Bezugsgröße ist jeweils das in einer Immobilie gebundene Kapital, das den Verkehrswert

Beide Renditen werden wiederum durch die Brutto-Mieteinnahmen und Netto-Bewirtschaftungskosten bzw. getätigte Transaktionen und Bestandswertänderungen bestimmt. Positivere Mieteinnahmen²⁴⁴ und niedrigere Netto Bewirtschaftungskosten münden beispielsweise in einer Steigerung der Netto Mieteinnahmen und umgekehrt.



Eigene Darstellung in Anlehnung an Kurzrock, 2016, S. 51-53; Wendlinger, 2012, S. 140 f.; gif, o.J..

Abbildung 9: Bestandteile des Total Return

Werden die Grundfaktoren des Total Returns²⁴⁵, unter Berücksichtigung aller bis jetzt gewonnenen Erkenntnisse, betrachtet, wären beispielsweise die auf der nachfolgenden Seite aufgelisteten Überlegungen mögliche Ansatzpunkte für Big Data in der Immobilienbranche zur Optimierung des Total Return²⁴⁶. Ein in die-

am Periodenanfang sowie wertbeeinflussende Investitionen und Netto- Mieteinnahmen im Betrachtungszeitraum beinhaltet. Investitionen erhöhen das gebundene Kapital, während Netto-Mieteinnahmen es mindern, da sie dem Investor als freie Mittel zufließen“

Kurzrock, 2016, S. 51.

244 Wird realisiert durch eine höhere Vermietungsquote, d.h. durch Verringerung des Leerstands und nicht durch eine Erhöhung der Miete.

245 Darunter sind die Punkte Gesamt Mieteinnahmen, Instandhaltung etc. aus Abbildung 9 zu verstehen.

246 Die dadurch beeinflussten Faktoren sind zusätzlich in Abbildung 9 grau hinterlegt.

sem Zusammenhang optimierter Total Return bedeutet folglich eine Steigerung der Immobilien-Performance und somit die Verbesserung des Wertschöpfungsbeitrages der Immobilienabteilung an der Wertschöpfung des Unternehmens.

- Teilautomatisierung von kaufmännischen (Echtzeit-Berichtswesen/Reporting, automatisierte Erstellung von Nebenkostenabrechnungen) und planerischen Leistungen (Bedarfsgerechte Steuerung der technischen und infrastrukturellen Leistungen d.h. Anpassung von Reinigungszyklen an Auslastung und Fluktuation etc.)²⁴⁷.
→ Reduzierung des Managementaufwands/der nicht umlegbaren Nebenkosten.
- Erstellen von Zukunftsprognosen, dadurch bessere Instandhaltungsplanungen folglich bessere Steuerung der zukünftigen Personalkapazitäten und Investitionsbudgets.
→ Reduzierung der Instandhaltungskosten und Verbesserung des Immobilienzustandes.
- Möglichkeit der Echtzeit-Immobilienbewertung inkl. verlässlichen Zustandsprognosen und zukünftigen Investitionsaufwendungen.
→ Automatisierte Echtzeit-Lebenszykluskosten-Analysen und Prognose der Rendite-Entwicklung von Investitionsobjekten.
- Möglichkeit der automatisierten Markteinschätzung und Prognose zukünftiger Entwicklungen, dadurch zeitlich bessere Möglichkeiten Immobilien und Flächen am Markt zu platzieren/neue Zukäufe zu tätigen.
→ Maximierung des Verkaufserlöses oder der Mieteinnahmen.
- Automatisierte Identifikation von Leerstandflächen durch Analysen der Belegungsquoten, Fluktuationen und Prognose der zukünftigen Auslastung. Nicht genutzte Flächen können u.U. untervermietet werden.
→ Reduzierung der Leerstandquote und automatisierte Raumplanungen für Mitarbeiter denkbar²⁴⁸.

247 Siehe hierzu auch die Überlegungen in 3.3.7.4.

248 Siehe hierzu insbesondere Fußnote 189.

5 Big Data in der Immobilienbranche – eine empirische Untersuchung

Der Grundbaustein dieses Kapitels ist der qualitative Forschungsansatz, der einer theorieentdeckenden Forschungslogik folgt²⁴⁹. Zu einer kleinen Stichprobe „wird [...] umfassendes [...] Datenmaterial erhoben und interpretativ ausgewertet, um auf dieser Basis den Untersuchungsgegenstand im Kontext detailliert zu beschreiben sowie Hypothesen und Theorien zu entwickeln“²⁵⁰. Diese Art der Forschung wurde aus folgendem Grund gewählt: Einige Entwicklungspfade im Big Data Kontext sind weiter entwickelt, andere stecken wiederum gerade erst am Anfang²⁵¹. Neue Themengebiete bieten immer viel freien und widerstandslosen Raum für neue Ansätze oder eben Theorien und Hypothesen. Die Anwendung von Big Data im Immobilienmanagement ist in Deutschland ein komplett neues Feld und steht somit am Anfang, bietet also viel freien Raum für neue und kreative Ideen. Die angesprochene Entwicklung innerhalb der Immobilienbranche, wo sie hin führen kann und was sie in Zukunft bieten wird, ist das, der Studie zur Grunde liegende, Forschungsthema. Aus diesem leitet sich ebenfalls die eingangs formulierte forschungsleitende Fragestellung „Wie lässt sich Big Data, unter der Hinzunahme möglicher Treiber und Barrieren, als Instrument in der Immobilienbranche einsetzen und nutzen? Welche Entscheidungen und Prozesse profitieren von dem Einsatz von Big Data als Unterstützungsinstrument?“ ab.

249 Döring/Bortz, 2016, S. 26.

250 Döring/Bortz, 2016, S. 25; Vgl. S. 215.

251 Vgl 3.3:Big Data – Mehr als nur große Daten?.

5.1 Darstellung des Forschungsdesigns und Methodenauswahl

Für eine praxisnahe Auseinandersetzung mit dem Forschungsthema wird eine Fallstudie durchgeführt. Im Bereich der Fallstudien lassen sich mehrere Arten unterscheiden: (1) Die holistische Einzelfallstudie (holistic, single-case design), (2) die eingebettete Einzelfallstudie (embedded, single-case design), (3) die holistisch, multiple Fallstudie (holistic, multiple-case design) und (4) eingebettete, multiple Fallstudie (embedded, multiple-case design). Holistische Fallstudien beinhalten dabei lediglich einen Untersuchungsgegenstand, wohingegen bei eingebetteten Fallstudien mehrere Untersuchungsgegenstände innerhalb der Studie betrachtet werden²⁵². Die Einzelfallstudie behandelt „eine einzelne Person, aber auch [...] eine Organisation, eine Veranstaltung, ein politisches Ereignis, eine Freundschaft, eine Unterrichtseinheit etc.“²⁵³. Eine multiple Fallstudie untersucht hingegen, wie dem Wortlaut zu entnehmen, mehrere Fälle²⁵⁴.

Die durchzuführende Studie betrachtet das übergeordnete Thema Big Data (Kontext) und vor dessen Hintergrund die entstehenden Entwicklungen innerhalb der Untersuchungseinheit der Immobilienbranche²⁵⁵. Zur Analyse der komplexen Strukturen einer Branche werden die Unternehmen als eingebettete Untersuchungsgegenstände²⁵⁶ (embedded units of analysis) betrachtet²⁵⁷. Eingebettete Untersuchungseinheiten können oft erhebliche Möglichkeiten für eine umfangreiche Analyse hinzufügen und die Einblicke in den Einzelfall verstärken²⁵⁸. Sodass das Forschungsdesign der eingebetteten Einzelfallstudie Anwendung findet. Als Untersuchungsgrundlage dienen „spezifische Forschungs-

252 Vgl. Yin, 2009, S. 46-60; Hussy/Schreier/Echterhoff, 2013, S. 199; Döring/Bortz, 2016, S. 215.

253 Döring/Bortz, 2016, S. 215.

254 Hussy/Schreier/Echterhoff, 2013, S. 199.

255 Vor dem Hintergrund der Fachrichtung dieser Arbeit sowie der zeitlichen Begrenzung wird bewusst die Auseinandersetzung mit der Immobilienbranche gewählt. Auf die Betrachtung mehrerer Branchen oder eine detaillierte Branchenuntersuchung der einzelnen Branchenteilnehmer, d.h. die Bildung eines multiple-case designs, wird an dieser Stelle verzichtet. Bei einem multiple-case design müsste eine cross-case Analyse, d.h. eine Gegenüberstellung jeder Branche/jedes Teilnehmers, durchgeführt werden, die den Rahmen dieser Arbeit übersteigt. Das verfolgte Ziel der Studie besteht in einer ersten Einschätzung der möglicher Zukunft der Branche mit Big Data und keine detaillierte Branchenuntersuchung, da, wie bereits gesagt, der Umfang begrenzt ist. Die wäre ein guter Anknüpfungspunkt für weiterführende Forschung.

256 Siehe dafür 5.3: Vorstellung der Interviewpartner.


257 Vgl. Hussy/Schreier/Echterhoff, 2013, S. 199.

258 Yin, 2009, S. 52 f.

fragen oder Forschungshypothesen“ mit denen die Besonderheiten des Falles identifiziert und erklärt werden²⁵⁹. Eine freie Verbindung verschiedener Erhebungs-, Aufbereitungs- und Auswertungsverfahren ist dabei möglich²⁶⁰.

Im Rahmen der Studie werden sechs Experteninterviews durchgeführt. Dabei wird darauf geachtet, dass ein fachlich und thematisch breiter Pool an Personen befragt wird, damit ein möglichst großes und umfassendes Zukunftsbild geschaffen werden kann. Die befragten Personen stammen beispielsweise aus dem Corporate- und IT-Bereich, aber auch aus dem Immobiliendienstleistungssektor²⁶¹.

Als Erhebungsverfahren kommt im Rahmen der Untersuchung ein offen gestaltetes, leitfadengestütztes und problemzentriertes Interview zur Anwendung. Die offene Gestaltung des Interviews ermöglicht es dem Befragten eine Antwort zu formulieren, die seine subjektiven Meinungen und Deutungen beinhaltet²⁶². So kann er „frei zu Wort kommen“²⁶³ und das Interview gleicht mehr einem offenen Gespräch. Dies hat zur Folge, dass sich zwischen Interviewer und Interviewtem eine intensivere Vertrauensbeziehung aufbaut und sich der Interviewte so nicht ausgehorcht und ernster genommen fühlt. Seine Antworten werden dadurch „ehrlicher, reflektierter, genauer und offener“²⁶⁴ als im Vergleich zu geschlossenen Varianten.



Eigene Darstellung, in Anlehnung an Mayring, 2002, S. 71.

Abbildung 10: Ablaufmodell des problemzentrierten Interviews

259 Döring/Bortz, 2016, S. 215.

260 Ebenda. Eine Übersicht der verschiedenen Verfahren ist in Mayring, 2002 zu finden.

261 Eine genauere Vorstellung der Interviewpartner erfolgt später unter 5.3.

262 Gerade diese sind im Rahmen der hier durchgeführten Studie von Interesse.

263 Mayring, 2002, S. 67.

264 Mayring, 2002, S. 69.

Für die Durchführung der problemzentrierten Interviews wird ein bestimmter Ablauf festgelegt, der sich am Ablaufmodell des problemzentrierten Interviews nach Mayring orientiert²⁶⁵. Zu Beginn einer jeden Untersuchung steht die Formulierung und Analyse des Problems (Problemanalyse), die bereits unter 1.1 erfolgte. Auf ebendiese Problemstellung wird das Interview zentriert. Damit ein roter Faden im Interview verfolgt werden kann, wird zu Beginn ein Interviewleitfaden entwickelt²⁶⁶. Die halbstrukturierte Auslegung der Interviews stellt sicher, dass alle geplanten Themenbereiche am Ende des Interviews abgearbeitet wurden und die Interviews untereinander vergleichbar bleiben. Letztendlich dient der Leitfragenkatalog als Gedankenstütze für den Interviewer und zur Anregung und Überleitung zu neuen Themenbereichen.²⁶⁷ Die im Leitfaden entwickelten offen gehaltenen Fragestellungen orientieren sich am Forschungsthema, sowie der unter 1.1:Einführung und Problemabgrenzung dargestellten Problemstellung. Im Anschluss daran empfiehlt Mayring eine Erprobung des Leitfadens (Pilotphase)²⁶⁸. Der Testlauf wurde vom Autor mit einer Testperson durchgeführt. Anhand der Erkenntnisse des Pre-Tests wurde der Leitfragenkatalog überarbeitet, sodass weniger Verständnisprobleme auftreten sollten, ein reibungsloser Ablauf gewährleistet wird und der zeitliche Umfang begrenzt ist. Die Protokollierung des Interviews erfolgt in zweierlei Weise: Zum einen wird das gesamte Interview mittels Tonaufnahme aufgezeichnet und zum anderen zeitgleich über ein Handprotokoll während des Gespräches zur Auswertungsunterstützung festgehalten.

Das so erhobene Datenmaterial wird wiederum einem Aufbereitungsverfahren unterzogen. Im ersten Schritt werden die aufgezeichneten Experteninterviews mittels wörtlicher Transkription in normales Schriftdeutsch übersetzt²⁶⁹. Dieses Transkript wird an den jeweiligen Interviewpartner versandt, der dadurch die

265 Siehe Abbildung 10: Ablaufmodell des problemzentrierten Interviews.

266 Siehe hierfür 5.2:Erarbeitung und Vorstellung des Fragebogens.

267 Vgl. Mayring, 2002, S. 66-71.

268 Vgl. Mayring, 2002, S. 69.

269 Siehe Mayring, 2002, S. 89-91.

Die so erstellten Transkripte der Interviews sind, aufgrund ihres Umfangs, auf der beigefügten CD zu finden.

Möglichkeit erhält Aussagen zu revidieren. Die von ihm durchgeführte Validierung und Freigabe ist eine Voraussetzung zur Einhaltung der Gütekriterien qualitativer Forschung nach Mayring²⁷⁰.

