KPI Intelligence.

Eine Methode für die Digitale Unternehmenssteuerung mittels
quantitativer Analyse von Kennzahlenrelationen
am Beispiel der Automobilindustrie.

Von der Wirtschaftswissenschaftlichen Fakultät
der Universität Leipzig
genehmigte

DISSERTATION

zur Erlangung des akademischen Grades

Doktor-Ingenieur

Dr.-Ing.

vorgelegt

von Daniel Burdensky, M. Sc.

geboren am 07.12.1989 in Berlin

Gutachter: Prof. Dr. Rainer Alt

Prof. Dr. Carsten Felden

Tag der Verleihung: 14.12.2022

Selbstständigkeitserklärung

Hiermit erkläre ich, die vorliegende Dissertation selbständig und ohne unzulässige fremde Hilfe, insbesondere ohne die Hilfe eines Promotionsberaters, angefertigt zu haben. Ich habe keine anderen als die angeführten Quellen und Hilfsmittel benutzt und sämtliche Textstellen, die wörtlich oder sinngemäß aus veröffentlichten oder unveröffentlichten Schriften entnommen wurden, und alle Angaben, die auf mündlichen Auskünften beruhen, als solche kenntlich gemacht. Ebenfalls sind alle von anderen Personen bereitgestellten Materialien oder erbrachten Dienstleistungen als solche gekennzeichnet.

Des Weiteren ist die vorgelegte Dissertation weder im Inland noch im Ausland in gleicher oder ähnlicher Form einer anderen Prüfungsbehörde zum Zwecke der Promotion oder eines anderen Prüfungsverfahrens vorgelegt und insgesamt noch nicht veröffentlicht worden.

München, 26.01.2022 ……

(Unterschrift)

Bibliographische Beschreibung

Burdensky, Daniel

KPI Intelligence.
Eine Methode für die Digitale Unternehmenssteuerung mittels quantitativer Analyse von Kennzahlenrelationen am Beispiel der Automobilindustrie.

Universität Leipzig, Dissertation

S. 227, 252 Lit., 52 Abb., 20 Tabellen

Referat:

Zur Steuerung großer Produktionsunternehmen muss das Management Alternativen bewerten, fundierte Entscheidungen herbeiführen und Maßnahmen zur Prozesssteuerung ergreifen. Jedoch macht die Komplexität der Ursache-Wirkbeziehungen zwischen den Kennzahlen, die zur Steuerung der interdependenten Geschäftsprozesse dienen, eine Abschätzung der Auswirkungen von Maßnahmen für den Menschen ohne Hilfsmittel nahezu unmöglich.

Die vorliegende Dissertation liefert daher Ansätze für die Weiterentwicklung der klassischen kennzahlenbasierten Unternehmenssteuerung durch die Einbeziehung von Advanced Analytics Algorithmik für die Analyse von Prozessinterdependenzen. Damit begegnet sie der identifizierten Lücke einer unzureichenden Integration von Advanced Analytics in die praktische Prozesssteuerung.

Die entwickelte Methode beinhaltet eine Vorgehensweise und Prozessmodelle für die quantitative Analyse der Interdependenzen. Zudem bietet sie Vorschläge für den komplementären und komparativen Einsatz fortgeschrittener Analysealgorithmik. Zur Beurteilung der Eignung der jeweiligen Lösung dienen Leitmerkmale, welche die Bedürfnisse von Anwendern repräsentieren. Die Analyseergebnisse sind schließlich auf ihren Beitrag zu den in der Dissertation erarbeiteten Anforderungen an die kennzahlenbasierte Unternehmenssteuerung zu prüfen. Die Entwicklung und Evaluierung der Methode erfolgt im Rahmen einer Fallstudie mit mehreren heterogenen Anwendungsfällen bei einem OEM der Automobilindustrie.

Die Forschungsergebnisse tragen dazu bei, die Vielzahl digitaler Lösungen zur Visualisierung von Daten mit dem größer werdenden Angebot an fortgeschrittenen Analysemöglichkeiten zur Unterstützung kennzahlenbasierter Managementprozesse zusammenzuführen. Dem Grundgedanken der Kybernetik folgend, ermöglicht die Methode Fachanwendern die selbständige quantitative Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen innerhalb einzelner Prozesse sowie prozess- und hierarchieübergreifend. Die Interpretation der Ergebnisse dient sodann der Ergänzung von deren implizitem Wissen und folglich einer effektiveren und effizienteren Prozesssteuerung.

Vorwort

Die vorliegende Dissertation entstand im Rahmen meiner Teilnahme an dem Doktorandenprogramm „ProMotion“ der BMW Group in enger Zusammenarbeit mit dem Institut für Wirtschaftsinformatik der Universität Leipzig. Diese Konstellation ermöglichte praxisrelevante Forschungsarbeit und die kontinuierliche Validierung und Weiterentwicklung der Beiträge. Eine teilweise Veröffentlichung der Ergebnisse erfolgte im Rahmen von Vorträgen und schriftlichen Publikationen. Diese sind im Detail dem Abschnitt Veröffentlichungen / Vorträge zu entnehmen.

Ein vielfältiges Team aus Kolleginnen und Kollegen sowie meiner Familie, Freundinnen und Freunden hat mein Dissertationsprojekt begleitet und gestärkt. Aus Gründen der Lesbarkeit der Arbeit wird darauf verzichtet, konsequent die männliche und weibliche Formulierung zu verwenden. Sämtliche personenbezogenen Bezeichnungen sind geschlechtsneutral zu verstehen.

Danken möchte ich meinem Doktorvater Herrn Prof. Dr. Rainer Alt, dessen engagierte wissenschaftliche Betreuung meine Forschung möglich gemacht hat. Durch seine Ratschläge, inhaltliches Feedback und konstruktive Kritik trug er maßgeblich zur Weiterentwicklung meiner Arbeit bei. Ebenso danke ich meinem Zweitgutachter Herrn Prof. Dr. Carsten Felden für seinen Input zu meiner Monographie sowie zu meinen Vorträgen und Publikationen.

Ich danke zudem Thomas Priemuth, der sich als mein Betreuer bei BMW stets für den erfolgreichen Abschluss meiner Dissertation und die Doktoranden im Werk Leipzig einsetzte. Er stand jederzeit mit Rat und Tat zur Seite und gab zahlreiche wertvolle Impulse für meine Arbeit. Weiterhin danke ich den Kollegen in Leipzig und den weiteren Standorten der BMW Group, den Interviewpartnern und fachlichen Experten. Stellvertretend genannt seien Thorsten Haucke, Dr. Benny Kneissl, Dr. Christoph Kracke, Verena Breu, Gerolf Kotte, Daniel Casares und Andreas Störmer. Mein Dank geht ebenso an das Team des Instituts für Anwendungssysteme in Wirtschaft und Verwaltung der Universität Leipzig.

Besonderer Dank gilt meiner Frau Ann-Katrin für ihre unermüdliche Unterstützung, Verständnis und Ermutigung. Meiner Mutter Bruni und meinen Schwestern Nina und Jana danke ich für unser starkes und unerschütterliches Team. Tobias Dick danke ich für seine Unterstützung und das Korrekturlesen. In Dankbarkeit denke ich an meinen Vater Jobst Alexander Burdensky. Widmen möchte ich diese Arbeit meiner Tochter Lina.

München, Januar 2021 Daniel Burdensky

Inhaltsübersicht

Selbstständigkeitserklärung II

Bibliographische Beschreibung III

Vorwort IV

Inhaltsübersicht V

Inhaltsverzeichnis VIII

Abbildungsverzeichnis XII

Tabellenverzeichnis XIV

Abkürzungsverzeichnis XV

1 Unternehmenssteuerung im digitalen Zeitalter 1

1.1 Komplexität der Steuerung großer Produktionssysteme 2

1.2 Unternehmenssteuerung in der BMW Group 6

1.3 Vision der Digitalen Unternehmenssteuerung 9

1.4 Forschungsfragen und Forschungsmethodik 13

1.5 Inhaltliche Struktur der Arbeit 18

2 Grundlagen der Unternehmenssteuerung 19

2.1 Systemtheoretische Betrachtung von Unternehmen 19

2.2 Prozessorientierte Steuerung von Systemen 20

2.3 Kennzahlenbasierte Prozesssteuerung 22

2.3.1 Charakteristika von Kennzahlen 22

2.3.2 Nutzen der Kennzahlensteuerung 25

2.3.3 Herausforderungen der Kennzahlensteuerung 26

2.3.4 Kennzahlensteuerung in der Praxis 27

2.3.5 Kennzahlensysteme 31

2.3.6 Kennzahlensysteme in der Praxis 33

2.4 Ursache-Wirkbeziehungen in der Kennzahlensteuerung 34
2.4.1 Vorteile transparenter Ursache-Wirkbeziehungen zwischen Kennzahlen 36
2.4.2 Empirische Ermittlung von Ursache-Wirkbeziehungen in der Praxis 37