Das innerhalb der Studie verwendete Auswertungsverfahren ist die qualitative Inhaltsanalyse nach Mayring. Ursprünglich hat sie sich „aus der kritischen Auseinandersetzung mit der quantitativen Inhaltsanalyse entwickelt“²⁷¹. Ihre positive Eigenschaft gegenüber anderen Verfahren ist das streng methodische Vorgehen der schrittweisen Analyse des Materials. Dazu wird das Material in einzelne Einheiten zerlegt, in diesem Fall in einzelne Sätze, und kodiert²⁷², auf die wiederum verschiedene Methodiken zur Interpretationsvorbereitung angewandt werden können²⁷³. Im ersten Schritt erfolgt die Zusammenfassung. Ihr Ziel ist es das vorhandene Material auf die wesentlichen Inhalte zu reduzieren und mittels Abstraktion eine überschaubare Sammlung zu erstellen, die weiterhin den Sinn des Ursprungsmaterials widerspiegelt²⁷⁴. Im nächsten Schritt werden die so zusammengefassten Aussagen über die Methodik der Paraphrasierung von ihren wenig inhaltsträchtigen Bestandteilen befreit²⁷⁵. Dazu werden sie in eine einheitliche Sprache in grammatikalischer Kurzform transformiert²⁷⁶.

Der letzte Schritt umfasst die Strukturierung. Ihr Ziel ist es bestimmte Aspekte aus den Daten herauszufiltern. Dazu werden die einzelnen Textstellen in ein entwickeltes Kategoriensystem eingeordnet²⁷⁷. Die Bildung des Kategoriensystems ist in der qualitativen Inhaltsanalyse ein zentrales Instrument²⁷⁸. Dabei las-

270 Siehe Mayring, 2002, S. 147.

271 Döring/Bortz, 2016, S. 541.

272 Das Kodierungsschema ist dabei wie folgt aufgebaut:

Zu Beginn steht eine Interviewkennung (BD1, BD2, ...) gefolgt von einem Punkt als Trennzeichen. Danach steht die fortlaufende Satznummer. Das Ende bildet „§“ als Endzeichen. Daraus ergibt sich für jeden Satz eine eindeutige Kennung.

Beispiel: *BD1.123§* → Satz 123 in Interview Nummer 1.

Durch die Kodierung lassen sich im Nachgang die paraphrasierten Aussagen wieder den jeweils ursprünglichen Textstellen zuordnen. Dies macht den Prozess für Dritte rückwirkend nachvollziehbar und stellt somit ein wichtiges Instrument für die Einhaltung der Gütekriterien qualitativer Forschung nach Mayring dar.

273 Vgl. Mayring, 2002, S. 114 f.

274 Vgl. Mayring, 2002, S. 115.

275 Dies können beispielsweise ausschmückende, wiederholende oder verdeutlichende Formulierungen sein.

276 Vgl. Lamnek, 2005, S. 520 ff.

277 Vgl. Mayring, 2002, S. 115.

278 Vgl. Mayring, 2002, S. 114.

sen sich zwei unterschiedliche Herangehensweise unterscheiden: Im Falle der deduktiven Arbeitsweise werden aus theoriegeleiteten Überlegung Kategorien gebildet, das heißt, dass die Kategorien schon zu Beginn vorhanden sind. Im Kontrast dazu steht die induktive Kategorienbildung. Sie ist „eine systematische Ableitung von Auswertungsgesichtspunkten aus dem Material“, das bedeutet, dass die Kategorien erst im Laufe der Auseinandersetzung mit dem Material aus selbigem abgeleitet werden und nicht schon zu Beginn vorliegen²⁷⁹. Für diese Studie ist eine Mischung aus beiden vorgesehen. Das anfängliche Grundgerüst ist deduktiv aufgebaut und leitet sich aus den theoretischen Vorüberlegungen ab²⁸⁰. Auf dessen Grundlage kann zunächst eine erste Zuordnung getroffen und wichtige Aussagen aus den Interviews gezogen werden. Auf Basis der dadurch identifizierten Aussagen erfolgt im nächsten Schritt die Ableitung des induktiven Kategoriensystems, für eine genauere Zuordnung. Dies ist insofern sinnvoll, als dass das deduktive System bewusst sehr allgemein gehalten ist, um für möglichst viele Gedankengänge geeignet zu sein und diese aufzunehmen. Damit im nächsten Schritt Kategorien entwickelt werden können, die den Gedankenrichtungen der Interviewten entsprechen.

5.2 Erarbeitung und Vorstellung des Fragebogens

Die thematische Grundlage für den Leitfragenkatalog bilden die in den Kapitel 3 und 4 erarbeiteten Erkenntnisse. Die Durchführung der explorativen Vorstudie hatte einen sehr fokussierten Blick auf die Thematik beim Autor zur Folge. Zur Erlangung eines anderen und umfassenderen Blickwinkels und somit besseren Ableitung von Fragestellungen für den Leitfragenkatalog und Aufbau des deduktiven Kategoriensystems wurde sich der Theorie des geplanten Verhaltens („theory of planned behavior“)²⁸¹ bedient. Sie besagt in groben Zügen, dass sich das Verhalten eines Menschen („behavior“) vor allem durch seine Verhaltensabsicht („intention“) bestimmt. Diese wird wiederum durch die drei Faktoren (1) „attitude“, das heißt die Einstellung gegenüber dem Verhalten, (2) „subjective norm“, d.h. der wahrgenommene soziale Druck, das Verhalten durchzuführen oder nicht durchzuführen, und (3) „perceived behavioral control“, d.h. die wahr-

279 Mayring, 2002, S. 115 f.

280 Siehe dafür 5.2:Erarbeitung und Vorstellung des Fragebogens.

281 Ajzen/Madden, 1986.

genommene Verhaltenskontrolle, also die Einschätzung des Schwierigkeitsgrades zur Umsetzung des Verhaltens, beeinflusst. Im Rahmen der Anwendung wird zu jedem Element eine Hypothese gebildet, die im Anschluss auf ihre Gültigkeit hin überprüft wird.²⁸² Da diese Vorgehensweise charakteristisch für den quantitativen Forschungsprozess ist²⁸³ und die vorliegende Arbeit einen qualitativen Forschungsansatz verfolgt, soll die Theorie des geplanten Verhaltens lediglich als Hilfsinstrument dienen²⁸⁴.

Im weiteren Verlauf werden die vier Faktoren attitude, subjective norm, perceived behavioral control und intention im Bezug auf das zur Grunde liegende Forschungsthema und der forschungsleitenden Fragestellung genauer betrachtet. Die Kernaspekte der forschungsleitenden Fragestellung liegen in der Identifikation von möglichen Treibern und Barrieren sowie dem Einsatz und Nutzen und damit zusammenhängenden profitierenden Entscheidungen bzw. Prozessen. Damit der Kenntnisstand der Befragten zum Thema Big Data sowie die subjektive Einstellung zum Thema abgefragt werden kann werden folgenden vorgelagerte Sondierungsfragen²⁸⁵ formuliert²⁸⁶:

1. Was verbinden Sie mit dem Begriff „Big Data“? (A1)
2. In welchem Zusammenhang gelangten Sie zu Ihrem Wissen zu Big Data? (A2)

Ad-hoc Fragen:

1. War dies im Rahmen von Projekten, durch Kollegen etc.?
2. Gab es bereits konkrete Auseinandersetzungen/Berührungspunkte?

282 Vgl. Ajzen/Madden, 1986.

283 Vgl. Döring/Bortz, 2016, S. 24.

284 Die Formulierung dieser Hypothesen half dem Autor den, oben angesprochenen, umfassenderen und allgemeineren Blick auf das Thema Big Data im Immobilienmanagement wieder zu erlangen.

285 Vgl. Mayring, 2002, S. 70.

286 Die in Klammern gesetzten Kürzel, am Ende jeder Frage, dienen für die Kategorienzuzuordnung. Siehe Seite 70.

Zur Schaffung eines einheitlichen Verständnisses folgt eine Definition des Begriffs Big Data auf Grundlage der oben gewonnenen Erkenntnisse:

Big Data besitzt eine **Mehrdimensionalität**

Es umfasst sowohl (1) große Datenmengen

- die in strukturierter als auch unstrukturierter Form vorliegen,
- aus unterschiedlichen Datenquellen stammen,
- in immer kürzerer Zeit immer schneller anwachsen,
- in Echtzeit verarbeitet werden,
- und sich schnell ändern können,

als auch (2) Technologien, (3) analytische Methoden, (4) Modellierungs- und Designverfahren sowie (5) rechtliche Rahmenbedingungen.

Da diese für den Fragenkatalog jedoch zu umfassend ist und lediglich nur einzelne Aspekte der Thematik im weiteren Verlauf betrachtet werden sollen, erfolgt eine Eingrenzung des Betrachtungsgegenstands für die Interviews:

Big Data beschreibt große heterogene Daten und Verfahren, diese Daten zu verarbeiten, zu analysieren um neue, unbekannte Erkenntnisse über Sachverhalte zu gewinnen.

Die Fragestellungen hinsichtlich des Einsatzes, Nutzen und damit zusammenhängende profitierende Entscheidungen bzw. Prozesse bilden den Anfang der Hauptfragen. Diesen Punkten lässt sich der Faktor *attitude* zuordnen. Die dazu formulierte Hypothese ist:

attitude: Je positiver die eigene Einstellung zu Big Data, desto gestärkter ist die Absicht Big Data zu nutzen.

3. Welchen Nutzen würden Sie sich von Big Data in der Immobilienbranche versprechen? (B1)

Big Data soll, neben anderen Dingen, auch zur Entscheidungsfindung/-unterstützung dienen.

4. Welche Möglichkeiten/Einsatzbereiche sehen Sie in diesem Zusammenhang wie Big Data in der Immobilienbranche unterstützend eingesetzt werden kann? (B2)

Ad-hoc Fragen:

1. Wie sieht es in den Bereichen TGM/IGM/KGM, Property Aufgaben, Steuerung aus?
2. Bei Corporates als Interviewpartner: Können Sie sich den Einsatz von Big Data in Ihrem Portfolio vorstellen? Warum ja/nein?
5. Welche Entscheidungen können in der Immobilienbranche durch Big Data unterstützt werden? Sind gewisse Entscheidungen automatisierbar? (B3)
6. Welche Prozesse würden durch eine solche Unterstützung beeinflusst? Wie sieht diese Beeinflussung aus? (B4)

Treiber und Barrieren stellen äußere sowie innere Einflüsse dar, die ein Unternehmen dazu bewegen den Einsatz von Big Data in Erwägung zu ziehen. Eben solche Einflüsse werden mit den Punkten subjective norm und perceived behavioral control untersucht. Die dazu formulierten Hypothesen lauten:

subjective norm: Je höher der wahrgenommene Druck des sozialen Umfeldes zum Big Data Einsatz, desto gestärkter ist die Absicht Big Data zu nutzen.

perceived behavioral control: Je höher die wahrgenommene Kontrolle, desto gestärkter ist die Absicht Big Data zu nutzen.

Unter Berücksichtigung der bereits gewonnenen Erkenntnisse wurden daraus folgende Fragestellungen abgeleitet:

7. Welche externen Faktoren können den Einsatz von Big Data beeinflussen? Wie sieht dieser Einfluss aus? (C1)
8. Welche internen Faktoren können den Einsatz von Big Data beeinflussen? Wie sieht dieser Einfluss aus? (C2)

Darüber hinaus sollte im Fragenkatalog die Gelegenheit genutzt werden den unter 4:Big Data im Immobilien-Kontext aufgestellte Datenpool mit den Aussagen der Experten abzugleichen:

9. Was können mögliche Datenlieferanten sein? Wo können die benötigten Daten herkommen? (C3)

Abgeschlossen wird mit einer Frage die den Faktor intention berücksichtigt. Sie Antworten über die zukünftige Entwicklung liefern.

10. Haben Sie die Absicht sich in den nächsten 12 Monaten mit Big Data verstärkt auseinander zu setzen? Planen Sie Ihr Unternehmen/Ihre Abteilung verstärkt in diese Richtung weiter zu entwickeln? Sind bereits Projekte für die Einführung geplant? (D1)

Als erstes deduktives Kategoriensystem werden die vier näher betrachteten Faktoren attitude als Kategorie Wertschöpfungspotentiale (BX), subjective norm in Verbindung mit perceived behavioral control als Treiber und Barrieren (CX), intention als Zukunftsperspektive (DX) und die Sondierungsfragen (AX) festgelegt. Diese können sich im weiteren Verlauf durch die Anwendung der induktiven Kategorienbildung verändern oder durch neue Kategorien ersetzt bzw. ergänzt werden.

5.3 Vorstellung der Interviewpartner

Als Interviewpartner sollten kreative Köpfe aus der Immobilienbranche gefunden werden, die bereits eine grundsätzliche Vorstellung vom Thema Big Data besitzen²⁸⁷. Aufgrund der Aktualität des Themas gestaltete sich die Suche nach geeigneten Personen etwas komplizierter. Von großem Vorteil war dabei die, sehr überraschende, positive Resonanz, auf die der Autor bei den ersten Kontaktaufnahmen traf. Daraus entwickelten sich weitere potentielle Kontaktpersonen, sodass am Ende eine deutlich höhere Anzahl an Interview-Interessenten vorlag als an angesetzten Interviews²⁸⁸. Da jeder Interessent die oben angeführten Eigenschaften erfüllte, erfolgte die letztendliche Auswahl der Kandidaten maßgeblich nach terminlichen Gesichtspunkten, jedoch immer vor dem Hintergrund einer breit gefächerten Aufstellung. Der Übersichtlichkeit halber erfolgt die detailliertere Darstellung der finalen Interviewpartner in tabellarischer Form²⁸⁹.

287 Darunter werden vom Autor keine fundierten IT-Kenntnisse in diesem Zusammenhang verstanden, sondern das Wissen darüber, was Big Data ist und umfasst.

288 Aufgrund der zeitlichen Perspektive waren nicht mehr Interviews realisierbar.

289 Siehe Tabelle 1.

Big Data in der Immobilienbranche – eine empirische Untersuchung

IP	Tätigkeitsfeld des Interviewpartners	Unternehmen/Branche	Eckdaten (weltweit)
1	Strategisches Facility Management und Facility Services	CRE, zuständig für die Flächen- und Servicebereitstellung, und alle Real Estate verwandten Themen innerhalb des Konzerns.	Konzernumsatz: ca. 80 Mrd. € Immobilienvermögen: ca. 4,5 Mrd. €
2	Chefvolkswirt für die Bereiche Volkswirtschaft, Marktforschung, Strategie	Tätig in den Bereichen Corporate Finance, Projektmanagement und Immobilienfonds.	Konzernumsatz: ca. 200 Mio. € Europaweit in über 12 Ländern aufgestellt.
3	Inhouse Berater Facility Management für Facility Services und Dienstleistungssteuerung	Immobilien/Projektentwicklung	Konzernumsatz: ca. 1 Mrd. € Assets under Management: ca. 34 Mrd. €
4	Facility Operations	CRE, zuständig für alle Real Estate Themen innerhalb des Konzerns (EMEA, APAC).	Konzernumsatz: ca. 8 Mrd. €
5	Digitale Innovationen	Integrierter Immobiliendienstleister	Konzernumsatz: ca. 12 Mrd. €
6	Development Manager Real Estate Management	IT/Software	Konzernumsatz: ca. 22 Mrd. €

Tabelle 1: Vorstellung der Interviewpartner

Aus den Interviewpartnern ergeben sich folgende eingebettete Untersuchungseinheiten:

Interviewpartner	Untersuchungseinheit
IP1 und IP4	Corporate Real Estate
IP2	Finance/Research
IP3	Inhouse-Beratung FM
IP5	Immobilien dienstleistung
IP6	IT/Software

Tabelle 2: Darstellung der eingebetteten Untersuchungseinheiten

5.4 Untersuchungsergebnisse

Das unter 5.2 dargestellte deduktive Kategoriensystem wurde im Verlauf der Datenauswertung mittels induktiver Kategorienbildung angepasst. Aufgrund der Aussagen der Interviewpartner wurden die Oberkategorie Status Quo und eine Unterkategorie im Bereich der Wertschöpfungspotentiale, die Veränderungen und Auswirkungen durch Big Data aufnimmt, ergänzt:

Kategorie		Fragestellung/Inhalt	Inhaltscode
Sondierungsfragen		Big Data Verständnis	A1
		Wissenskontext	A2
Status Quo		Informationen zum Status Quo	B1
Wertschöpfungspotentiale	attitude	Nutzen	C1
	attitude	Einsatzbereiche	C2
	attitude	Entscheidungen	C3
	attitude	Prozesse	C4
		Veränderungen/Auswirkungen durch Big Data	C5
Treiber und Barrieren	norm & control	Externe Faktoren	D1
	norm & control	Interne Faktoren	D2
	norm & control	Datenlieferanten	D3
Zukunftsperspektive	intention	Eigene zukünftige Entwicklung	E1

Tabelle 3: Darstellung des Kategoriensystems

Die zusammenfassende Darstellung der aufbereiteten Untersuchungsergebnisse erfolgt entlang dieses Kategoriensystems.

5.4.1 Sondierungsfragen

Bei allen Interviewpartnern liegt ein grundsätzliches Verständnis über Big Data vor. Es wird hauptsächlich als die Verwendung einer großen Datenmenge beschrieben, die sowohl strukturierte als auch unstrukturierte Daten beinhaltet, durch deren Analyse neue Erkenntnisse in Echtzeit und mit hoher Präzision gewonnen werden. Heutige technische Lösungen ermöglichen Datenanalysen, die früher undurchführbar waren. Big Data wird als ein Prozess zur Maximierung der Effizienz beschrieben, der erst ab einer gewissen Unternehmensreife von Belang ist. Darüber hinaus wird angemerkt, dass es sich bei dem Begriff Big Data um ein Buzzword handelt, das Fluch und Segen zugleich darstellt, da es sich in den Augen eines Interviewpartners manipulativ einsetzen lässt, aber auch große Potentiale bietet. Die erste Aufmerksamkeit erreichte das Thema unter anderem durch die Presse, fachliche Publikationen und Fachkongresse. Die letztliche Auseinandersetzung erfolgte bei den Interviewpartnern auf unterschiedliche Art und Weise. Entweder wurde sie durch den beruflichen Hintergrund der Interviewpartner getrieben oder durch das Geschäftsumfeld, sodass teilweise eine reaktive Auseinandersetzung im jeweiligen spezifischen Kontext erfolgte.

5.4.2 Status Quo

Die Unternehmen innerhalb der Immobilienbranchen haben aktuell mit einer sehr heterogenen IT-Struktur zu kämpfen und besitzen keine Transparenz bezüglich ihrer Daten. Gerade im Bereich der FM-Dienstleistungen werden die Unternehmen von einem Interviewpartner als eher innovationsscheu und auf das Thema wenig vorbereitet beschrieben. Die notwendige Unternehmensreife zur Anwendung von Big Data ist bei vielen Unternehmen noch nicht vorhanden. An dieser Stelle gilt jedoch eine Einschränkung: Großunternehmen setzen sich mit dem Thema Big Data bereits verstärkt auseinander. Die Begründung sieht ein Interviewpartner darin, dass diese viel häufiger und intensiver im internationalen Wettbewerb stehen und die Verbindung unterschiedlicher Datenquellen bei Kunden in den USA deutlich mehr im Trend ist, als in Europa. Im Bereich des Mittelstandes wird Big Data keine so große Rolle zugesprochen, sodass

Big Data von den Interviewpartnern momentan eher als eine intellektuelle Diskussion beschrieben und der tatsächliche Nutzen aktuell teilweise noch nicht gesehen wird. Durch eine bislang chaotische Datenauswertung fällt es vielen Marktteilnehmern schwer, dem Thema Big Data zu folgen. Dies führt jedoch auch zu einer Bewusstseinsänderung bei den Marktteilnehmern für systematischere Auswertungen, die wiederum ersteres begünstigen. Somit wird Big Data eine dynamisierende Wirkung auf den Markt vor dem Hintergrund der Datenbedeutung nachgesagt, die eine notwendige Sensibilisierung für die Datenerhebung begünstigt. Die aktuelle Situation wird von den Interviewpartnern so beschrieben, dass wenn überhaupt nur ein Bruchteil der aktuell verfügbaren Daten genutzt wird. Trotz dieser nicht vorhandenen bzw. geringen Nutzung werden immer mehr Daten gesammelt. Ein Problem kann darin liegen, dass schon bestehende und geeignete Daten nicht aus den vorhandenen Systemen ausgelesen werden um sie für Big Data Zwecke zu verwenden (beispielsweise Wifi-Netze oder Zugangssysteme), oder die aktuelle Datenbasis von Unternehmen für den Einsatz ungeeignet ist. Dabei wird die Nutzbarmachung der ungeeigneten Daten als eine große Herausforderung angesehen und ein zunehmender Fokus auf die Strukturierung der Daten gelegt. Vorhandene Daten werden aktuell bei einigen Interviewpartnern zwecks vereinfachter Darstellung, Messung, Steuerung der Realität und Vorbereitung auf den Big Data-Einsatz in standardisierter Form zusammengetragen und aggregiert. Bevor Unternehmen diesen Schritt gehen können, müssen sie sich darüber klar werden, welche Daten in Zukunft benötigt werden und welche Informationen in Zukunft aus den Daten gewonnen werden sollen. Ein anderes Problem wird in dem Fehlen von branchenspezifischen Methodiken zur Datenauswertung gesehen. Die technische Entwicklung und Nutzbarmachung steht im betrachteten Zusammenhang gemäß den Interviewpartnern noch am Anfang und wird noch ein paar Jahre benötigen. Aktuell gibt es jedoch schon Entwicklungen, die das Ziel verfolgen Handlungsempfehlungen für den Nutzer zu generieren, um so Entscheidungen zu unterstützen²⁹⁰.

290 Stichwort: prescriptive analytics (Kapitel 3.3.7.3).

Insgesamt steht die Immobilienbranche, nach Aussagen der Interviewpartner, noch am Anfang. Von einem künftigen Einsatz von Big Data in der Branche wird jedoch aufgrund des gesehenen großen Potentials ausgegangen.

5.4.3 Wertschöpfungspotentiale

Im Bereich der Wertschöpfungspotentiale wurde nach mehreren Aspekten gefragt. Im weiteren Verlauf werden die genannten Einsatzszenarien und den damit verbundenen Nutzen vorgestellt inkl. ihren Entscheidungen und Prozessen, die durch Big Data beeinflusst werden. Abschließend folgen die Auswirkungen durch Big Data auf die Branche.

Von Big Data wird sich ein vielseitiger Nutzen versprochen. Zum einen soll es die allgemeine Transparenz und die Datentransparenz innerhalb der Unternehmen und des Marktes erhöhen und zum anderen den Aufbau eines unternehmensinternen Mindeststandards für die Anforderungen an die Datenermittlung und -ablage sowie die Identifikation von relevanten Daten ermöglichen²⁹¹. In diesem Zusammenhang versprechen sich die Interviewpartner eine höhere Datenqualität, Datengranularität, Informationsdichte und ein besseres Verständnis von Datenzusammenhängen, aber auch ein schnittstellenfreieres Arbeiten. Vor dem Hintergrund der Erkenntnisse aus den Daten soll Big Data eine Basis für die objektivere Entscheidungsfindung liefern, die letztendlich zu einer Risikoreduzierung führen soll. Die Art und der Umfang der Entscheidungsunterstützung hängt vom jeweiligen Einsatzszenario ab. Darüber hinaus sehen die Interviewpartner vielseitigere Steuerungsmöglichkeiten in Abhängigkeit des Risikoszenarios. Dabei ergänzt Big Data die menschliche Denkweise und Entscheidungsfindung. Big Data in Verbindung mit IoT soll eine engere Verzahnung von Wertschöpfungsketten zwischen Auftraggeber und Auftragnehmer, aber auch zwischen unterschiedlichen Wertschöpfungsprozessen innerhalb eines Unternehmens ermöglichen. Wird dies aus globaler Perspektive betrachtet schafft Big Data auf Immobilienebene so die Grundlage für weitreichendere Anwendungen wie globale Vertragssituationen (und damit erzielbare Skaleneffekte) oder die Smart-City.

291 Darunter ist die Entwicklung individueller Kriterien zur Ableitung von Smart Data zu verstehen.

Die neuen Erkenntnisse für das Tagesgeschäft, die sich die Interviewpartner von Big Data erhoffen, lassen sich in vier Einsatzszenarien unterteilen: (1) die Immobilienentwicklung, (2) die Immobiliennutzung mit den Schwerpunkten im technischen, infrastrukturellen und kaufmännischen Bereich sowie Nutzer/Mieter, (3) die Immobilienbewertung und (4) die Immobilientransaktionen.

Im Bereich der Immobilienentwicklung wird eine detaillierte Lebenszyklusbeurteilung der Immobilie gesehen und eine Unterstützung im Bereich der Expansion zur Standortfindung. Auf der Grundlage von Nutzerzufriedenheitsdaten und Daten aus technischen Anlagebeständen lassen sich heutige und zukünftige Nutzeranforderungen identifizieren und bessere Nutzerbedarfsprogramme aufstellen sowie unterschiedlichen Bau- und Ausstattungsszenarien (sowohl hinsichtlich Technik als auch Möblierung) abwägen. Dies soll den Interviewpartnern eine bessere Vorhersehbarkeit der Immobilienbeschaffenheit (d.h. Raum-Geometrien, Technik, Zugänglichkeit) und in Kombination mit Finanzdaten eine zuverlässigere Prognose der Lebenszykluskosten bieten.

Die Immobiliennutzung ist stark von operativen Prozessen geprägt und gerade im operativen Bereich sehen die Interviewpartner für Big Data große Potentiale. Durch Big Data in Verbindung mit Gebäudeautomation stellen sie sich eine intelligente Immobilie vor, die ihren Bedarf für operative Leistungsprozesse selbst meldet²⁹². Im technischen Schwerpunkt sehen die Interviewpartner durch Big Data die Möglichkeit, in Abhängigkeit der jeweiligen Zielsetzungen unterschiedliche Betriebsszenarien zu prognostizieren und zu modellieren, die über die Gebäudeautomation anschließend automatisch umgesetzt werden. Die Instandhaltungsprozesse sollen durch einen detaillierten Blick auf und in die Technik, predictive maintenance und eine Gebädetransparenz in Echtzeit profitieren. Neben der Empfehlung von Instandhaltungsstrategien sehen die Interviewpartner eine Möglichkeit zur optimalen Auslastung und dem optimalen Betrieb der technischen Anlagen in den Gebäuden. Die hinzugezogene Sensorik soll im infrastrukturellen Bereich ebenfalls für eine Vereinfachung sorgen indem Reinigungszyklen entsprechend des Bedarfs automatisch angepasst werden. Durch die Verfügbarkeit von Markt- und Mietdaten ließen sich Prozesse der Mieterbe-

292 Hierbei kann es sich beispielsweise um Reinigungsarbeiten oder um Wartungen handeln.

treuung und beispielsweise Änderungen der Mietverhältnisse im kaufmännischen Bereich besser und kurzfristiger abwickeln und durch die Sensorunterstützung Nebenkostenabrechnungen automatisch erstellen. In Bezug auf die Immobiliennutzer erhoffen sich die Interviewpartner ein besseres Verständnis der zeitlichen und räumlichen Nutzung der Immobilie, d.h. welche Einrichtungen von den Mietern genutzt werden, aber auch, wie diese genutzt werden (d.h. Verhaltensweisen der Nutzer) in Abhängigkeit von der Tageszeit oder Klimasituation. Dadurch lassen sich nutzerbedarfsgerechtere Anpassungen an der Immobilie und Technik vornehmen sowie die Flächen besser an die Nutzungssituationen anpassen.

Neben der Steigerung der Nutzerzufriedenheit sehen die Interviewpartner in diesen Zusammenhang eine bessere Steuerung der Flächenbelegung und somit eine effizientere Immobiliennutzung durch beispielsweise das Herunterfahren von nicht genutzten Flächen. Das Herunterfahren von solchen Flächen (Bedarfsanpassung) hat wiederum positive Auswirkungen auf die technischen und infrastrukturellen Bereiche in denen automatische Anpassungen vorgenommen werden (z.B. Abschaltung der Heizung oder Klimaanlage zwecks Energieeinsparung oder Anpassung von Reinigungszyklen). Operative Immobilienprozesse werden in den Augen der Interviewpartner zunehmend digitalisiert und automatisiert, wodurch die stark operativ getriebenen und objektbezogenen Prozesse deutlich optimiert und vereinfacht werden, was eine bessere wirtschaftliche und technische Steuerung eines Gebäudes und des Personals ermöglicht.

Im Bereich der Immobilienbewertung und der Immobilientransaktionen ist für die Interviewpartner die Entscheidungsunterstützung durch Big Data relevant. Es lassen sich bessere Verkaufsentscheidungen durch die genauere Bestimmung und Prognose des Immobilienwertes und des Verkaufszeitpunktes sowie Vorhersagen über die technische Beschaffenheit eines Objektes treffen.

Letztendlich können die Interviewpartner durch Big Data die Prozesse bedarfsgerechter auslegen, wodurch Arbeits- und Entscheidungsprozesse beschleunigt werden. Davon versprechen sie sich wiederum eine Kostenentlastung und Zeitoptimierung, die in einer Steigerung der Prozesseffizienz und Produktivität, d.h. einem optimierten Immobilienbetrieb, münden soll.