2.5 Zusammenfassung: Herausforderungen bei der kennzahlenbasierten Steuerung großer Produktionsunternehmen 40

3 Entscheidungsunterstützungssysteme für die kennzahlenbasierte Unternehmenssteuerung 43

3.1 Business Intelligence 43

3.2 Business Intelligence in der Praxis 46

3.3 Analysefähigkeiten in der Business Intelligence 47

3.4 Advanced Analytics und Data Mining 51

3.5 Ansätze für die empirische Analyse von Kennzahlenrelationen 53
3.5.1 Qualitativ geprägte Ansätze für die empirische Analyse von Kennzahlenrelationen 53
3.5.2 Quantitative Ansätze für die empirische Analyse von Kennzahlenrelationen 56
3.5.3 Schlussfolgerungen der Analyse wissenschaftlicher Ansätze 58

3.6 Quantitative Analyse von Kennzahlenrelationen in der Black Box 61

3.7 Zusammenfassung: Leitmerkmale für die Analyse von Kennzahlenrelationen in der Unternehmenssteuerung 62

4 Elemente der Digitalen Unternehmenssteuerung 66

4.1 Methoden Engineering 66

4.2 Aktivitäten 68
4.2.1 Initialisierung 70
4.2.2 Analyse 79
4.2.3 Realisierung 91

4.3 Rollenmodell 94

4.4 Tool und Leitmerkmale 95

4.5 Methode für die Digitale Unternehmenssteuerung 96

5 Umsetzung der Digitalen Unternehmenssteuerung 100

5.1 Evaluationsstrategien im Design Science Research 100

5.2 Individual- und Standardsoftwarelösungen..... 102

5.3 KPI Intelligence Tool v1: Analyse von Werkskennzahlen 104
5.3.1 Initialisierung..... 104
5.3.2 Analyse 106
5.3.3 Realisierung 115

5.4 KPI Intelligence Tool v2: Analyse von Logistikkennzahlen 119
5.4.1 Initialisierung..... 119
5.4.2 Analyse 121
5.4.3 Realisierung 128

5.5 KPI Intelligence Tool v3: Analyse von Kennzahlenhierarchien 130
5.5.1 Initialisierung..... 132
5.5.2 Analyse 135
5.5.3 Realisierung 149
5.5.4 Anwenderumfrage 154

5.6 Zusammenfassung: Quantitative Analyse von Kennzahlenrelationen 156

6 Schlussbetrachtungen 158

6.1 Evaluation von Advanced Analytics-Algorithmen in der Digitalen Unternehmenssteuerung..... 159

6.2 Beurteilung der Ergebnisse nach Design Science Research..... 165

6.3 Kritische Würdigung..... 169

6.4 Ausblick 171

7 Literaturverzeichnis.....XVII

Index XXXII

Anhang XXXIV

Curriculum Vitae LIII

Inhaltsverzeichnis

Selbstständigkeitserklärung II

Bibliographische Beschreibung III

Vorwort IV

Inhaltsübersicht V

Inhaltsverzeichnis VIII

Abbildungsverzeichnis XII

Tabellenverzeichnis XIV

Abkürzungsverzeichnis XV

1 Unternehmenssteuerung im digitalen Zeitalter 1

1.1 Komplexität der Steuerung großer Produktionssysteme 2

1.2 Unternehmenssteuerung in der BMW Group 6

1.3 Vision der Digitalen Unternehmenssteuerung 9

1.4 Forschungsfragen und Forschungsmethodik 13

1.5 Inhaltliche Struktur der Arbeit 18

2 Grundlagen der Unternehmenssteuerung 19

2.1 Systemtheoretische Betrachtung von Unternehmen 19

2.2 Prozessorientierte Steuerung von Systemen 20

2.3 Kennzahlenbasierte Prozesssteuerung 22

2.3.1 Charakteristika von Kennzahlen 22

2.3.2 Nutzen der Kennzahlensteuerung 25

2.3.3 Herausforderungen der Kennzahlensteuerung 26

2.3.4 Kennzahlensteuerung in der Praxis 27

2.3.5 Kennzahlensysteme 31

2.3.6 Kennzahlensysteme in der Praxis 33

2.4 Ursache-Wirkbeziehungen in der Kennzahlensteuerung 34
2.4.1 Vorteile transparenter Ursache-Wirkbeziehungen zwischen Kennzahlen 36
2.4.2 Empirische Ermittlung von Ursache-Wirkbeziehungen in der Praxis 37

2.5 Zusammenfassung: Herausforderungen bei der kennzahlenbasierten Steuerung großer Produktionsunternehmen 40

3 Entscheidungsunterstützungssysteme für die kennzahlenbasierte Unternehmenssteuerung 43

3.1 Business Intelligence 43

3.2 Business Intelligence in der Praxis 46

3.3 Analysefähigkeiten in der Business Intelligence 47

3.4 Advanced Analytics und Data Mining 51

3.5 Ansätze für die empirische Analyse von Kennzahlenrelationen 53
3.5.1 Qualitativ geprägte Ansätze für die empirische Analyse von Kennzahlenrelationen 53
3.5.2 Quantitative Ansätze für die empirische Analyse von Kennzahlenrelationen 56
3.5.3 Schlussfolgerungen der Analyse wissenschaftlicher Ansätze 58

3.6 Quantitative Analyse von Kennzahlenrelationen in der Black Box 61

3.7 Zusammenfassung: Leitmerkmale für die Analyse von Kennzahlenrelationen in der Unternehmenssteuerung 62

4 Elemente der Digitalen Unternehmenssteuerung 66

4.1 Methoden Engineering 66

4.2 Aktivitäten 68
4.2.1 Initialisierung 70
4.2.1.1 Festlegen des/der zu untersuchenden Prozesse(s) 70
4.2.1.2 Festlegen der zu untersuchenden Ebene(n) 73
4.2.1.3 Modellierung der Prozesskennzahlen 77
4.2.1.4 Beschaffung der Kennzahlendaten 78
4.2.1.5 Datenimport 78
4.2.2 Analyse 79
4.2.2.1 Deskription/Diagnostik 80
4.2.2.2 Prädiktion 83
4.2.2.3 Präskription 89

4.2.3 Realisierung 91
4.2.3.1 Interpretation der Informationen 92
4.2.3.2 Konklusion hinsichtlich zukünftiger Handlungen 93
4.2.3.3 Applikation der Erkenntnisse 93

4.3 Rollenmodell 94

4.4 Tool und Leitmerkmale 95

4.5 Methode für die Digitale Unternehmenssteuerung 96

5 Umsetzung der Digitalen Unternehmenssteuerung 100

5.1 Evaluationsstrategien im Design Science Research 100

5.2 Individual- und Standardsoftwarelösungen 102

5.3 KPI Intelligence Tool v1: Analyse von Werkskennzahlen 104
5.3.1 Initialisierung 104
5.3.2 Analyse 106
5.3.2.1 Deskription/Diagnostik 107
5.3.2.2 Prädiktion 110
5.3.3 Realisierung 115

5.4 KPI Intelligence Tool v2: Analyse von Logistikkennzahlen 119
5.4.1 Initialisierung 119
5.4.2 Analyse 121
5.4.2.1 Deskription/Diagnostik 121
5.4.2.2 Prädiktion 125
5.4.3 Realisierung 128

5.5 KPI Intelligence Tool v3: Analyse von Kennzahlenhierarchien 130
5.5.1 Initialisierung 132
5.5.2 Analyse 135
5.5.2.1 Deskription/Diagnostik 136
5.5.2.2 Prädiktion 141
5.5.3 Realisierung 149
5.5.4 Anwenderumfrage 154

5.6 Zusammenfassung: Quantitative Analyse von Kennzahlenrelationen 156

6 Schlussbetrachtungen 158

6.1 Evaluation von Advanced Analytics-Algorithmen in der Digitalen Unternehmenssteuerung 159

6.2 Beurteilung der Ergebnisse nach Design Science Research 165

6.3 Kritische Würdigung 169

6.4 Ausblick 171

7 Literaturverzeichnis XVII

Index XXXII

Anhang XXXIV

Curriculum Vitae LIII

Abbildungsverzeichnis

Abb. 1-1: Prozessmodell der BMW Group 6
Abb. 1-2: Visionsbild der Digitalen Unternehmenssteuerung 11
Abb. 1-3: Forschungsvorgehen 16
Abb. 2-1: Einflussfaktorenanalyse mit der Matrix von Vester 38
Abb. 2-2: Qualitativ erfasste Kennzahlenrelationen 39
Abb. 3-1: Begrifflichkeiten in der Business Intelligence 44
Abb. 3-2: Levels der Self-Service BI 45
Abb. 3-3: Gartner Analytics Ascendancy Model 48
Abb. 3-4: Einordnung unterschiedlicher Analytics-Ausprägungen 52
Abb. 4-1: Elemente des Methoden Engineering 67
Abb. 4-2: Vorgehensmodell für die Digitale Unternehmenssteuerung 70
Abb. 4-3: Prozessmodell der Digitalen Unternehmenssteuerung 72
Abb. 4-4: Ebenenmodell Digitale Unternehmenssteuerung (Ebene 1) 73
Abb. 4-5: Ebenenmodell Digitale Unternehmenssteuerung (Ebene 2) 74
Abb. 4-6: Ebenenmodell für die Digitale Unternehmenssteuerung (Ebene 3) 75
Abb. 4-7: Ebenenmodell für die Digitale Unternehmenssteuerung (Ebene 4) 75
Abb. 4-8: Erkenntnisbeiträge der Deskription/Diagnostik 80
Abb. 4-9: Erkenntnisbeiträge der Prädiktion 86
Abb. 4-10: In Unternehmen eingesetzte prädiktive Algorithmen 87
Abb. 4-11: Erkenntnisbeiträge der Präskription 90
Abb. 4-12: Metamodell der Methode für die Digitale Unternehmenssteuerung 97
Abb. 5-1: Framework for Evaluation in Design Science 100
Abb. 5-2: Prozessmodell KPI Intelligence Tool v1 105
Abb. 5-3: Streudiagramm zwischen der Termintreue und der Durchlaufzeit 108
Abb. 5-4: Abhängigkeitsgraph KPI Intelligence Tool v1 109
Abb. 5-5: Qualitativ erfasste Ursache-Wirkbeziehungen 115
Abb. 5-6: Logistikprozessmodell 120
Abb. 5-7: Startseite KPI Intelligence Tool v2 120

Abb. 5-8: Abhängigkeitsgraph KPI Intelligence Tool v2 122
Abb. 5-9: Abhängigkeitsgraph gefiltert KPI Intelligence Tool v2 123
Abb. 5-10: Abhängigkeitsgraph Versorgungsleistung KPI Intelligence Tool v2 124
Abb. 5-11: Visualisierung Neuronales Netz KPI Intelligence Tool v2 126
Abb. 5-12: Visualisierung Prädiktion KPI Intelligence Tool v2 126
Abb. 5-13: Vorhersagegüte Neuronales Netz (links) und multivariate lineare Regression (rechts) 127
Abb. 5-14: Prozessmodell Werk 133
Abb. 5-15: Hierarchisches Prozessmodell gemäß Zielwerttabelle 133
Abb. 5-16: Tabellenansicht KPI Intelligence Tool v3 134
Abb. 5-17: Ausreißerbereinigung KPI Intelligence Tool v3 135
Abb. 5-18: Korrelationsgraph Zielwerttabelle Werksebene 137
Abb. 5-19: Streudiagramm von Kennzahlen KPI Intelligence Tool v3 138
Abb. 5-20: Sequentielle Prozesse KPI Intelligence Tool v3 139
Abb. 5-21: Hierarchischer Abhängigkeitsgraph KPI Intelligence Tool v3 140
Abb. 5-22: Beispiel Entscheidungsbaum 143
Abb. 5-23: Gütekriterien im KPI Intelligence Tool v3 – Ridge Regression 145
Abb. 5-24: Gütekriterien im KPI Intelligence Tool v3 – Random Forest 145
Abb. 5-25: Prädiktionsmodus Hierarchie KPI Intelligence Tool v3 149
Abb. 6-1: Prinzipien rekombinanter Innovationen 166
Abb. 0-1: Erweitertes Schema des Regelkreises XXXIV
Abb. 0-2: Leitfaden KPI Intelligence XXXV
Abb. 0-3: Modellierung mehrerer Ebenen im KPI Intelligence Tool XXXVII
Abb. 0-4: Abhängigkeitsgraph des KPI Intelligence Tools (Ebene 1) XXXVII
Abb. 0-5: Prädiktionsansicht des KPI Intelligence Tools (Ebene 1) XXXVIII
Abb. 0-6: Auswertung Anwenderumfrage LII

Tabellenverzeichnis

Tabelle 1-1: Muster des Umgangs mit Komplexität 3
Tabelle 2-1: Anforderungen an Kennzahlen 24
Tabelle 2-2: Rollen des Zielemanagementprozesses 28
Tabelle 3-1: Ansätze der empirischen Analyse von Ursache-Wirkbeziehungen 55
Tabelle 4-1: Kurzbeschreibung deskriptiver/diagnostischer Algorithmen 82
Tabelle 4-2: Kurzbeschreibung prädiktiver Algorithmen 88
Tabelle 4-3: Rollenmodell für die Digitale Unternehmenssteuerung 94
Tabelle 5-1: Vor- und Nachteile der Softwarelösungen 103
Tabelle 5-2: Auswertung der multivariaten linearen Regression 111
Tabelle 5-3: Gütekriterien Multivariate Lineare Regression 112
Tabelle 5-4: Erfüllung der Leitmerkmale durch das KPI Intelligence Tool v1 117
Tabelle 5-5: Erfüllung der Leitmerkmale durch das KPI Intelligence Tool v2 128
Tabelle 5-6: Analysefähigkeiten des KPI Intelligence Tools v3 136
Tabelle 5-7: Gegenüberstellung Zielwerttabelle und Datenanalyse 150
Tabelle 5-8: Erfüllung der Leitmerkmale durch das KPI Intelligence Tool v3 153
Tabelle 6-1: Chancen des Einsatzes von Advanced Analytics-Algorithmen 162
Tabelle 6-2: Herausforderungen des Einsatzes von Advanced Analytics-Algorithmen 164
Tabelle 6-3:Rückschlüsse für die Gestaltung der digitalen Transformation in Unternehmen 171
Tabelle 0-1: Kriterienkatalog XXXVI
Tabelle 0-2: Kernaussagen Praxis-Interviews XLVI

Abkürzungsverzeichnis

AHP	Analytic Hierarchy Process
BI	Business Intelligence
BSC	Balanced Scorecard
DLQ	Direktläuferquote
DLZ	Durchlaufzeit
DW	Durbin-Watson
DWH	Data Warehouse
ERP	Enterprise Resource Planning
F&E	Forschung & Entwicklung
FpE	Fehler pro Einheit
GW	Gewährleistungskosten
HFF	Hauptforschungsfrage
IT	Informationstechnik
KDD	Knowledge Discovery in Databases
KPI	Key Performance Indicator
MVP	Minimum Viable Product
NAF1	Nacharbeitsminuten
OEE	Overall Equipment Effectiveness
OLS	Ordinary Least Squares
OR	Operations Research
PU	Produktionsunterbrechungen
QZF	Kundenorientierte Qualitätszahl Standard
QZS	Kundenorientierte Qualitätszahl für Funktionalität
MSE	Mean Squared Error
SIV F1	Soll-Ist-Vergleich am F1 Punkt
SIV F2	Soll-Ist-Vergleich am F2 Punkt
TFF	Teilforschungsfrage
TT	Termintreue

VIF	Variance Inflation Factor
VL_BMW	Versorgungsleistung BMW intern
VL_ges	Versorgungsleistung
VL_Lief_Log	Versorgungsleistung Lieferanten Logistik
ZMP	Zielemanagementprozess
ZpE	Zeit pro Einheit

1 Unternehmenssteuerung im digitalen Zeitalter

Die Digitalisierung durchdringt schrittweise eine Vielzahl der Aufgabenbereiche großer Produktionsunternehmen[1]. Insbesondere der Automobilindustrie prophezeien Experten eine tiefgreifende digitale Transformation [Diekmann/Sümmchen 2016, 5]. Angetrieben durch die Industrie 4.0 und das Internet of Things stehen bisher vor allem Wertschöpfungsprozesse wie Vertrieb/Marketing, die Produktion und die Supply Chain aber auch Kundenservices wie Fahrzeugkonfiguratoren, Mobilitäts- und Infotainmentdienste im Fokus [Diekmann/Sümmchen 2016, 5]. Eine eher geringe Durchdringung der Digitalisierung erfolgte bisher bei der Steuerung der Unternehmen aus Managementperspektive (siehe dazu Kapitel 3.3). Zwar gibt es eine Vielzahl digitaler Lösungen zur Visualisierung von Daten (z. B. Dashboards, interaktive Berichtssysteme) und ein größer werdendes Angebot an fortgeschrittenen Analysemöglichkeiten in spezifischen Kontexten (z. B. Predictive Maintenance, Process Mining), allerdings findet deren Zusammenführung zur Unterstützung kennzahlenbasierter Managementprozesse in der Praxis kaum statt. Dabei benötigen Entscheidungsträger in Zeiten der Industrie 4.0, in welchen dynamische und vernetzte Produktionsstrukturen zunehmen, IT-Systeme, die die Bearbeitung komplexer Aufgabenstellungen systematisch mit Informationen anreichern [Hänel/Felden 2015, 260]. Beispielsweise kann ein LKW im Stau auf der Autobahn Stunden später Probleme in der Produktion erzeugen, wenn die erwarteten Just-in-Time-Lieferungen nicht pünktlich zu Verfügung stehen. In einem solchen Fall muss für das Management das Ereignis des Staus in den Daten den Ereignissen im Produktionsprozess zuteilbar sein, um die Ursache-Wirkbeziehungen zu analysieren und einzuschätzen, wie stark sich dieses Ereignis auswirkt. Darauf aufbauend sind wirtschaftlich sinnvolle Maßnahmen zu ergreifen.