Der immer wieder angesprochene Punkt der Entscheidungsautomatisierung stellt einen wichtigen Aspekt der zukünftigen Entwicklungen für die Interviewpartner dar. Sie versprechen sich durch die eingebaute Sensorik eine Automatisierung von Prozessen (Steigerung der Prozesseffizienz) und, dass aktuell von Menschen getroffene Entscheidungen zukünftig automatisiert getroffen werden und eine automatisierte Anpassung der Prozesse und Entscheidungen an die jeweilige Zielsetzung erfolgt. Von den Interviewpartnern wird jedoch angemerkt, dass im Automatisierungsprozess am Ende immer eine Kontrollinstanz stehen sollte, da Big Data im Rahmen der Entscheidungsfindung keine 100 prozentige Sicherheit liefern wird. Der Mensch als Entscheider ist somit nicht gänzlich ersetzbar. Entscheidungen für einfache Kausalzusammenhänge auf operativer Ebene (beispielsweise die Arbeitsplatzzuweisung von Mitarbeitern in Abhängigkeit vom Tagesplan) sollen zukünftig aber automatisierbar sein.

Nach Meinung der Interviewpartner wird die Digitalisierung der Immobilie und der Branche weiter zunehmen. Die zunehmende Digitalisierung und der Einsatz von Big Data wird dabei eine starke Auswirkung auf die Immobilienbranche haben, andere Hierarchie- und Unternehmensmodelle mit sich bringen und den Wandel zur ergebnisorientierten Ausschreibung unterstützen. Operative Prozesse lassen sich automatisieren und ersetzen so aktuell menschlich durchgeführte Tätigkeiten. Neben der Branche sehen die Interviewpartner speziell für FM-Dienstleister große Auswirkungen. Die aktuellen Geschäftsmodelle müssen überarbeitet und an die neue Situation angepasst werden. Big Data verändert den Arbeitsmarkt und die beruflichen Anforderungen an die Beschäftigten innerhalb der Branche (speziell im FM Bereich), da durch die Automatisierung einfacher Kausalzusammenhänge Arbeiten weg fallen und der Fokus so stärker auf übergeordnete Aspekte gerichtet wird. Reinigungskräfte oder Beschäftigte für einfache kaufmännische Tätigkeiten (zum Beispiel Nebenkostenabrechnungen)

können in Zukunft durch Systeme oder Roboter ersetzt werden, was große personalpolitische Probleme und psychologische Auswirkungen auf das Personal mit sich bringen wird: Was wird mit den frei werdenden Ressourcen gemacht? Wie ist dieser Wandel mit bestehenden Arbeitsverträgen zu vereinbaren? Big Data verändert die Art der Leistungserbringung, sodass auf Dienstleisterseite neue Instrumente zur Steuerung der neuen Geschäftsmodelle notwendig werden als Reaktion auf die bedarfsgrechere Auslegung der Prozesse auf Auftragsgeberseite. Diese neue Auslegung macht gänzlich andere Personalsteuerungen notwendig ermöglicht aber auch die bereits angesprochene viel engere Verknüpfung der Wertschöpfungsketten zweier Unternehmen. Andere Hierarchiemodelle ergeben sich durch eine gewisse Demokratisierung von Entscheidungen durch Big Data, die von einem Interviewpartner gesehen wird, da durch die vorherige bessere Datenaufbereitung Entscheidungskompetenzen auf weiter unten liegende Ebenen übertragen werden können. Der selbe Interviewpartner merkt jedoch auch an, dass dies die Gefahr der Datendiktatur aufgrund einer Machtverschiebung innerhalb der Branche mit sich bringt. Eine positive Auswirkung wird in der steigenden Bereitschaft des Marktes für Daten und deren Erfassung gesehen, von der sich eine zunehmende Marktflexibilität erhofft wird, da durch mehr Daten oft bessere Prognosen möglich sind. Nach Aussage der Interviewpartner wird dadurch die bereits niedrige Loyalität und Bereitschaft der Unternehmen für die Bindung an Bürofläche weiter abnehmen.

5.4.4 Treiber und Barrieren

Eine kritische Auseinandersetzung mit dem Thema ist für die Interviewpartner notwendig zur Identifizierung von Einflüssen durch Big Data um keinem Wettbewerbsnachteil zu unterliegen. Der Markt und das Wettbewerbsumfeld werden so durch ihre Entwicklung (d.h. zunehmende Digitalisierung und Auseinandersetzung mit Big Data) als extern treibender Faktor auftreten. Auf der FM-Dienstleisterseite wird aufgrund der unterstellten disruptiven Wirkung²⁹³ von Big Data nur ein geringes Interesse zur proaktiven Einführung und Nutzung von Big Data vermutet. In Zukunft wird in den Augen der Interviewpartner jedoch ein Umdenken auf Dienstleisterseite durch den vom Auftraggeber in den Markt gegebenen

²⁹³ Siehe dazu die Diskussion unter 8.1.

Kosten- und Digitalisierungsdruck erhofft. Marktteilnehmer die sich dem Thema nicht öffnen und sich damit nicht auseinandersetzen erleiden einen Wettbewerbsnachteil und gefährden dadurch ihre Position im Markt. Dabei ist für die Interviewpartner immer zwischen dem eigenem Wettbewerbsvorteil, durch Intransparenz gegenüber Dritten, und Nutzung von Synergieeffekten, durch Offenlegung und Integration von Dritten, abzuwägen. In erster Linie muss jedoch der Markt für die Datennutzung, den Wert, den Daten bringen und deren Qualität sensibilisiert und aufgeklärt werden. Diese Sensibilisierung des Marktes für Daten wird bereits durch Branchenexterne wie die IT-Branche getrieben. Der Datenschutz stellt eine weitere Barriere dar und die Auseinandersetzung mit rechtlichen Rahmenbedingungen ist im Rahmen von Big Data für die Interviewpartner essentiell um Datenmissbrauch vorzubeugen. Datensicherheit, Datenverfügbarkeit und Anonymisierung der Daten spielen dabei für sie eine große Rolle, wobei die Anonymisierung der Daten als notwendig erwartet wird. Im Rahmen der Big Data-Nutzung soll aber nicht der einzelne Mitarbeiter im Fokus stehen, sondern die Allgemeinheit. Dem Faktor Mensch wird davon unabhängig dennoch eine große Bedeutung zugeschrieben, da seine Zufriedenheit als Nutzer der Immobilie von Bedeutung ist. Jede technische Neuerung muss für den Nutzer nicht zwangsläufig besser sein und ist somit für die Interviewpartner immer vor dem Hintergrund der Nutzerzufriedenheit zu bewerten. Als weiterer Aspekt wird von einem Interviewpartner die hohe Trägheit des Immobilienmarktes in Bezug auf die Umsetzung und den Einsatz neuer Technologien und Sensorik (Marktumschlaghäufigkeit und -durchdringung in 20-30 Jahren) angesprochen. Der überwiegende Teil des Marktes besteht aus Bestandsimmobilien und nur bei Neubauten oder Kernsanierungen besteht rein operativ die Chance, neue Technologien und Sensorik ins Gebäude einzubauen. Dementsprechend wird eine flächendeckende Verfügbarkeit von Daten aus der Sensorik in Gebäuden erst zu einem späteren Zeitpunkt gesehen, sodass die operative Bedeutung von neuer Sensorik zum aktuellen Zeitpunkt noch als sehr gering beschrieben wird und die zukünftige Relevanz des Themas in erster Linie beim Neubau liegt. Der Drang zum Einbau von Sensorik als weiterer Datenlieferant kommt eher aus dem Betrieb heraus, muss also nachjustiert werden, und ist im Bereich der Pla-

nung nicht im Fokus. Die zunehmende Ausstattung der Gebäude mit Sensorik (beispielsweise beim Austausch von technischen Anlagen oder Leuchtmitteln) wird diesen Trend jedoch fördern.

Ein schon aktuelles Problem stellt die unternehmensinterne Datentransparenz dar. Die Daten liegen in vielen unterschiedlichen Systemen vor, sodass die Herausforderung in der Identifikation der relevanten Daten (Smart Data) liegt. Die Daten und Datenlieferanten sind dabei immer vom jeweiligen Einsatzszenario abhängig. Prinzipiell sehen die Interviewpartner das eigene Unternehmen als besten Datenlieferanten an, in Zukunft wird sich vom Markt jedoch wahrscheinlich ein Benchmark-Anbieter gewünscht, der Daten poolt. Es lassen sich bei den Daten interne und externe Datenquellen, wie in Tabelle 4 dargestellt, unterscheiden. Bereits heute können vorhandene Infrastrukturen (Wifi-Netze zum Anwesenheitstracking) als Datenlieferanten verwendet werden, somit sind nicht zwangsweise neue Sensoren zu verbauen, und es existieren Systeme zur Zusammenführung der Heterogenität der Gebäudetechnik, um so einheitliche Daten aus verschiedenen Systemen zu erhalten. Der Big Data-Einsatz ist folglich immer unternehmensindividuell und muss dementsprechend individuell abgewägt werden. Dabei ist für die Interviewpartner das Verhältnis des mit dem Einsatz verbundenen Aufwands²⁹⁴ im Vergleich zum generierten Nutzen ausschlaggebend. Über Pilotversuche muss man sich einem praxisnahen Einsatz annähern und die Betrachtungszeiträume für Smart Data-Kriterien erproben, damit ein ausgewogenes Aufwand-Nutzen-Verhältnis gewährleistet werden kann.

294 Der Aufwand entspricht dem festgelegten Detaillierungsgrad für die Daten.

Interne Datenquellen	Externe Datenquellen
<ul style="list-style-type: none"> • der Gebäudeerstellungsprozess • CAFM-Systeme (Gebäudezustände, Instandhaltungskosten, Planungs- und Belegungsdaten etc.) • die Immobilie (GLT, Sensordaten, Iot) • die Nutzer (Daten aus Zufriedenheitsmessungen) • Buchhaltungs- und ERP-Systeme (Finanzdaten, Immobilienkosten, Filial-Umsätze) • HR- und Reisemanagement-Lösungen • Energiemanagementsysteme (Energieverbräuche) • Kundenindividuelle Informationsquellen 	<ul style="list-style-type: none"> • Die Umwelt (Geoinformationen: Klima, Verkehr, Bevölkerung etc.) • mikro- und makroökonomische Daten (Konkurrenzsituationen an Standorten, Gehaltsfälle in der Region etc.) • Marktdaten • extern zukaufbare Informationen

Tabelle 4: Mögliche Datenquellen aus der Sicht der Interviewpartner

5.4.5 Zukunftsperspektive

Big Data rückt bei den Interviewpartnern in die nähere Betrachtung und es besteht ein Interesse an der stärkeren Auseinandersetzung mit dem Thema. Konkrete Projekte sind stellenweise bereits vorhanden und es wird branchenübergreifend bei der möglichen Adaption von neuen Erkenntnissen kooperiert. Bei einem Interviewpartner ist die Einführung eines Prozesses zur standardisierten Datenerfassung für die nahe Zukunft (in 12-15 Monaten) geplant. Die detaillierte Datenerfassung und Datenaufbereitung wird nach und nach über Pilotprojekte erfolgen (Zeitraum: <= 5 Jahre).

6 Beurteilung der Big Data-Reife der Branche

Zur Einschätzung der derzeitigen Reife der Immobilienbranche für einen Big Data-Einsatz wird sich wieder des Ansatzes des Reifegradmodells bedient. Dieses wird aus dem in Anhang 1 dargestellten, unter Berücksichtigung der Interviewaussagen noch zu verändernden, Modell vereinfacht abgeleitet. Die letztendliche Beurteilung der Reife erfolgt auf Grundlage des durch die Interviewpartner dargestellten Status Quo (5.4.2)²⁹⁵.

Interessant macht die Verwendung eines Reifegradmodelles der ihm zur Grundlage liegende kritische Entwicklungspfad, der ebenfalls dem in Anhang 1 dargestellten Modell innewohnt. Dieses Modell wurde im Rahmen der Ausarbeitung von Kapitel 3 entwickelt und beinhaltet deswegen nur die Erkenntnisse aus jenem Kapitel. Im weiteren Verlauf wird das Modell um folgende Erkenntnisse aus den Experteninterviews ergänzt: Zur Verwendung von Big Data in der Immobilienbranche müssen zunächst die relevanten Systeme und dort vorhandenen Rohdaten identifiziert werden. Im nächsten Schritt sind unternehmens- und ein-satzindividuelle Datenfilterkriterien (Smart Data Kriterien) zu entwickeln²⁹⁶. Anhand dieser Kriterien können die für das Einsatzszenario relevanten Daten erhoben (d.h. aus den Ursprungssystemen geladen), aggregiert und aufbereitet werden. Dazu sind individuell festgelegte Mindeststandards notwendig, die zur Schaffung einer Datentransparenz beitragen²⁹⁷. Die nun in einem aufbereiteten Zustand vorliegenden Daten werden für die Analyse in Form von Data Marts²⁹⁸ innerhalb der Smart Data Plattform zur Verfügung gestellt und nutzbar gemacht.

295 An dieser Stelle ist anzumerken, dass hier wiederum eine Zweckentfremdung des Ansatzes der Reifegradmodelle erfolgt, wie schon unter 2.3. Die hier bezweckte Verwendung eines Reifegradmodells ist nicht konform mit dem ursprünglichen Zweck der Modelle. Diesen soll es auch nicht erfüllen, sondern lediglich zur visuellen Einordnung des Marktes dienen.

296 Die genaue einheitliche Strukturierungslogiken für Daten vorgeben.

297 Darunter ist beispielsweise die Vereinheitlichung von verschiedenen Flächenmaßen zu verstehen. Dieser Standard kann wahlweise auch schon zu einem früheren Zeitpunkt ausgearbeitet und etabliert werden, wenn die Rohdaten bereits in einer Art Stammdatenmanagementsystem vorliegen.

298 Data Marts stellen einen Teilausschnitt der verfügbaren Daten dar. Vgl. Dorschel, 2015, S. 260. Durch diese Herangehensweise werden die Daten direkt aus dem Ursprungssystem geladen und es ist keine separate Datenbank notwendig, die andernfalls sämtliche Daten aus den Systemen beinhalten müsste.

Somit ergeben sich aus dem Big Data Datenbestand in Abhängigkeit vom jeweiligen Einsatzszenario für die Analyse relevanten Smart Data. Das finale Modell ist in Abbildung 12 dargestellt.