Generell beinhalten Managementprozesse das Führen und Steuern von Organisationen durch aufeinander abgestimmte Tätigkeiten [Deutsches Institut für Normung 2015, 31], sodass die von verschiedenen Instanzen getroffenen Entscheidungen letztlich zur Realisierung der obersten Unternehmensziele beitragen [Gladen 2014, 18]. Dabei zählen die exponentiell steigende Komplexität und die Dynamik des Wandels der heutigen, global vernetzten Systeme[2] zu den wichtigsten Herausforderungen für das Management [Malik 2013, 4]. Zu diesen vernetzten Systemen gehören zum Beispiel politische Systeme, Verkehrssysteme, aber auch die Produktionsunternehmen selbst mit ihrer Vielzahl wechselseitig voneinander abhängiger Aufgaben [Gladen 2014, 18]. Als hochintegrierte, komplexe Systeme implizieren sie Wechselwirkungen, welche für den einzelnen nicht absehbar sind [Legner 1999, 190].

---

[1] [Schön 2018, 228] vergleicht verschiedene Grenzen für die Größeneinordnung von Unternehmen. Diese weichen stark voneinander ab. Folgend gilt ein Unternehmen gemäß der Definition des Europäischen Kompetenzzentrums für Angewandte Mittelstandsforschung ab 3000 Mitarbeitern und mehr als 600 Mio. € Jahresumsatz als groß.

[2] Eine Definition von Systemen folgt in Kapitel 2.1.

1.1 Komplexität der Steuerung großer Produktionssysteme

Das Ziel der Entscheidungsträger in Produktionsunternehmen ist, mit gegebenem Kapitaleinsatz (Input wie z. B. Kosten, Verbrauchsmenge) maximalen Erfolg (Output wie z. B. Produktionsmengen, Gewinn) oder mit minimalen Mitteln ein definiertes Ergebnis zu erzielen [Gladen 2014, 184]. Die Vielzahl an Abhängigkeiten zwischen den Unternehmensprozessen, die beteiligten Personen, die enorme Datenmenge und Datenvielfalt, kurze Reaktionszeiten sowie verteilte Ressourcen erschweren das Herstellen von Zusammenhängen, Bewerten von Alternativen und Herbeiführen fundierter Entscheidungen jedoch massiv [Lambeck 2015, 37]. Als Ganzes sind die komplexen Beziehungen im Unternehmen mehr als die Summe der Teile und führen zu Systemeigenschaften, die auf einzelne Systemelemente nicht mehr zurückführbar sind [Trier et al. 2013, 48; Malik 2013, 19]. Vor diesem Hintergrund definieren [Trier et al. 2013, 49] die Komplexität von Systemen als:

$$\mathrm{K} = \frac{n_r}{n_e}\text{, mit}$$

K = Komplexität,

n_r = Anzahl der Relationen,

n_e = Anzahl der Elemente.

Demnach steigt die Komplexität bei gleichbleibender Anzahl der Elemente mit der Anzahl an Relationen. [Schwaninger 2004, 6 f.] beschreibt Komplexität anhand ihrer „…Eigenschaft, viele Zustände oder Verhaltensweisen annehmen zu können“ und ihrer „…Konnektivität und dynamische[n] Interaktion ihrer Komponenten“. Ähnlich dazu bezeichnet [Rüegg-Stürm 2014, 7] ein System als komplex, wenn „…the elements of a system interact in a variety of ways and interrelate with each other in a specific and dynamic relationship.“ Diese drei Definitionen verdeutlichen, dass die Beziehungen zwischen den Elementen den entscheidenden Ausschlag für die Komplexität von Systemen geben. Daher steht die Analyse von Ursache-Wirkbeziehungen in großen Produktionsunternehmen im Fokus der Ausführungen der vorliegenden Dissertation.

Große Unternehmen besitzen viele Elemente, die auf vielfältige Art und Weise in Beziehung zueinander stehen. Daher weisen sie eine hohe Komplexität auf. In diesem Kontext ist eine Aufgabe des Managements, Maßnahmen zur Planung, Steuerung und Kontrolle strategischer sowie operativer Geschäftsprozesse abzuleiten und zu ergreifen [Alt/Puschmann 2016, 55]. Allerdings können Menschen Systeme von nur maximal vier Variablen kognitiv verarbeiten [Halford et al. 2005, 75]. Folglich sind die Ursache-Wirkbeziehungen zwischen den Prozessen großer Unternehmen intuitiv nicht mehr nachvollziehbar oder antizipierbar und überfordern die Leistungsfähigkeit der Führungskräfte [Schwaninger 2004, 7; Forrester 2009, 8; Ster-

man 2001, 10; Eley 2012, 3; Druzdzel/Flynn 2009, 1]. Das bedeutet, dass das Abschätzen der Interaktionen der Elemente anhand der Beziehungen und die resultierenden Wirkungen nur in begrenztem Maße möglich ist. Daher besteht ein großer Bedarf nach Hilfsmitteln zur Entscheidungsunterstützung. Übliche Muster des Umgangs mit Komplexität sind:

Trial-and-Error	Man probiert aus, wie ein Ziel erreicht werden kann.
Ausblenden	Man bleibt beim alten Muster und ignoriert Alternativen.
Rationales Durchdringen und Verstehen	Man versucht Komplexität über die Details zu verstehen und stößt an Grenzen.
Trivialisierung	Man reduziert die Fragestellung durch die Konzentration auf einzelne Faktoren.
Emotionale Bewertung	Man bildet komplexe Muster im Gehirn jenseits des bewussten Verstehens und agiert intuitiv.

Tabelle 1-1: Muster des Umgangs mit Komplexität [Kruse o. D.]

Unabhängig von der gewählten Strategie stützt sich menschliches Handeln, ob bewusst oder unbewusst, auf Modelle [Schwaninger 2004, 9]. Sie basieren auf verschiedensten Grundlagen, wie den Ergebnissen früherer Entscheidungsprozesse sowie Annahmen, Einstellungen, individuellem Wissensstand und Grundüberzeugungen [Gladen 2014, 38]. Die mentalen Modelle von Entscheidungsträgern beinhalten also individuelle Hypothesen über Ursache-Wirkbeziehungen in den Unternehmen und erleichtern ihnen die Wahrnehmung der komplexen Realität [Gladen 2014, 38].

Die mentalen Modelle sind regelmäßig auf Aktualität zu prüfen und den veränderten Rahmenbedingungen anzupassen, da sich das Marktumfeld vieler Unternehmen ändert und sich die verfügbare Datenbasis stetig ausweitet [Kemper et al. 2010, 8]. Beispielsweise sahen sich die Automobilhersteller weltweit in den Jahren 2020 und 2021 mit der Corona-Krise konfrontiert. Aufgrund ökonomischer Unsicherheiten brach die Nachfrage zunächst ein. Anschließend gab es einen deutlichen Anstieg der Nachfrage – zunehmend nach elektrifizierten Fahrzeugen. Dies stellte die Hersteller vor die Herausforderung, innerhalb kürzester Zeit mit starken Volumenschwankungen und einem veränderten Schwerpunkt hinsichtlich nachgefragter Produkteigenschaften umzugehen. Als Folge der volatilen Nachfrage entstanden Engpässe bei der Versorgung der globalen Lieferketten mit Chips durch die Halbleiterindustrie, die wiederum andere Herausforderungen für die OEMs darstellten.

Unternehmen, die zukünftig im Wettbewerb bestehen wollen, müssen agil auf derartige Schwankungen reagieren. Agilität bedingt jedoch auch eine höhere Entscheidungsdichte und führt dazu, dass das Management in kürzerer Zeit Entscheidungen treffen muss [Diekmann/Sümmchen 2016, 27]. Die Bedeutung der Faktoren Zeit und Komplexität für das Treffen von Entscheidungen spiegelt sich auch in dem Beitrag von [Rahman/Feis 2009, 46] wider. Für ihr „Analytical framework for strategic decision-making“ nutzen sie eben diese Faktoren als die maßgeblichen Dimensionen zur Einordnung von Modellen und Methoden zur Entscheidungsunterstützung. Im Spannungsfeld zwischen Zeitdruck und Komplexität der Unternehmenssteuerung sind in die Unternehmensprozesse und -strukturen integrierte, innovative IT Lösungen ein wesentlicher Stellhebel [Alt et al. 2020, 614] für die Unterstützung der Wertschöpfung, die Anreicherung mit neuen Services sowie digitalen Produkten und die Schaffung neuer Geschäftsmodelle [Alt et al. 2020, 613].

Es ist kaum abschätzbar, welche Änderungen zukünftig auftreten. Deshalb umfasst der zeitliche Horizont sowohl kurz- wie auch langfristige Perspektiven und schließt eine permanente Weiterentwicklung der Geschäftsprozesse an die sich ändernden Umweltbedingungen (z. B. neue Technologien, Gesetze, Kundenanforderungen) ein [Legner 1999, 1]. Auf diese Weise trägt die Anpassungsfähigkeit von Unternehmensprozessen (z. B. hinsichtlich des Produktionsvolumens oder der Produktvielfalt) und die Geschwindigkeit in der Produktentwicklung neben der Effizienz und Effektivität der Prozesse maßgeblich zur Wettbewerbsfähigkeit bei. Gleichzeitig steigen die Anforderungen an Transparenz und Fundierung von Entscheidungen [Kemper et al. 2010, 8] sowie an das quantitative Berichtswesen im Unternehmen [Steuernagel 2017, 5]. Jene Anforderungen bleiben jedoch häufig unerfüllt, da Entscheidungen weiterhin überwiegend auf Intuitionen und Annahmen bezüglich separierter Teile des Gesamtsystems basieren [Forrester 2009, 9; Druzdzel/Flynn 2009, 2]. Dieses Vorgehen reduziert zwar einerseits die kognitive Belastung des Managements, andererseits aber auch die Entscheidungsqualität [Druzdzel/Flynn 2009, 2; Davenport 2010, 2], weil die Phase der Willensbildung häufig durch Wissensdefizite gekennzeichnet ist [Gladen 2014, 361].

Aufgrund der Unsicherheiten, die die Komplexität und Dynamik von Produktionsunternehmen erzeugen, gibt es keine Garantie, dass das Ergebnis einer Maßnahme der ursprünglichen Absicht entspricht. Daher bleibt nur eine Optimierung des Entscheidungsprozesses, in welchem möglichst alle maßgebenden Faktoren, Alternativen und Präferenzen berücksichtigt werden [Druzdzel/Flynn 2009, 3]. “Information kills variety; and the reduction of variety is one of the main techniques of regulation - not indeed because it simplifies the system to be controlled, but because it makes it more predictable.” [Beer 1959, 44] Schließlich kann das Ergebnis eines Managementprozesses in der Regel nicht besser sein als das zugrunde liegende mentale Modell [Schwaninger 2001, 138]. Demnach sind mentale Modelle durch geeignete Hilfsmittel, wie zum Beispiel die Balanced Scorecard (BSC) (siehe Kapitel 2.3.5), sowie relevante Informationen zu ergänzen und zu aktualisieren.

Es gibt Bemühungen zu untersuchen, welche Faktoren das Verhalten von Systemen maßgeblich beeinflussen und wie die Beziehungen zwischen diesen beschaffen sind, um das Systemverhalten im Sinne der übergeordneten Ziele zu steuern [Schwaninger 2001, 138]. Für derartige Analysen eignen sich unter anderem Szenariobetrachtungen und Simulationen [Gladen 2014, 361]. Insbesondere wenn dabei aber die Menge an Informationen für den Entscheidungsträger zu groß ist, empfiehlt sich der Einsatz von Entscheidungsunterstützungssystemen [Druzdzel/Flynn 2009, 1]. Als Informationsbasis stehen dafür die mentalen Modelle von Experten und Entscheidungsträgern als implizites Wissen[3], aber auch die Daten der Unternehmen zur Verfügung. Die meisten Unternehmen verfügen über große Mengen von Daten, deren Potentiale sie aber nicht ausschöpfen: Es werden eher historische als gegenwarts- bzw. zukunftsorientierte Betrachtungen durchgeführt, eher aggregierte Daten als Rohdaten verwendet und deren Spektrum häufig zu eng gefasst, obwohl eine verbesserte Informationsbasis eine bessere Prozessleistung bewirken kann [Hammer/Hershman 2010, 39].

Die Industrie 4.0, mit der eine revolutionäre Umgestaltung der industriellen Produktion einhergeht, macht vor dem Hintergrund veränderter, stärker vernetzter Produktionsabläufe und des Einsatzes zeitgemäßer Technologien eine Neuorganisation der IT-Systeme für die Entscheidungsunterstützung unumgänglich [Hänel/Felden 2015, 260 f.]. Speziell die Kennzahlendaten, die die Leistung und Effizienz der vernetzten Prozesse repräsentieren, weshalb die Manager der Unternehmen sie zur Steuerung und Überwachung des Unternehmenserfolges nutzen, stellen eine Informationsquelle dar, die sehr wertvolle Erkenntnisse über die Ursache-Wirkbeziehungen zwischen Prozessen und deren Einflüssen liefern kann. Zur Nutzung dieser Informationen werden fortgeschrittene, quantitative Methoden (z. B. aus der Statistik) auf die Daten angewendet. Eine solche quantitative Analyse von Kennzahlenrelationen bietet die Möglichkeit, mentale Modelle zu prüfen, zu fundieren, zu ergänzen oder zu korrigieren. Als praktisches Beispiel für ein großes Produktionsunternehmen dient die BMW Group.

[3] Das implizite Wissen dient beispielsweise bei der Anwendung der BSC als Grundlage und wird durch deren Anwendung strukturiert.

1.2 Unternehmenssteuerung in der BMW Group

Die BMW Group umfasst die Marken BMW, MINI, Rolls-Royce Motor Cars und BMW Motorrad und beschäftige im Jahr 2020 120.726 Mitarbeiter [BMW Group 2022a]. An 31 Produktionsstandorten in 15 Ländern wurden 2.325.179 Automobile und 169.272 Motorräder ausgeliefert, wobei ein Umsatz von 98.990.000.000 € erwirtschaftet wurde [BMW Group 2022a].

Ihre Unternehmensstruktur vereint die Eigenschaften zweier unterschiedlicher Organisationsformen: Sie ist einerseits ressortorientiert aufgebaut, um funktionale Spezialisierungen auf Fachprozesse zu ermöglichen (z. B. Produktion, Einkauf und Lieferantennetzwerk, Finanzen). Da dies zu Prozessbrüchen führt, also funktionale Verantwortungen und Ziele durch die Ressortgrenzen voneinander trennt, ist die BMW Group andererseits ebenfalls prozessorientiert organisiert. Das Prozessmodell ist in Abb. 1-1 dargestellt und zeigt, dass sich die Teilprozesse durchgängig am Beitrag für den Endkunden (repräsentiert durch die blauen Quadrate) orientieren. So werden übergreifende Ziele gesetzt und Potentiale durch nachhaltige Prozesse und gemeinsame Best Practices genutzt.

Die vier Hauptprozesse des Prozessmodells gliedern sich schrittweise in die jeweiligen zur Automobilfertigung notwendigen Teilprozesse auf, sodass ein komplexes Gefüge an prozessualen Interdependenzen entsteht. Durch diese Organisationsstruktur beeinflussen sich die Prozesse im Sinne von Vorgänger-Nachfolger-Beziehungen, Parallelprozessen und dem hierarchischen System der Prozesse. Diese Logik durchzieht das Unternehmen über alle Hierarchieebenen hinweg.