Das Modell lässt sich in fünf aufeinander aufbauende Bereiche zerlegen, die den späteren Reifestufen entsprechen²⁹⁹. Der erste Bereich umfasst die vorhandenen Rohdaten, die in den jeweiligen Systemen vorliegen. Ist ein Unternehmen oder eine Branche im Besitz solcher Rohdaten, kann die erste Reifestufe als erfüllt angesehen werden. Der zweite Bereich beinhaltet die Auseinandersetzung mit und das Vorhandensein von Smart Data-Kriterien, Einsatzszenarien und Standards zur Datenaufbereitung zum Aufbau einer Smart Data-Plattform für die Nutzung der Rohdaten aus Stufe 1. Die weiteren drei Bereiche umfassen die Teilbereiche der Data Analytics (3.3.7.3): Bereich 3 behandelt Daten, die mittels descriptive analytics ausgewertet werden, Bereich 4 umfasst predictive analytics und Bereich 5 prescriptive analytics. Unter der Hinzunahme einer Stufe 0, in der nicht einmal Daten vorhanden sind, ergibt sich folgendes Modell zur Beurteilung der Big Data Reife der Branche:



Abbildung 11: Modell zur Beurteilung der Big Data-Reife

²⁹⁹ Dadurch, dass die fünf Bereiche aufeinander aufbauen, weist das Modell einen kritischen Entwicklungspfad auf. Stufe 3 ist nur unter der Voraussetzung, dass Stufe 1 und 2 erfüllt sind, zu erreichen.

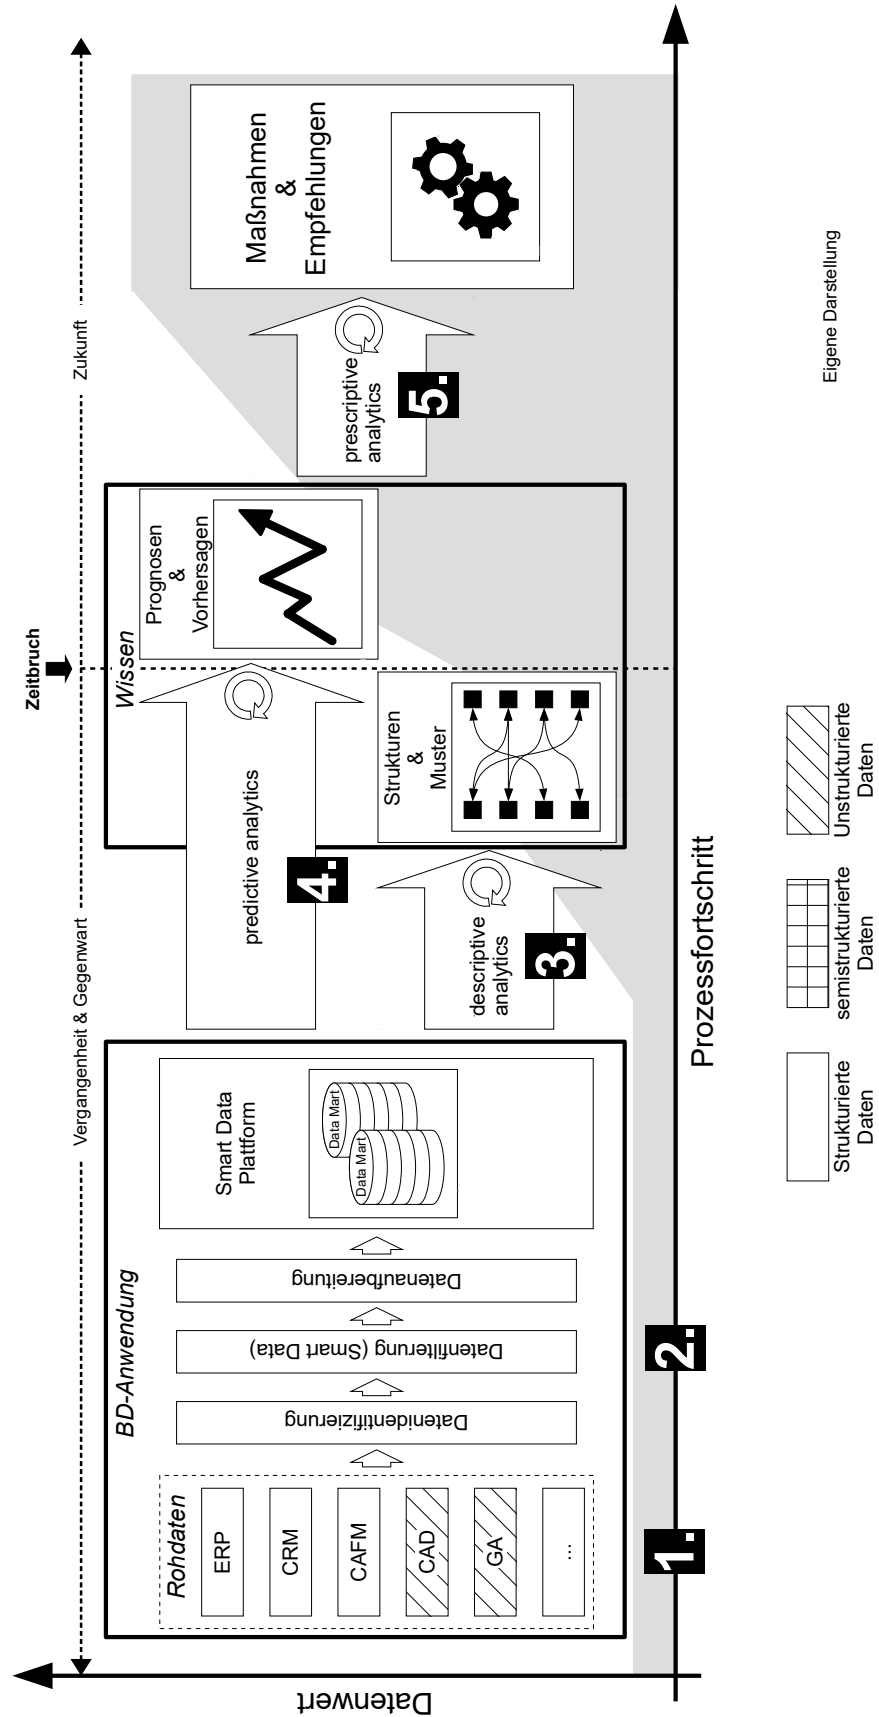


Abbildung 12: Angepasste Big Data-Anwendung inkl. der Reifegradstufen

Vor dem Hintergrund der Experteninterviews wird die Branche aktuell auf der Schwelle zu Stufe 2 einsortiert. Nach Aussage der Interviewpartner sind Rohdaten in teilweise großen Mengen vorhanden, sodass Stufe 0 übersprungen und Stufe 1 als erfüllt angesehen wird. Stufe 2, der Aufbau einer Smart Data Plattform, wird von der Branche nicht komplett erfüllt. Für die Interviewpartner sind zahlreiche Einsatzszenarien vorhanden. Dabei stellen alle unter 5.4.3 vorgestellten Szenarien Innovationen im Sinne der unter 2.3 erfolgten Definition dar. Jedes der Szenarien ist aber zum aktuellen Zeitpunkt, unter Berücksichtigung der Reife der Branche, nicht umsetzbar, da die Auseinandersetzungen mit Smart Data-Kriterien und Standards zur Datenaufbereitung gerade erst in den Anfängen steckt. Nach Aussage einiger Interviewpartner wird dies auch noch einige Zeit in Anspruch nehmen.

7 Überprüfung der Einhaltung der Gütekriterien qualitativer Forschung

Empirische Untersuchungen müssen sich an bestimmten Gütekriterien messen, damit diese als wissenschaftlich bezeichnet werden können³⁰⁰. Für die Messung werden in diesem Fall die von Mayring abgeleiteten folgenden sechs Gütekriterien für qualitative Forschungen herangezogen³⁰¹. Diese werden im weiteren Verlauf genauer vorgestellt und hinsichtlich ihrer Einhaltung überprüft.

(1) Verfahrensdokumentation:

Ohne die genaue Dokumentation des Vorgehens ist jedes Ergebnis wissenschaftlich wertlos³⁰². Damit der Forschungsablauf für Dritte nachvollziehbar wird, muss die gesamte Vorgehensweise inkl. der gewählten Methoden genau dokumentiert werden. Dies umfasst die Erklärung des Vorverständnisses, die Zusammenstellung des Analyseinstrumentariums und die Durchführung sowie Auswertung der Datenerhebung³⁰³.

Überprüfung der Einhaltung:

Im Rahmen der Vorstudie erfolgte die explorative Klärung des Phänomens Big Data. Der Forschungsablauf wurde detailliert dokumentiert und die verwendeten Methoden und Verfahrensweisen dargestellt, damit das Vorgehen für Dritte nachvollziehbar und transparent ist. Abschließend erfolgt die Zusammenfassung der Ergebnisse. Eine detailliertere Darstellung der Durchführung und Auswertung würde die Nachvollziehbarkeit noch weiter steigern.

300 Vgl. Hussy/Schreier/Echterhoff, 2013, S. 23.

301 Mayring, 2002, S. 144-148.

302 Vgl. ebenda.

303 Vgl. Hussy/Schreier/Echterhoff, 2013, S. 25; Mayring, 2002, S. 144 f.

(2) Argumentative Interpretationsabsicherung:

Die im Rahmen der Untersuchung getätigten Interpretationen spielen in qualitativ orientierten Forschung eine entscheidende Rolle und sind deshalb zu begründen, da sie nicht, wie Rechenoperationen, eindeutig reproduzierbar sind³⁰⁴.

Überprüfung der Einhaltung:

Die Transkripte der Interviews werden für Alternativdeutungen zur Verfügung gestellt³⁰⁵ und durch die umfangreiche Literaturrecherche und -aufarbeitung wurde ein adäquates Vorverständnis als Interpretationsgrundlage geschaffen.

(3) Regelgeleitetheit:

Das Vorgehen muss sich an bestimmte Verfahrensregel halten. „Trotz Offenheit gegenüber dem Untersuchungsgegenstand und der Bereitschaft, ggf. geplante Analyseschritte zu modifizieren, darf nicht ein völlig unsystematisches Vorgehen resultieren“³⁰⁶. Ohne die Beachtung von Regeln bleibt die qualitative Forschung wertlos³⁰⁷.

Überprüfung der Einhaltung:

Die Datenauswertung folgte einem vorher festgelegten, strukturiertem, einheitlichem Schema und den von Mayring vorgegebenen Analyseschritten (5.1). Die Qualität der Interpretationen wurde durch das sequenzielle Vorgehen abgesichert.

(4) Nähe zum Gegenstand:

Die Nähe zum Gegenstand beschreibt die möglichst nahe Anknüpfung an die Alltagswelt der beforschten Subjekte. Von großer Bedeutung ist dabei die Erreichung einer Interessenübereinstimmung zwischen Forscher und Beforschten

304 Vgl. Hussy/Schreier/Echterhoff, 2013, S. 25; Mayring, 2002, S. 145.

305 Siehe hierzu die Anmerkung in Fußnote 269.

306 Hussy/Schreier/Echterhoff, 2013, S. 25.

307 Mayring, 2002, S. 146.

Überprüfung der Einhaltung der Gütekriterien qualitativer Forschung

und ein offenes, gleichberechtigtes Verhältnis herzustellen. Durch die Annäherung der Interessen erreicht der Forschungsprozess die geforderte Nähe zum Gegenstand³⁰⁸.

Überprüfung der Einhaltung:

Durch die Abfrage des Verständnisses von Big Data und der Vorgabe einer Begriffsdefinition für den weiteren Verlauf des Interviews, die mit dem Verständnis der Befragten in den größten Teilen übereinstimmte, wurde eine Annäherung der Interessen geschaffen. Im Rahmen der ersten Kontaktaufnahme wurde darüber hinaus eine kurze Präsentation an die Interviewpartner versandt, die einen Einblick in das geplante Vorhaben gab³⁰⁹. Darüber hinaus verfolgen die Interviewpartner das selbe Bestreben wie diese Arbeit Innovationen für den Markt voran zu bringen und neue Technologie im Alltag einzusetzen und zu nutzen. Dennoch hätten weitere Maßnahmen ergriffen werden können um eine intensivere Interessenübereinstimmung zu erreichen.

(5) Kommunikative Validierung:

Im Rahmen der qualitativen Forschung werden die Interviewpartner nicht als Datenlieferanten gesehen, sondern als denkende Subjekte. Zur Überprüfung der Gültigkeit der Ergebnisse können sie den Interviewpartnern nochmals vorgelegt werden und wenn sie sich in den Ergebnissen wiederfinden, kann dies ein gutes Argument zur Absicherung der Ergebnisse sein.³¹⁰

Überprüfung der Einhaltung:

Nach erfolgter Transkription des Interviews (d.h. Datenaufnahme und Datenaufbereitung) wurde es den Interviewpartnern zur Überprüfung auf Vollständigkeit und Richtigkeit zur Verfügung gestellt. Die Validierung der Transkription erfolgte durch die Befragten. An dieser Stelle ist kritisch anzumerken, dass nicht überprüft werden konnte, ob die Interviewpartner das Transkript tatsächlich vollständig gelesen haben. Hierzu wäre beispielsweise ein Vor-Ort Besuch beim Inter-

308 Vgl. Mayring, 2002, S. 146.

309 Diese ist ebenfalls auf der beigefügten CD zu finden.

310 Vgl. Hussy/Schreier/Echterhoff, 2013, S. 25; Mayring, 2002, S. 147.

Überprüfung der Einhaltung der Gütekriterien qualitativer Forschung

viewpartner notwendig gewesen, bei dem er in Anwesenheit des Interviewers das Transkript hätten lesen und unterschreiben müssen. Der damit verbundenen zeitliche Aufwand wäre jedoch zu groß gewesen.

(6) Triangulation:

Unter Triangulation ist der Versuch zu verstehen „für die Fragestellung unterschiedliche Lösungswege zu finden und die Ergebnisse zu vergleichen“. Dabei können verschiedene Datenquellen, Interpreten, Methoden oder Theorieansätze hinzugezogen werden³¹¹.

Überprüfung der Einhaltung:

Im Rahmen der Auswahl der Interviewpartner wurde darauf geachtet einen thematisch möglichst breiten Pool an Interviewpartnern zu erreichen, die aus unterschiedlichen Fachdisziplinen der Immobilienbranche stammen um deren Sicht zur einer kaleidoskopartigen Betrachtung zusammenzufassen. Eine Hinzunahme weiterer Datenquellen zur Absicherung der Interviewaussagen oder die Kombination mit einer anschließend durchzuführenden quantitativen Studie hätten weitere Vergleichbarkeit geschaffen.