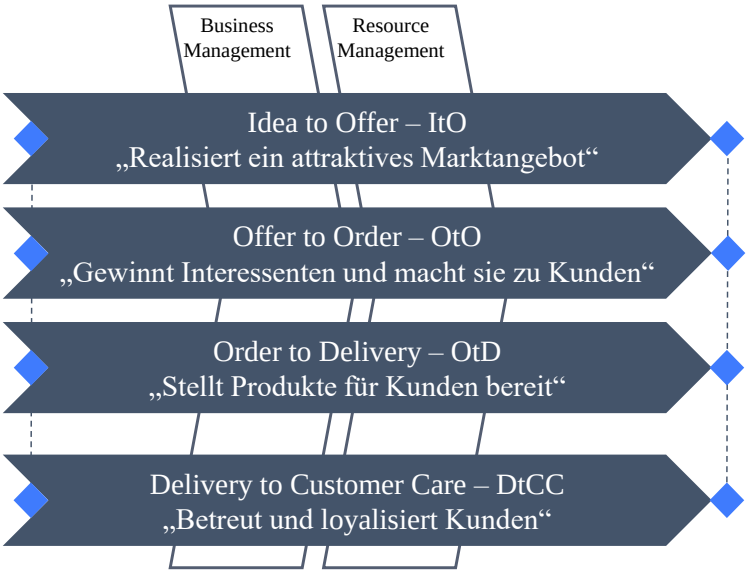

Abb. 1-1: Prozessmodell der BMW Group [BMW Group 2016, 11]

[Beer 1959, 12] bezeichnet ein System, welches so kompliziert ist, dass es auf präzise und detaillierte Art und Weise nicht mehr beschrieben werden kann, als überaus komplex. Darüber hinaus unterteilt er nach deterministischen Systemen, die perfekt vorhersagbar sind und probabilistischen Systemen, deren Verhalten nur im Rahmen von bestimmten Wahrscheinlichkeiten vorhergesagt werden kann [Beer 1959, 12]. Produzierende Unternehmen bezeichnet er grundsätzlich als komplex und probabilistisch [Beer 1959, 16]. [Rüegg-Stürm 2014, 8] nennt in Ergänzung zu der Definition in Kapitel 1.1 ein System komplex, wenn

- eine Vielzahl nicht einfach verständlicher Beziehungen und Interaktionen zwischen dessen Elementen besteht,
- die Elemente aufgrund vielfältiger wechselnder (Un-) Abhängigkeiten einem laufenden und kaum vorhersagbaren Wandel unterliegen,
- die Relationen und Interaktionen Ergebnisse hervorbringen, welche nicht auf bestimmte Besonderheiten oder Charakteristika individueller Elemente zurückzuführen sind, sondern aus deren Kombination entstehen.

Gemäß dieser Kriterien ist die BMW Group als Ganzes, aber auch jedes einzelne ihrer Automobilwerke für sich, als überaus komplex und probabilistisch zu betrachten (siehe auch [Interview 23.08.2018]). Die Werke sind durch eine Vielzahl von Prozessen auf unterschiedlichen Hierarchieebenen, die in vielfältigen Ursache-Wirkbeziehungen miteinander stehen, organisiert. Die Interaktionen der Prozesse sind dynamisch, wandeln sich und ermöglichen in Kombination miteinander die Leistungserbringung des Unternehmens. Daher eignet sich das BMW Group Werk Leipzig[4] exemplarisch für die Durchführung einer Fallstudie zur Untersuchung der zuvor aus der Literatur hergeleiteten Fragestellung der umfassenden Unterstützung der Steuerung komplexer Produktionsunternehmen mit Hilfe von Advanced Analytics.

Die Bewältigung der Komplexität von Prozessen ist für das Management die größte Herausforderung [Schwaninger 2004, 7]. Um dieser zu begegnen, kommen bei der Prozesssteuerung Kennzahlen zum Einsatz. Im Rahmen eines strategischen Werksprojektes zur Schaffung von „Transparenz, Messbarkeit und Wirksamkeit“ der Kennzahlensteuerung im BMW Group Werk Leipzig, in welches das Dissertationsprojekt über einen mehrjährigen Zeitraum als Teilprojekt eingegliedert war, zeigte sich, dass mehr als 550 Kennzahlen-Berichte und Cockpits in dem Werk existieren. Diese stellen eine Vielzahl an Kennzahlen dar und weisen zahlreiche Überschneidungen, Inkonsistenzen und Redundanzen auf. Ebenfalls wurde deutlich, dass ein hohes Ausmaß an Abhängigkeiten zwischen den Kennzahlen besteht. Die entsprechenden Ursache-Wirkbeziehungen berücksichtigen Experten ausschließlich auf

[4] Im BMW Group Werk Leipzig werden die Fahrzeuge der BMW 1er und 2er Reihe sowie Autos mit Elektroantrieb gefertigt. Rund 5.400 Mitarbeiter produzieren täglich über 1000 Fahrzeuge [BMW Group 2022b]

der Grundlage ihres Fachwissens und Erfahrungsschatzes, welche nicht konsistent nachvollziehbar oder abbildbar sind. Dies führt dazu, dass die Intransparenz und Komplexität durch die Menge an Berichten und Kennzahlen steigen, obwohl diese gerade Transparenz und eine reduzierte Komplexität der Prozesssteuerung schaffen sollen. Die gleiche Problematik stellten [Becker/Winkelmann 2014, 72] bei wissenschaftlichen Untersuchungen branchenübergreifend auch in anderen Unternehmen fest.

Darüber hinaus erfüllt die retrospektive Abbildung der Kennzahlenausprägungen die Erwartungen der Führungskräfte des Werksleitungskreises nicht [Interview 23.08.2018]. Sie fordern vor dem Hintergrund steigender Komplexität und wirtschaftlicher Dynamik, Veränderungen zu verstehen, mehr Transparenz bezüglich der Zusammenhänge zwischen den Kennzahlen zu erhalten sowie die Möglichkeit Vorhersagen und Simulationen durchzuführen [Interview 23.08.2018]. Darauf aufbauend sollen schnell und proaktiv wirksame Maßnahmen zur Steuerung im Sinne der übergeordneten Unternehmensziele abgeleitet werden [Interview 23.08.2018]. Auch soll sichergestellt werden, dass das Kennzahlensystem des Werkes gemäß der menschlichen kognitiven Leistungsfähigkeit beherrschbar und verständlich ist.

Übereinstimmend mit den Beobachtungen von [Becker/Winkelmann 2014, 71] in anderen Unternehmen, werden bis dato Arbeitshypothesen qualitativ, also auf Basis impliziten Wissens, darüber gebildet, ob ein hoher oder niedriger Kennzahlenwert einen bestimmten Prozess im Sinne der übergeordneten Ziele beeinflusst (siehe hierzu Kapitel 2.4.2). Somit erfolgt die Bestimmung der Zusammenhänge immer vor dem Hintergrund des spezifischen Kontextes und der mentalen Modelle der Beteiligten [Rüegg-Stürm 2014, 9] und besitzt ein geringes Maß an Objektivität. Hinzu kommt, dass das Denken in dieser Form recht abstrakt ist [Schwaninger 2001, 141] und das Management wiederum vor komplexe Problemstellungen stellt. Daher ist eine weniger abstrakte Lösung zur Entscheidungsunterstützung notwendig. Bestehende Reporting-Lösungen bieten allerdings keinen einheitlichen und ganzheitlichen Blick auf die jeweiligen Unternehmen [Diekmann/Sümmchen 2016, 22].

Die praktischen Einblicke belegen die zuvor auf Grundlage der Literatur erarbeiteten Herausforderungen der Unternehmenssteuerung und dass das BMW Group Werk Leipzig repräsentativ für andere Unternehmen ist. Dies bildet die Ausgangslage der Vision der Digitalen Unternehmenssteuerung.

1.3 Vision der Digitalen Unternehmenssteuerung

[Steuernagel 2017, 27] nutzt die Begriffe Management und Unternehmenssteuerung, wie es häufig in der Theorie und der Praxis erfolgt, synonym und definiert sie als: „Alle Aktivitäten, quantitativer und qualitativer, operativer und strategischer Art, durch die Unternehmen und deren Mitarbeiter ein System von Zielen (Kurs) erhalten, diesen regelmäßig auf den Prüfstand stellen (Kursüberprüfung bzw. -anpassung) und durch die sie auch zur kurz- und langfristigen Erreichung der Ziele beitragen.“ Die Unternehmenssteuerung ist also die Aufgabe von Managern sämtlicher Hierarchiestufen und beinhaltet unterschiedliche Zeiträume und ein breites Maßnahmenspektrum, welche es bei dem Ableiten von Entscheidungen zu berücksichtigen gilt. Kennzahlen sind ein Hilfsmittel bei der Definition und Messung der Erreichung der jeweiligen Ziele durch die Maßnahmen. Daher hat sich in diversen Kontexten die Terminologie von kennzahlenbasierter beziehungsweise kennzahlenorientierter Steuerung von Prozessen und Unternehmen etabliert [Deuter 2018; Glaser 2016; Zielonka 2018; Behnke et al. 2014]. Daran anknüpfend soll hier von kennzahlenbasierter Unternehmenssteuerung die Rede sein (vgl. [Steuernagel 2017, 5]).

Die historischen Kennzahlendaten beinhalten unabhängig von menschlichen mentalen Modellen und vom Kontext, in welchem sie interpretiert werden, Informationen über Fakten der repräsentierten Prozesse [Schwaninger 2004, 10]. [Moellers et al. 2017, 135] sprechen datenbasierten Analysen höchste Validität zu und konstatieren, dass die benötigten Informationen in Datenbanken enthalten sind. Datenanalysen bieten die Möglichkeit, Ursache-Wirkbeziehungen zwischen Prozessen, repräsentiert durch die Kennzahlen, strukturiert, nachvollziehbar und statistisch überprüfbar zu beschreiben [Kieninger et al. 2015, 5]. Darauf aufbauend erlauben Simulations- und Szenariomodelle die effiziente Optimierung von betriebswirtschaftlichen Fragestellungen, die über die klassischen Möglichkeiten hinaus gehen [Kieninger et al. 2015, 5]. So kann das Management umfassende Informationen zur Entscheidungsvorbereitung einbeziehen, den Entscheidungsprozess transparenter gestalten und noch besser fundierte Entscheidungen treffen. [Becker/Winkelmann 2014, 9] nehmen an, dass die Analyse von Massendaten mittels OLAP- und Data Mining-Tools selbstverständlich werden wird. Treiber dessen sind die großen Potentiale, die die Menge verfügbarer Daten und die quantitativen Modelle zur Informationsgenerierung in sich tragen [Kieninger et al. 2016, 247].