Insgesamt betrachtet wurden die Gütekriterien qualitativer Forschung nach Mayring größtenteils eingehalten.

311 Mayring, 2002, S. 147 f.

8 Zusammenfassung und Ausblick

8.1 Kritische Zusammenfassung der Untersuchungsergebnisse

Big Data stellt für die Immobilienbranche eine große Innovation dar. Prinzipiell entspricht das Big Data Verständnis der Interviewpartner dem der unter 3.3.1 dargestellten Definitionen. Der Mehrdimensionalität waren sich jedoch, viele von ihnen nicht bewusst. Ihr Fokus lag oftmals auf den charakterisierenden Vs (3.3.2) und den neu zu gewinnenden Erkenntnissen. Aspekte wie der nicht zu verachtende Datenschutz kamen stellenweise erst nach gezieltem Nachfragen zur Sprache, sodass an dieser Stelle noch deutlicher Sensibilisierungsbedarf im Markt unterstellt werden kann. Die Interviewpartner sehen das Phänomen Big Data in einer engen Verbindung mit der zunehmenden Digitalisierung der Welt und den aktuellen Entwicklungen hinsichtlich der Industrie 4.0. Aus ihr ergeben sich große Potentiale für die Branche, gerade auf operativer Ebene und den dort angelagerten Prozessen. Es können engere Verknüpfungen von Wertschöpfungsprozessen und Vertragspartner übergreifende Wertschöpfungsketten geschaffen werden. Die von den Interviewpartnern postulierte disruptive Wirkung auf die Branche sollte jedoch mit Vorsicht betrachtet werden. Ein Paradebeispiel für die Auswirkungen wäre die Sicherheitsbranche, die eine ebensolche Entwicklung bereits durchlebt hat: Früher war sie durch das notwendige Vor-Ort-Personal eine sehr personalintensive Dienstleistung, heute hat sich, durch die zunehmende Digitalisierung der Personalbedarf durch Überwachungskameras, Sensoren etc. erheblich reduziert und das Anforderungsbild der Beschäftigten geändert³¹². Ob ein solches Ausmaß auch für andere operative Prozesse im Immobilienbetrieb gilt, ist zum heutigen Zeitpunkt aber nicht vorhersehbar, da gerade der Faktor Mensch mit seinen Gewohnheiten und Vorlieben die große Unbekannte bleibt. Die persönliche Interaktion mit den Mitmenschen³¹³ und eine Art „Home-Base“ für den Mitarbeiter trägt in einem nicht zu verachtenden Maße zum Wohlbefinden bei und ist als Gegenpol zur zunehmenden Anonymisierung zu sehen, die durch Roboter und Automatisierungen erzeugt wird. Unbewusste Annahmen und Tendenzen bei den Interviewpartner

312 Siehe hierzu Interview BD3.

313 Stichwort Reinigungspersonal.

erwecken den Eindruck, dass Big Data als eine Art „All-Heilmittel“ gesehen wird, mit dem jegliche aktuell bestehenden Probleme „durch einem Klick“ lösbar werden. Ein ähnliches Hype-Phänomen, wenn auch nicht so ausgeprägt, ergab sich in der Vergangenheit durch das Aufkommen von BIM, dass in den frühen Stadien als die Problemlösung für alle im Planungsprozess bestehenden Herausforderungen und kommunikativen Probleme gesehen wurde. Die relativ nüchterne Erkenntnis, dass BIM ein ebensolches All-Heilmittel nicht darstellt benötigte ihre Zeit. So wird auch der Markt für Big Data Zeit benötigen um die für sich tatsächlichen Vorteile und damit zusammenhängenden Auswirkungen zu erkennen. Ein weiterer großer Punkt innerhalb der Branche ist die Datenlage, die aufgrund des historischen Wachstums vieler Firmen sehr heterogen und intransparent ist. Durch Big Data bietet sich nun eine Chance für die Branche, die lange nicht angegangene Situation zu verändern und zu verbessern. Davon werden nicht nur einzelne Unternehmen, sondern die ganze Branche profitieren. Die Unternehmen müssen sich im Big Data Zeitalter darüber klar werden, welche Daten in Zukunft benötigt werden welche Informationen in Zukunft aus den Daten gewonnen werden sollen. Dies stellt ein grundlegendes Problem dar: Wie soll man zum heutigen Zeitpunkt wissen, welche Daten in Zukunft benötigt werden? Es entsteht durch die Einführung von Big Data eine sich iterativ entwickelnde Kette: Auf der Grundlage von Mindeststandards, die den heutigen Bedürfnissen und Ansprüchen eines Unternehmens entspricht, wird eine Big Data Anwendung entwickelt. Durch ihren Einsatz werden wiederum neue Möglichkeiten aufgedeckt, die jedoch mit den ursprünglich festgelegten Mindeststandards nicht realisierbar sind. Um das neue Potential heben zu können müssen dafür die ursprünglichen Mindeststandards angepasst werden, die in einer neuen Big Data Anwendung resultieren, welche wiederum neue Möglichkeiten denkbar macht.

Dies macht eine schrittweise Entwicklung und Auseinandersetzung mit dem Thema notwendig. Dabei sollte die Entwicklung auf Seiten der Auftraggeber und auf Seiten der Auftragnehmer Hand in Hand gehen. Der maßgebliche Druck wird jedoch durch die Auftraggeber ausgeübt. Beispielsweise werden FM-Dienstleister, die sich diesem Druck nicht fügen einen Wettbewerbsnachteil er-

leiden, der schnell eine Marktveränderung bewirkt und somit die Marktsituation des Dienstleisters gefährden. Ein weiteres Problem stellt die Trägheit der Branche dar. Es wird lange dauern, bis ein Digitalisierungsniveau innerhalb der Branche erreicht ist, mit dem die unter 5.4.3 vorgestellten Szenarien Realität werden und Zukunftsvisionen, wie Smart-Citys in Gänze realisierbar sind.

8.2 Weitere Forschungsfelder

Die oben erfolgte Einschätzung des Marktes soll lediglich ein erstes Bild darüber liefern, wie umfangreich und zeitintensiv die weiteren Entwicklungen für die Branche sein werden. Big Data ist ein hochkomplexes Thema und bietet gerade innerhalb der Immobilienbranche noch weiteres Forschungspotential. So bietet sich der gerade durchgeführte erste Ansatz zur Einschätzung für eine detaillierte Ausarbeitung eines Reifegradmodells an, das weitere Informationen über die Ausprägung der Smart Data-Kriterien und Mindeststandards liefern könnte. Ebenfalls wird ein großer Bedarf an spezifischen Auswertungsalgorithmen durch die Interviewpartner gemeldet. Wie an einigen Stellen bereits angesprochen, müssen über kleinere Pilotprojekte oder branchenübergreifende Projekte erste kleinere Herausforderungen angegangen werden, indem beispielsweise Lösungen aus anderen Branchen im Immobilienbereich angewendet und erprobt werden.

Literaturverzeichnis

- Ajzen, I.; Madden, T. J.:** Prediction of Goal-Directed Behavior: Attitudes, Intentions, and Perceived Behavioral Control, *Journal of Experimental Social Psychology* 22, 1986, S. 453–474.
- Becker, Jörg; Knackstedt, Ralf; Pöppelbuß, Jens:** Dokumentationsqualität von Reifegradmodellentwicklungen, *Arbeitsberichte des Instituts für Wirtschaftsinformatik*, Arbeitsbericht Nr. 123, Münster, 2009.
- Behme, Wolfgang:** Business Intelligence als Baustein des Geschäftserfolgs, in: Muchsch, H.; Behme, W. (Hrsg.): *Das Data-Warehouse-Konzept-Architektur-Datenmodelle-Anwendungen*, Wiesbaden, 1996, S. 27-46.
- Behnke, Joachim; Behnke, Nathalie:** Grundlagen der statistischen Datenanalyse, Eine Einführung für Politikwissenschaftler, Wiesbaden, 2006.
- Beierle, Christoph; Kern-Isberner, Gabriele:** Methoden wissensbasierter Systeme, Grundlagen, Algorithmen, Anwendungen, in: Bibel, Wolfgang; Kruse, Rudolf; Nebel, Bernhard (Hrsg.): *Computational Intelligence*, Wiesbaden, 2014.
- Beyerle, Thomas; Müller, Leon:** Catella Research, Big Data in the Real Estate sector a big opportunity or a big threat?, Catella Research, Frankfurt, 2015, abrufbar unter URL: http://www.catella.com/PageFiles/44061/Catella_Research_Big_Data_%202015_en.pdf?epslanguage=en.
- BfDI, Die Bundesbeauftragte für den Datenschutz und die Informationsfreiheit:** Was ist Datenschutz?, o.J., abgerufen unter URL: <https://www.bfdi.bund.de/DE/Datenschutz/datenschutz-node.html> am 27.04.2017.
- Bodendorf, Freimut:** Daten- und Wissensmanagement, Berlin; Heidelberg, 2006.
- Bohne, Dirk:** Technischer Ausbau von Gebäuden, Und nachhaltige Gebäude technik, Wiesbaden, 2014.

BSI (Bundesamt für Sicherheit in der Informationstechnik) Online Glossar und Begriffdefinitionen: Integrität, o.J., abgerufen unter URL: https://www.bsi.bund.de/DE/Themen/ITGrundschutz/ITGrundschutzKataloge/Inhalt/Glossar/glossar_node.html am 27.04.2017.

Bundestagsdrucksache 4/270: Entwurf eines Gesetzes über Urheberrecht und verwandte Schutzrechte (Urheberrechtsgesetz), vom 23. März 1962, abrufbar unter URL: <http://dipbt.bundestag.de/doc/btd/04/002/0400270.pdf>.

Cavanillas, José María; Curry, Edward; Wahlster, Wolfgang: New Horizons for a Data-Driven Economy, A Roadmap for Usage and Exploitation of Big Data in Europe, als open access Dokument elektronisch veröffentlicht unter URL: www.springerlink.com, 2016.

Chen, C.L. Philip; Zhang, Chun-Yang: Data-intensive applications, challenges, techniques and technologies: A survey on Big Data, als open access Dokument elektronisch veröffentlicht in: Pedrycz W. (editor-in-chief): Information Sciences, Ausgabe 275, Edmonton, Canada, 2014, S. 314–347, abrufbar unter URL: <http://www.sciencedirect.com/science/journal/00200255/>.

Cordon, Carlos; Garcia-Milà, Pau; Ferreiro Vilarino, Teresa; Caballero, Pablo: Strategy is Digital, How Companies Can Use Big Data in the Value Chain, Switzerland, 2016.

Cramer, Erhard; Udo Kamps: Grundlagen der Wahrscheinlichkeitsrechnung und Statistik, Ein Skript für Studierende der Informatik, der Ingenieur- und Wirtschaftswissenschaften, Berlin; Heidelberg, 2014.

Delen, Dursun; Demirkan, Haluk: Data, information and analytics as services, als open access Dokument elektronisch veröffentlicht in: Marsden, James R. (editor-in-chief); Whinston, Andrew B. (Emeritus Editor-in-chief); Whinston, Veronika (Emeritus Managing Editor): Decision Support Systems, Volume 55, Issue 1, 2013, S. 359–363, abrufbar unter URL: <http://www.sciencedirect.com/science/journal/01679236>.

- DIN EN 15221-1:** Deutsches Institut für Normung e.V., Facility Management, Begriffe, Deutsche Fassung, Berlin, 2007.
- Dorschel, Joachim:** Praxishandbuch Big Data, Wirtschaft - Recht - Technik, Wiesbaden, 2015.
- Döring, Nicola; Bortz, Jürgen:** Forschungsmethoden und Evaluation in den Sozial- und Humanwissenschaften, Berlin; Heidelberg, 2016.
- Duisberg, Alexander:** Gelöste und ungelöste Rechtsfragen im IT-Outsourcing und Cloud Computing, in: Picot, A.; Hertz, U.; Götz, T. (Hrsg.): Trust in IT – Wann vertrauen Sie ihr Geschäft der Internet-Cloud an?, Berlin, 2011, S. 9–70.
- DWDS (Etymologisches Wörterbuch): Statistik,** in: Digitales Wörterbuch der deutschen Sprache (DWDS), Etymologisches Wörterbuch, Pfeifer, Wolfgang, o.J., URL: <https://www.dwds.de/wb/Statistik>, abgerufen am 24.04.2017.
- DWDS (Wörterbuch der deutschen Gegenwartssprache, WDG, 1976): Statistik,** in: Digitales Wörterbuch der deutschen Sprache (DWDS), Wörterbuch der deutschen Gegenwartssprache (WDG), 1976, URL: <https://www.dwds.de/wb/Statistik>, abgerufen am 24.04.2017.
- Eckey, Hans-Friedrich; Kosfeld, Reinhold; Türck, Matthias:** Deskriptive Statistik, Grundlage - Methoden - Beispiele, Wiesbaden, 2008.
- Eckey, Hans-Friedrich; Kosfeld, Reinhold; Türck, Matthias:** Wahrscheinlichkeitsrechnung und Induktive Statistik, Grundlage - Methoden - Beispiele, Wiesbaden, 2005.
- Ester, Martin; Sander, Jörg:** Knowledge Discovery in Databases, Techniken und Anwendungen, Berlin; Heidelberg, 2000.
- Fahrmeir, Ludwig; Heumann, Christian; Künstler, Rita; Pigeot, Iris; Tutz, Gerhard:** Statistik, Der Weg zur Datenanalyse, Berlin; Heidelberg, 2016.
- Fasel, Daniel:** Big Data, Eine Einführung, in: HMD Praxis der Wirtschaftsinformatik, Ausgabe 51, Wiesbaden, 2014, S. 386-400.