Wie in Kapitel 1 dargelegt, haben sich viele Unternehmen in der Vergangenheit bei ihrem Engagement auf Verbesserungen wie beispielsweise die Automatisierung von Prozessen konzentriert, wobei der Entscheidungsprozess der kennzahlenbasierten Unternehmenssteuerung nicht im Fokus stand [Davenport 2010, 1]. Folglich haben sich datenbasierte Lösungen zur Analyse von Kennzahlenrelationen in der Praxis noch nicht etabliert, nehmen aber zunehmend eine zentrale Rolle ein (siehe auch [Davenport 2010, 1]). [Mehanna et al. 2015, 29] sprechen von einem Paradigmenwechsel der Unternehmenssteuerung durch die Digitalisierung. Diese Weiterentwicklung der klassischen Steuerung unter Einbeziehung der Potentiale der Digitalisierung wird als Digitale Unternehmenssteuerung bezeichnet [Kieninger et al. 2015, 4].

Das Vorhergehende zeigt anhand der wissenschaftlichen Literatur sowie einem Praxisbeispiel, dass die Komplexität der Unternehmenssteuerung intern auf interprozessuale Ursache-Wirkbeziehungen, die beteiligten Personen sowie Maschinen und weitere Ressourcen zurückzuführen ist. Allerdings beeinflussen ebenso exogene, für Unternehmen nicht kontrollierbare Faktoren, wie zum Beispiel die Politik oder das Wetter die Handlungen in Unternehmen. Auch externe Partner wirken auf die Unternehmensergebnisse ein, weshalb erste Kooperationen für Prognosebildungen in Unternehmensnetzwerken entstehen [Mertens et al. 2012, 621]. Ferner stellen Unternehmen externen Parteien Informationen zur Verfügung, um die interne Sicht der Unternehmensleitung darzulegen [Diekmann/Sümmchen 2016, 27], was wiederum eine beeinflussende Reaktion zur Folge hat (z. B. Verlauf der Aktienkurse). Zusammenfassend zeigt Abb. 1-2 auf, dass Einflüsse sowohl innerhalb als auch außerhalb der Unternehmensgrenzen (bzw. Organisationssystemgrenzen) auf die Handlungen der Akteure wirken. Wie in dem Logistik-Beispiel aus der Einleitung können sich Anlieferungen von Waren durch LKW aufgrund von Staus durch Glatteis auf den Autobahnen (Wetter- und Verkehrsdaten mit externen Informationen) verzögern. In diesem Fall müssen die Mitarbeiter der internen Logistik den Lagerbestand und die voraussichtlichen Auswirkungen auf die interne Kennzahl Versorgungsleistung (Daten mit internen Informationen) prüfen, um einzuschätzen, ob die verzögerte Anlieferung der Waren die eigene Unternehmensleistung verschlechtert (eine mögliche technische Umsetzung beinhaltet Kapitel 4.2.2.1). Ergibt die Prüfung der Kennzahlendaten zum Beispiel, dass eine negative Beeinflussung der Produktion durch Fehlteile droht, sind die effizientesten und effektivsten Maßnahmen zu identifizieren und zu ergreifen, um derartige Effekte abzuwenden. Die resultierende Handlung beeinflusst wiederum die Umwelt des Unternehmens, indem z. B. aufgrund der Dringlichkeit eine Ersatzlieferung beauftragt wird, wodurch die entstehenden Kosten deutlich höher sind, als dies bei einem regulären Transport (Daten mit internen Informationen) der Fall gewesen wäre (wie eine technische Lösung dieser Fragestellung aussehen könnte, ist in Kapitel 4.2.2.2 dargestellt). Darüber hinaus hat die resultierende Handlung Auswirkungen auf das Unternehmen selbst, indem durch die Nutzung der verfügbaren Daten Sofortmaßnahmen zur Reduktion der negativen Effekte angestoßen werden.

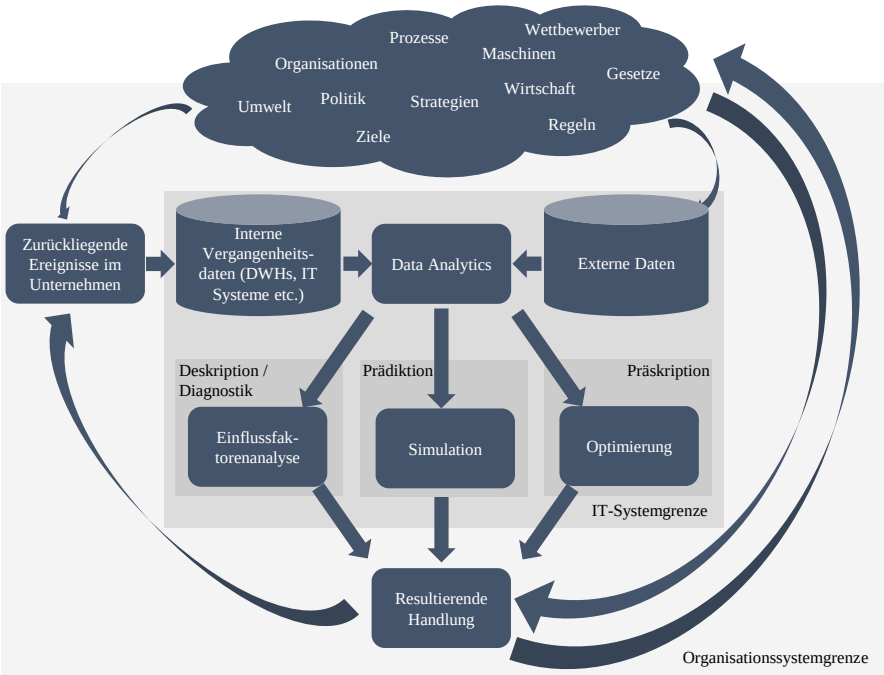

Abb. 1-2: Visionsbild der Digitalen Unternehmenssteuerung

Die zu nutzenden Daten entstehen durch die Geschäftstätigkeiten von Unternehmen, wie beispielsweise durch die kennzahlenbasierte Unternehmenssteuerung, ERP-Systeme oder Sensoren und spiegeln die realen Ereignisse wider. Unterschiedliche IT-Systeme speichern die Daten und bieten die Möglichkeit, interne mit externen Daten (z. B. in dem Logistikszenario Anlieferausfälle und deren Einfluss auf die Produktion mit Lagerbeständen und Wetterdaten) zu kombinieren und IT-gestützte Datenanalyseverfahren zur Einflussfaktorenanalyse, Simulation und Optimierung anzuwenden. Jene Informationen benötigt das Management für das Treffen von Entscheidungen und Kontrollen, weshalb sie als Rohstoff für Entscheidungs- und Kontrollprozesse zu betrachten sind [Alpar et al. 2019, 9].

Durch die umfassende Analyse der verknüpften externen sowie internen Daten herrscht im Zielzustand über alle Prozesse und Hierarchieebenen hinweg Transparenz bezüglich der Auswirkungen von Ereignissen sowie zu ergreifender Maßnahmen. Somit können Entscheidungsträger die effizientesten und effektivsten Alternativen zur Steuerung hinsichtlich der übergeordneten Unternehmensziele auswählen. In dem Logistik-Beispiel ist mittels der Datenanalyse die Vorhersage der Wahrscheinlichkeiten von Anlieferausfällen aufgrund der Wettersituation und die Simulation verfügbarer Maßnahmen möglich. Dies erleichtert das frühzeitige Treffen der

richtigen Entscheidungen, ohne dass kurzfristig weniger effiziente und weniger effektive Ad-hoc-Lösungen notwendig sind. Darüber hinaus sind die Auswirkungen der jeweiligen Ereignisse auf vor- oder nachgelagerte sowie Parallelprozesse (zum Beispiel die Produktion) prüfbar, ebenso wie die Wirkungen der alternativen Eingriffsmöglichkeiten hinsichtlich der übergeordneten Unternehmensziele.