- Fasel, Daniel; Meier, Andreas:** Was versteht man unter Big Data und NoSQL?, in: Fasel, Daniel; Meier, Andreas (Hrsg.): Big Data: Grundlagen, Systeme und Nutzungspotenziale, Wiesbaden, 2016, S.3-16.
- Fayyad, Usama M.:** Advances in Knowledge Discovery and Data Mining, Menlo Park, 1996.
- Fox, Stephen; Do Tuan:** Getting real about Big Data: applying critical realism to analyse Big Data hype, elektronisch veröffentlicht in: International Journal of Managing Projects in Business, Vol. 6 Issue 4, 2013, S.739 - 760, abrufbar unter Emerald Insight URL: <http://dx.doi.org/10.1108/IJMPB-08-2012-0049>.
- Franks, Bill:** Taming the Big Data tidal wave, Finding opportunities in huge data streams with advanced analytics, Hoboken; New Jersey, 2012.
- Furht, Borko; Villanustre, Flavio:** Big Data Technologies and Applications, Switzerland, 2016.
- Gabler Wirtschaftslexikon, Stichwort: Enterprise-Resource-Planning-System:** Springer Gabler Verlag (Hrsg.): o.J., abgerufen unter URL: <http://wirtschaftslexikon.gabler.de/Archiv/17984/enterprise-resource-planning-system-v12.html> am 26.04.2017.
- Gabler Wirtschaftslexikon, Stichwort: Wearables:** Springer Gabler Verlag (Hrsg.): o.J., abgerufen unter URL: <http://wirtschaftslexikon.gabler.de/Archiv/-2046631402/wearable-v4.html> am 01.06.2017.
- Gartner IT Glossary: Big Data:** Gartner, Inc. (Hrsg.): o.J. abgerufen unter URL: <http://www.gartner.com/it-glossary/big-data/> am 25.04.2017.
- GEFMA 100-1:** German Facility Management Association e.V., Facility Management Grundlagen, Bonn, 2004.
- GEFMA 190:** German Facility Management Association e.V., Betreiberverantwortung im Facility Management, Bonn, 2004.

- GEFMA 400:** German Facility Management Association e.V., Computer Aided Facility Management CAFM Begriffsbestimmungen, Leistungsmerkmale, Bonn, 2013.
- Gesellschaft für immobilienwirtschaftliche Forschung (gif):** gif e.V. - Arbeitskreis Real Estate Investment Management, Gig-Wiki: Wertänderungsrendite, o.J., abgerufen unter URL: <http://www.gif-wiki.de/w/Wertänderungsrendite> am 26.04.2017.
- Gluchowski, Peter:** Empirische Ergebnisse zu Big Data, in: HMD Praxis der Wirtschaftsinformatik, Ausgabe 51, Wiesbaden, 2014, S. 401-411.
- Golabchi, Alireza; Akula, Manu; Kamat, Vineet:** Automated building information modeling for fault detection and diagnostics in commercial HVAC systems, elektronisch veröffentlicht in: Facilities, Vol. 34 Issue 3/4, 2016, S. 233-246, abrufbar unter Emerald Insight URL: <http://dx.doi.org/10.1108/F-06-2014-0050>.
- Hanning, Uwe:** Vom Data Warehouse zum Corporate Performance Management, Ludwigshafen, 2008.
- Helmke, Stefan; Uebel, Matthias; Dangelmaier, Wilhelm:** Grundlagen und Ziele des CRM-Ansatzes, in: Helmke, Stefan; Uebel, Matthias; Dangelmaier, Wilhelm (Hrsg.): Effektives Customer Relationship Management, Instrumente – Einführungskonzepte – Organisation, Wiesbaden, 2017, S. 3-22.
- Henze, Norbert:** Stochastik für Einsteiger, Eine Einführung in die faszinierende Welt des Zufalls, Wiesbaden, 2017.
- Heuberger-Götsch, Olivier:** Der Wert von Daten aus juristischer Sicht am Beispiel des Profiling, in: Fasel, Daniel; Meier, Andres (Hrsg.): Big Data: Grundlagen, Systeme und Nutzungspotenziale, Wiesbaden, 2016, S.83-106.
- Holland, Heinrich; Scharnbacher, Kurt:** Grundlagen der Statistik, Datenerfassung und -darstellung, Maßzahlen, Indexzahlen, Zeitreihenanalyse, Wiesbaden, 2010.

- Horn, Dennis:** Hat wirklich der große Big-Data-Zauber Trump zum Präsidenten gemacht?, 2016, elektronisch veröffentlicht unter URL: <https://blog.wdr.de/digitalistan/hat-wirklich-der-groesse-big-data-zauber-trump-zum-praesidenten-gemacht/> abgerufen am 01.06.2017.
- Hussy, Walter; Schreiber, Margrit; Echerhoff, Gerald:** Forschungsmethoden in Psychologie und Sozialwissenschaften, Berlin; Heidelberg, 2013.
- Inmon, William H.:** Building the data warehouse, New York, 1996.
- Jensen, Per Anker; van der Voordt, Theo; Coenen, Christian:** Background and Introduction, in: Centre for Facilities Management, TU Denmark, Polyteknisk Forlag: The added value of Facilities Management – Concepts, Findings and Perspectives, 2012, S. 14-30.
- King, Stefanie:** Big Data, Potential und Barrieren der Nutzung im Unternehmenskontext, Wiesbaden, 2014.
- Koch, Stefan; May, Michael; Schlauer, Alwin:** CAFM-Software und CAFM-Systeme, in: May, Michael (Hrsg.): CAFM-Handbuch, IT im Facility Management erfolgreich einsetzen, Berlin; Heidelberg, 2013, S. 251-268.
- Kroes, N.:** Big data for Europe – ICT 2013 Event – Session on Innovating by exploiting big and open data and digital content, Vilnius, 2013, abrufbar unter URL: http://europa.eu/rapid/press-release_SPEECH-13-893_en.htm#content.
- Kumar Sharma, Rajiv; Kumar, Dinesh; Kumar, Pradeep:** Manufacturing excellence through TPM implementation: a practical analysis, elektronisch veröffentlicht in: Industrial Management & Data Systems, Vol. 106 No. 2, S. 256-280, abrufbar unter Emerald Insight URL: <http://dx.doi.org/10.1108/02635570610649899>.
- Kurzrock, Björn-Martin:** Einflussfaktoren auf die Performance von Immobilien-Direktanlagen, in: Rottke, Nico B.; Mutl, Jan (Hrsg.): Essays in Real Estate Research, Band 2, Wiesbaden, 2016.
- Lamnek, Siegfried:** Qualitative Sozialforschung – Lehrbuch, Weinheim; Basel, 2005.

- Langley, Pat:** Elements of machine learning, San Francisco, 1996.
- Laughman, Casey:** Cover Story, Darrell Smith Profile (Microsoft), elektronisch veröffentlicht in: building operating management, Issue September 2013, abrufbar unter URL: <http://www.facilitiesnet.com/energyefficiency/article/Microsoft-Uses-Fault-Detection-And-Diagnostics-To-Transform-Facilities-Management---14358?source=part>.
- Lomotey, Richard K.; Deters, Ralph:** Unstructured Data, NoSQL, and Terms Analytics, in: Hung, Patrick C.K. (Hrsg.): Big Data Applications and Use Cases, International Series on Computer Entertainment and Media Technology, Switzerland, 2016, S. 109-143.
- Manyika, James; Chui, Michael; Brown, Brad; Bughin, Jacques; Dobbs, Richard; Roxburgh, Charles; Hung Byers, Angela:** Big data: The next frontier for innovation, competition, and productivity, Technical Report, McKinsey Global Institute, 2011.
- Mayring, Philipp:** Einführung in die qualitative Sozialforschung, Weinheim; Basel, 2002.
- Mazumder, Sourav:** Big Data Tools and Platforms, in: Yu, Shui; Guo, Song (Editors): Big Data Concepts, Theories, and Applications, Switzerland, 2016, S. 29-128.
- McAfee, Andrew; Brynjolfsson, Erik:** Big Data: The Management Revolution, in: Harvard Business Review, October, 2012, S. 60-68.
- Meier, Andreas; Kaufmann, Michael:** SQL- & NoSql-Datenbanken, in: examen.press, Berlin; Heidelberg, 2016.
- Mell, Peter; Grance, Timothy:** The NIST definition of cloud computing., Recommendations of the National Institute of Standards and Technology, U.S. Department of Commerce, National Institute of Standards and Technology (NIST), Special Publication 800-145, Gaithersburg, 2011, abrufbar unter URL: <http://nvlpubs.nist.gov/nistpubs/Legacy/SP/nistspecialpublication800-145.pdf>.

- Merz, Hermann; Hansemann, Thomas; Hübner, Christof:** Gebäudeautomati on, Kommunikationssysteme mit EIB/KNX, LON und BACnet, München, 2010.
- Morabito, Vincenzo:** Big Data and Analytics, Strategic and Organizational Im pacts, Switzerland, 2015.
- Morgenroth, Markus; Mansmann, Urs; Schulzki-Haddouti, Christiane; Hei drich, Joerg:** Digital gebrandmarkt, in c't Magazin für Computer Technik. 2016, Ausgabe 1/17, S. 64-79.
- Müller, Stefan:** Erweiterung des Data Warehouse um Hadoop, NoSQL & Co, in: Fasel, Daniel; Meier, Andreas (Hrsg.): Big Data: Grundlagen, Systeme und Nutzungspotenziale, Wiesbaden, 2016, S.139-158.
- Nävy, Jens:** Facility Management, Berlin; Heidelberg, 1998.
- Nilsson, Nils J.:** Introduction to machine learning, An early draft of a proposed textbook, Stanford University, 2005.
- Olshannikova, Ekaterina; Ometov, Aleksandr; Koucheryavy, Yevgeni; Ols son, Thomas:** Visualizing Big Data with augmented and virtual reality: challenges and research agenda, in: Furht, Borko; Khoshgoftaar, Taghi (Editors-in-Chief): Journal of Big Data, Vol. 2, No. 22, 2015.
- Opic, Marko; Hohmann Joachim; Maier, Alexander; Schauer, Alwin; Schlundt Maik:** Anwendungsfelder für den IT-Einsatz im FM, in: May, Michael (Hrsg.): CAFM-Handbuch, IT im Facility Management erfolgreich einsetzen, Berlin; Heidelberg, 2013, S. 45-68.
- Pettey, Christy; Goasduff, Laurence:** Gartner Says Solving 'Big Data' Chal lenge involves More Than Just Managing Volumes of Data, Gartner Special Report Examines How to Leverage Pattern-Based Strategy to Gain Value in Big Data, Gartner Newsroom, Press Release, STAM FORD, Conn., June 27, 2011 abgerufen unter URL: <http://www.gartner.com/newsroom/id/1731916> am 26.04.2017.
- Pfnür, Andreas:** Modernes Immobilienmanagement, Facility-Management und Corporate-Real-Estate-Management, Berlin; Heidelberg, 2002.

- Pfnür, Andreas:** Modernes Immobilienmanagement, Immobilieninvestment, Immobilienutzung, Immobilienentwicklung und -betrieb, Berlin; Heidelberg, 2011.
- Porter, Michael E.:** Wettbewerbsvorteile – Spitzenleistungen erreichen und behaupten, Frankfurt am Main, 2010.
- Rafferty William, Rafferty Laura, Hung Patrick C.K.:** Introduction to Big Data, in: Hung, Patrick C.K. (Hrsg.): Big Data Applications and Use Cases, International Series on Computer Entertainment and Media Technology, Switzerland, 2016, S. 1-15.
- Schaffranietz Klaus; Neumann, Fritz:** Wissensgenerierung aus Datenbanken, in: Keuper, Frank; Neumann, Fritz (Hrsg.): Wissens- und Informationsmanagement: Strategien, Organisation und Prozesse, Wiesbaden, 2009, S. 149-177.
- Schauer, Alwin; Görze, Rita; Hinke, Reiko; Kalweit, Thomas; Koch, Stefan; Ranglack, Dirk:** Integrationstechnologien im CAFM, in: May, Michael (Hrsg.): CAFM-Handbuch, IT im Facility Management erfolgreich einsetzen, Berlin; Heidelberg, 2013, S. 269-300.
- Schön, Dietmar:** Planung und Reporting, Grundlagen, Business Intelligence, Mobile BI and Big-Data-Analytics, Wiesbaden, 2016.
- Schulte, Karl-Werner; Schäfers, Wolfgang:** Handbuch Corporate Real Estate Management, Köln, 2004.
- Schulzki-Haddouti, Christiane:** Der schillernde Ruf nach dem Dateneigentum, Big Data: "Datensouveränität" oder auch "Dateneigentum", so lauten die neuen Buzzwords, deren rechtliche Definition aber noch völlig ungeklärt ist, in: VDI Nachrichten Technik Wirtschaft Gesellschaft, Nr. 7, 17.02.2017, S. 6.
- Seufert, Andreas:** Das Controlling als Business Partner, Business Intelligence & Big Data als zentrales Aufgabenfeld, in: Gleich, R.; Klein, A. ; Kirchmann, M.; Leyk, J. (Hrsg.): Der Controlling-Berater: Controlling und Big Data, Band 35, Freiburg, 2014a, S. 23-45.

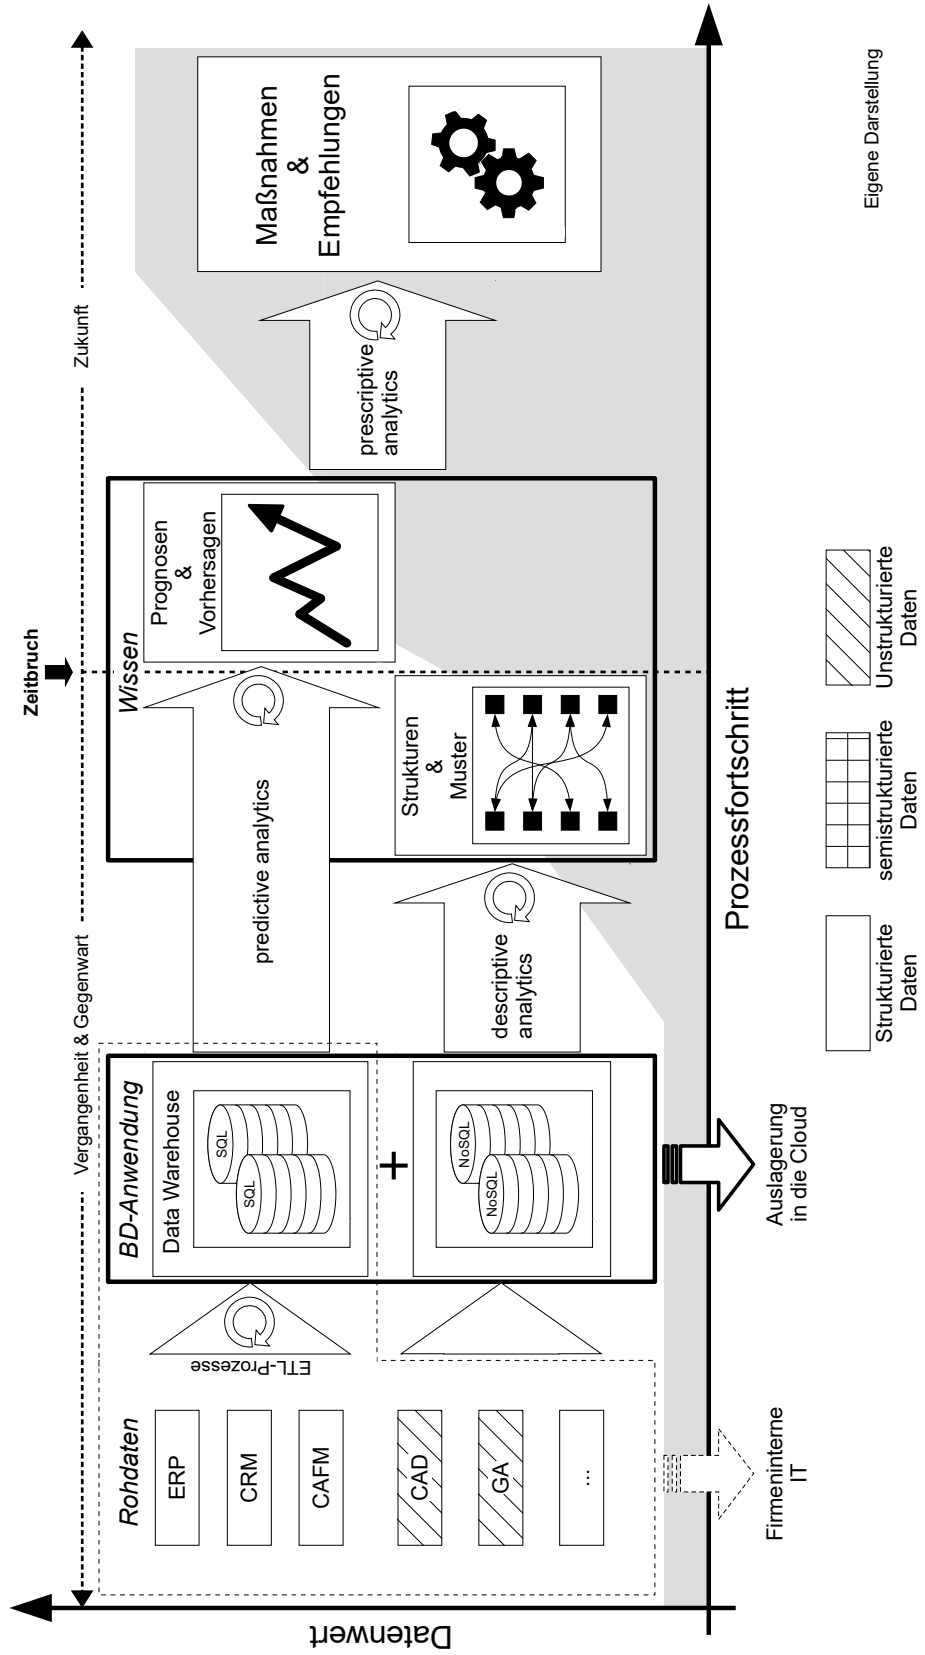
- Seufert, Andreas:** Entwicklungsstand, Potentiale und zukünftige Herausforderungen von Big Data – Ergebnisse einer empirischen Studie, in: HMD Praxis der Wirtschaftsinformatik, Ausgabe 51, Wiesbaden, 2014b, S. 412-423
- Siems, Dorothea:** Der schleichende Abstieg des Standorts Deutschland, 2017, elektronisch veröffentlicht unter URL: <https://www.welt.de/wirtschaft/article165132931/Der-schleichende-Abstieg-des-Standorts-Deutschland.html>, abgerufen am 01.06.2017.
- Simon, Phil:** The visual organization: data visualization, Big Data, and the quest for better decisions, Hoboken, New Jersey, 2014.
- Sun, Daoyuan; Du, Yudie; Xu, Wei; Zuo, Mei Yun; Zhang, Ce; Zhou, Junjie:** Combining Online News Articles and Web Search to Predict the Fluctuation of Real Estate Market in Big Data Context, elektronisch veröffentlicht in: Pacific Asia Journal of the Association for Information Systems, Vol. 6, Iss. 4, Article 2, abrufbar unter URL: <http://aisel.aisnet.org/pajais/vol6/iss4/2>.
- Teichmann, Sven:** Bestimmung und Abgrenzung von Managementdisziplinen im Kontext des Immobilien-und Facilities Managements, in: Zeitschrift für Immobilienökonomie, Ausgabe 2/2007, 2007, abrufbar unter URL: http://www.uni-potsdam.de/strohe-statoek/documents/paper/ZIO2_2007.pdf
- Tiemeyer, Ernst:** Handbuch IT-Systemmanagement, Handlungsfelder, Prozesse, Managementinstrumente, Good-Practices, München, 2016.
- Tsai, Chun-Wie; Lai, Chin-Feng; Chao, Han-Chieh; Vasilakos, Athanasios V.:** Big data analytics: a survey, in: Furht, Borko; Khoshgoftaar, Taghi (Editors-in-Chief): Journal of Big Data, Vol. 2, No. 21, 2015.
- Uotila, Varpu; Skogster, Patrik:** Space management in a DIY store analysing consumer shopping paths with data-tracking devices, elektronisch veröffentlicht in: Facilities, Vol. 25 Issue 9/10, 2007, S. 363-374, abrufbar unter Emerald Insight URL: <http://dx.doi.org/10.1108/02632770710772469>.

- Vajna, Sandor; Weber, Christian; Bley, Helmut; Zeman, Klaus; Hehenberger, Peter:** Cax für Ingenieure, Eine praxisbezogene Einführung, Berlin; Heidelberg, 2009.
- Vargas-Solar, Genoveva; Espinosa-Oviedo, Javier A.; Zechinelli-Martini, José Luis:** Big Continuous Data: Dealing with Velocity by Composing Event Streams, in: Yu, Shui; Guo, Song (Editors): Big Data Concepts, Theories, and Applications, Switzerland, 2016, S. 1-28.
- VDI 3814 Blatt 1-5:** VDI Verein Deutscher Ingenieure e.V., Düsseldorf, 2005.
- Ward, Jonathan Stuart; Barker, Adam:** Undefined By Data: A Survey of Big Data Definitions, School of Computer Science, University of St Andrews, UK, Cornell University Library, 2013, abrufbar unter URL: <https://arxiv.org/abs/1309.5821>.
- Wendlinger, Peter:** Immobilienkennzahlen, Fundierte Immobilienanalyse in der Praxis, Wien, 2012.
- Yin, Robert K.:** Case Study Research, Design and Methods, Thousand Oaks, CA, USA et al., 2009.

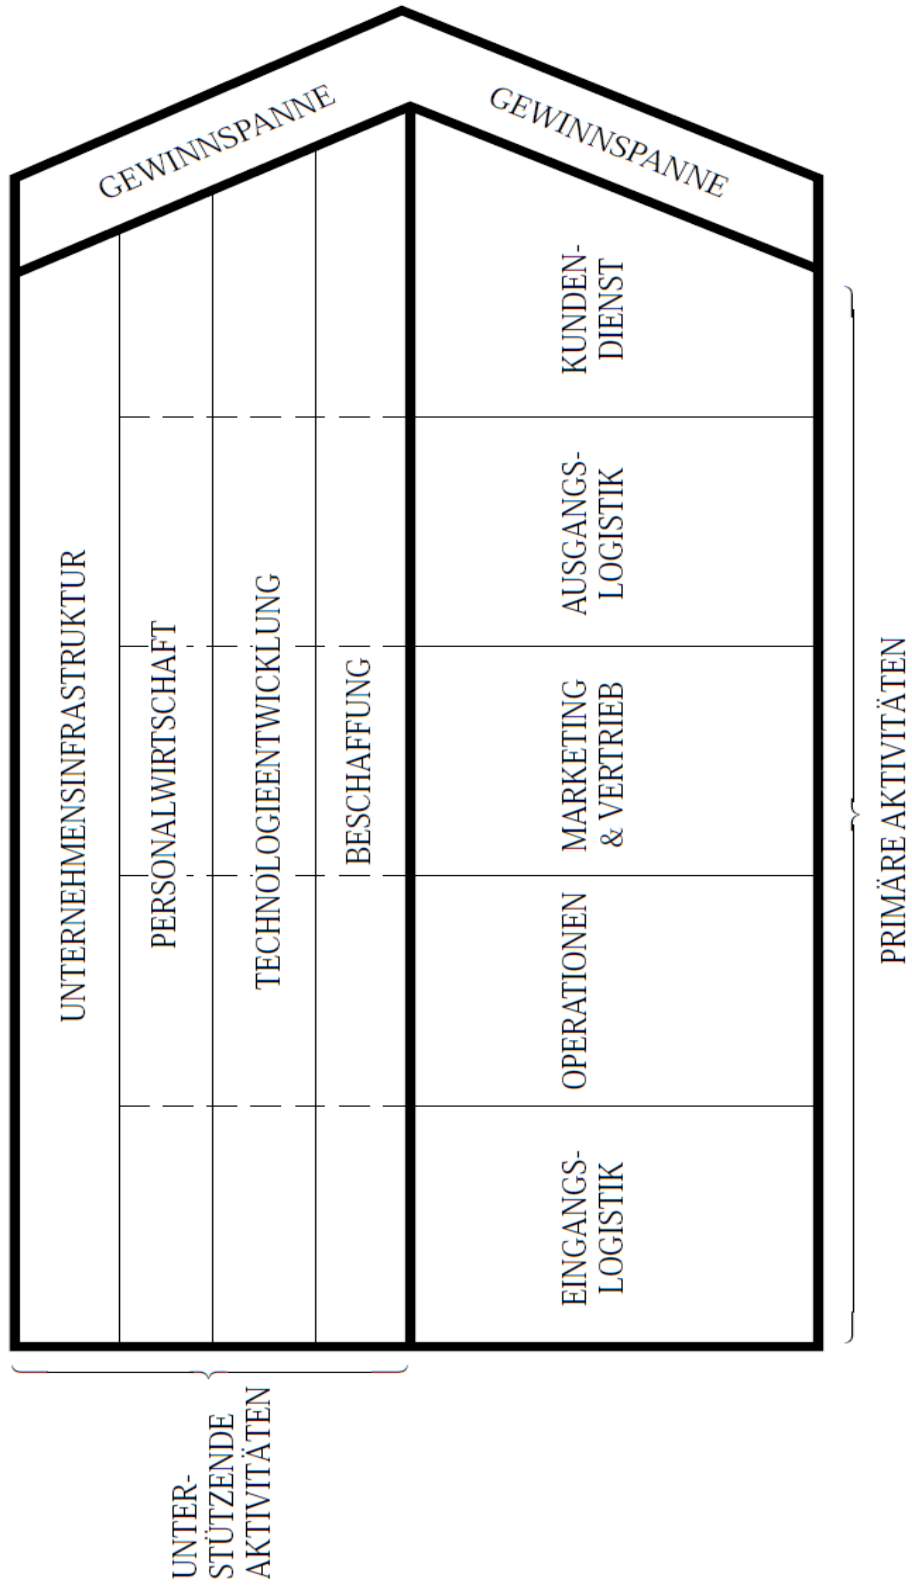
Anhang

Anhang 1: Big Data-Anwendung (Kapitel 3).....	XIX
Anhang 2: Portersche Wertschöpfungskette.....	XX
Anhang 3: Übersicht der Managementdisziplinen im Immobilienbereich	XXI

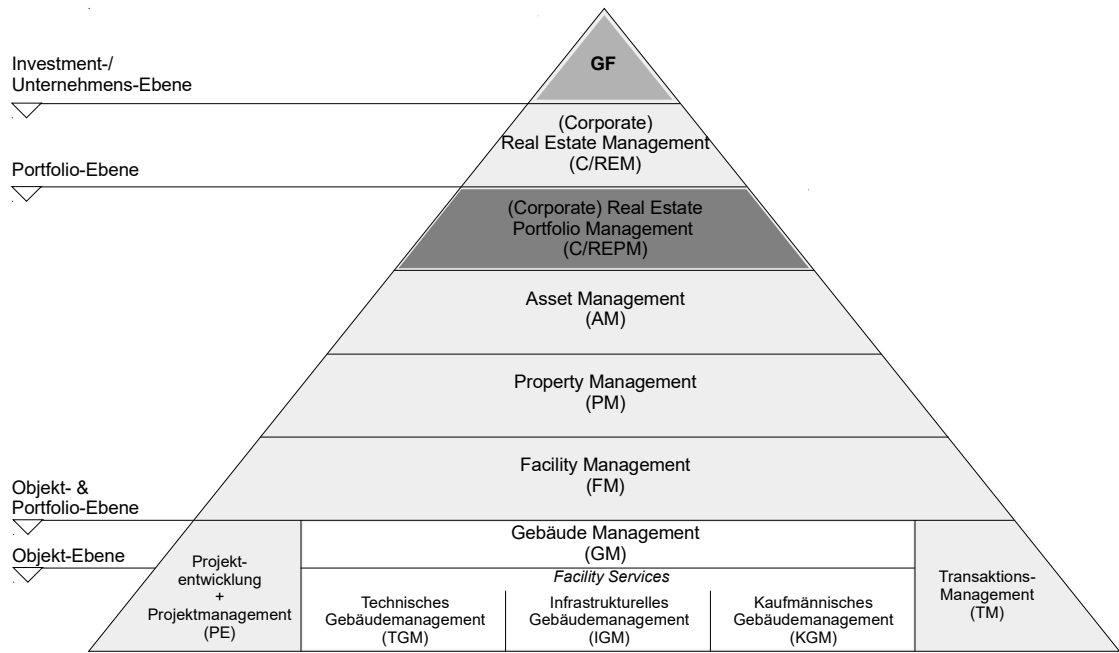
Anhang 1: Big Data-Anwendung (Kapitel 3)



Anhang 2: Portersche Wertschöpfungskette



Anhang 3: Übersicht der Managementdisziplinen im Immobilienbereich



Eigene Darstellung, in Anlehnung an: Teichmann, 2007, S. 9/15.

Erklärung

Ich versichere, dass ich die vorliegende Arbeit selbstständig angefertigt und keine anderen als die angegebenen Hilfsmittel und Quellen verwendet habe. Die eingereichte Arbeit habe ich in gleicher oder ähnlicher Form noch keinem anderen Prüfungsausschuss vorgelegt.

Münster, 02.06.17

.....

Unterschrift