Das Treffen von Entscheidungen und das Ableiten von Maßnahmen setzen voraus, dass ein definiertes Ziel zu erreichen ist [Rezgui 2018, 43]. Diese Ziele sind im Kontext der kennzahlenbasierten Unternehmenssteuerung durch quantitative Größen klar definiert, sodass die Zielerreichung objektiv evaluierbar ist [Rezgui 2018, 43]. Die Durchführung der Datenanalysen und die Evaluation der abgeleiteten Entscheidungen anhand der Zielkennzahlen führen somit perspektivisch zu besseren (mentalen) Modellen der komplexen Realität und deutlich verringerten Wissensdefiziten. Diese fließen in den Entscheidungsprozess ein und tragen zu verbesserten Entscheidungen und Handlungen bei, die ihrerseits wiederum neue, bessere Daten erzeugen, welche zukünftig zur Analyse zur Verfügung stehen: „The results of our actions define the situation we face in the future." [Sterman 2001, 12] Anhand der optimierten Modelle werden permanent neue Erkenntnisse über ehemals ausschließlich qualitativ erfasste Ursache-Wirkbeziehungen entlang der gesamten Wertschöpfungskette von Unternehmen gewonnen, die konsequent die eigene Validität prüfen [Kieninger et al. 2015, 6]. Der Analysefokus der Kennzahlen verschiebt sich somit stark von der reinen retrospektiven Prüfung der Erreichung definierter Ziele in Richtung der proaktiven Analyse, wie ein zukünftiges Ziel erreicht werden kann. Auf diese Weise entsteht von der operativen bis zur strategischen Steuerung von Unternehmen eine Positivspirale effektiverer sowie effizienterer Handlungen und Maßnahmen, die zum richtigen Zeitpunkt ergriffen werden und die unternehmerische Leistungsfähigkeit steigern. Darüber hinaus dient die Datenanalyse der quantitativen Prüfung und kontinuierlichen Verbesserung des Kennzahlengefüges im Unternehmen und stellt eine nachvollziehbare und wirksame Steuerung sicher.

Die prozess-, hierarchie- und unternehmensübergreifende Analyse von Daten zur proaktiven, kennzahlenbasierten Unternehmenssteuerung beschreibt die Vision der Digitalen Unternehmenssteuerung. Sie schließt ein, dass ein zunehmender Anteil an Entscheidungen in Unternehmen auf Maschinen übergehen wird. Dies wird zunächst vergleichsweise einfach strukturierte aber zunehmend auch komplexere Aufgabenstellungen betreffen. Die Zielstellung der vorliegenden Dissertation orientiert sich an der Vision der Digitalen Unternehmenssteuerung und untersucht, inwiefern die Hypothese, dass fortgeschrittene Datenanalysemethoden die Unternehmenssteuerung zukünftig fundamental verändern werden zu akzeptieren oder zurückzuweisen ist (vgl. [Wikfeldt 2016, 4]).

1.4 Forschungsfragen und Forschungsmethodik

Wie in den Kapiteln 1 und 1.1 dargestellt, zeigen zahlreiche Autoren in der wissenschaftlichen Literatur einen hohen Bedarf nach IT-basierter Unterstützung für die Planung, Steuerung und Kontrolle strategischer und operativer Geschäftsprozesse auf. Ursächlich dafür sind die exponentiell steigende Komplexität und Dynamik der Unternehmenssteuerung und eine unüberschaubare Menge an Wechselwirkungen innerhalb der Unternehmen und im Zusammenspiel mit deren Umwelt. Es gibt in der Wissenschaft Ansätze, das Verhalten komplexer Systeme zu verstehen und Unterstützung bei Entscheidungen zu deren zielgerichteter Steuerung anzubieten. Ungenutzte Potentiale zeigen sich in diesem Kontext in der Analyse von Kennzahlendaten aus den Unternehmen. Der Einblick in die Praxis in Kapitel 1.2 unterstützt die in der Wissenschaft diskutierten Fragestellungen und unterstreicht deren Relevanz. Darauf baut die Vision für die Digitale Unternehmenssteuerung in Kapitel 1.3 auf und stellt eine Sollvorstellung dar, auf welche Art und Weise, die Analyse von Kennzahlendaten zu dem Treffen von geeigneten Entscheidungen beitragen kann und welche Effekte dadurch erzielbar sind. Sie verdeutlicht, dass sowohl aus Sicht der Wissenschaft als auch der Praxis Analysen von Kennzahlendaten, die über beschreibende Methoden hinaus gehen, in der Zukunft eine wichtige Rolle einnehmen werden.

„Die Wirtschaftsinformatik geht […] von einer Sollvorstellung eines Informationssystems aus und sucht nach Mitteln, bei gegebenen Restriktionen ein Informationssystem mit diesem Ziel zu konstruieren.“ [Österle et al. 2010, 667] Die Vision der Digitalen Unternehmenssteuerung als Sollvorstellung bildet demnach die Grundlage für die Herleitung der folgenden Hauptforschungsfrage:

<u>Wie können Advanced Analytics[5]-Algorithmen zur Digitalen Unternehmenssteuerung beitragen?</u>

Zu deren Beantwortung ist es von zentraler Bedeutung ein Verständnis der betrieblichen Informationssysteme und ihrer Anwendungsbereiche zu erlangen und die Methoden und Techniken für die Gestaltung derartiger Informationssysteme zu untersuchen [Becker et al. 2003, 11]. Daher stellt die Beantwortung der Teilforschungsfragen 1 und 2 das Erkenntnisziel dieser Arbeit dar. Bei der Erarbeitung der Ergebnisse für die Teilforschungsfrage 1 steht im Fokus, die Herausforderungen für das kennzahlenbasierte Management großer Produktionsunternehmen sowohl aus Sicht der Wissenschaft als auch aus Sicht der Anwender zu verstehen:

<u>Welche Herausforderungen stellen sich dem Management großer Produktionsunternehmen bei der kennzahlenbasierten Unternehmenssteuerung?</u>

---

[5] Laut [Felden 2016] umfasst der Begriff Advanced Analytics „…moderne Verfahren der Auswertung großer Datenvorräte, vor allem Data Mining und maschinelles Lernen auf Grundlage der Künstlichen Intelligenz und statistischer Methoden.“ Eine weitere Begriffseinordnung folgt in Kapitel 3.4.

Aufbauend darauf wird in Teilforschungsfrage 2 untersucht, wie den Herausforderungen durch die Analyse von Kennzahlenrelationen begegnet werden kann und warum bestehende Methoden in der Praxis wenig Anwendung finden:

Wie können Kennzahlenrelationen zur Entscheidungsunterstützung in der Unternehmenssteuerung analysiert werden?

Das Gestaltungsziel der vorliegenden Dissertation ist der Entwurf einer Methode zur Informationssystemgestaltung für die Digitale Unternehmenssteuerung anhand der zuvor identifizierten Defizite bestehender Ansätze für die Analyse von Kennzahlenrelationen. Dies ist Gegenstand der Beantwortung der Teilforschungsfrage 3:

Wie kann die Digitale Unternehmenssteuerung mittels quantitativer Analyse von Kennzahlenrelationen implementiert werden?

Durch die Anwendung der Methode in einem realen Betrieb erfolgt deren Validierung [Becker et al. 2003, 11]. Diese Struktur kombiniert eine theoretisch fundierte Herleitung mit einer pragmatischen Ausrichtung der Wissenschaft und verbindet somit theoretische und methodische Strenge und Exaktheit mit hoher praktischer Relevanz [Töpfer 2012, 57]. Als Vorgehen für die Erarbeitung der Forschungsfragen eignen sich besonders der Erkenntnisprozess der gestaltungsorientierten Wirtschaftsinformatik nach [Österle et al. 2010] mit den Schritten Analyse, Entwurf, Evaluation und Diffusion sowie die Konsortialforschung nach [Österle/Otto 2010]. Die Beurteilung der Forschungsergebnisse in Kapitel 6.2 erfolgt gemäß den Kriterien des Design Science Research nach [Hevner et al. 2004, 84 ff.].

Nach [Österle et al. 2010, 4] kann der Anstoß für ein Forschungsthema für die Initialisierung des Analyseschrittes aus der Wissenschaft oder aus der Praxis kommen. Vorliegend kam dieser, wie in Abb. 1-3 dargestellt, aus der Praxis: In zahlreichen Expertengesprächen in der BMW Group wurde die beschriebene Problemstellung diskutiert. Anschließend dienten eine umfassende Literaturrecherche und der Austausch mit Experten mehrerer weltweit tätiger Beratungsunternehmen mit vieljähriger Erfahrung zur Prüfung, ob dies eine unternehmensspezifische Fragestellung darstellt oder sie auch bei anderen Produktionsunternehmen auftritt. Letzteres bestätigte sich, sodass eine Analyse bezüglich bestehender Lösungen in der Literatur und Praxis hinsichtlich deren Eignung für die Problemlösung folgte. Dabei wurden Experten der angesprochenen Unternehmen befragt sowie eine eigens beauftragte Marktstudie durch das Institut für Angewandte Informatik e.V. durchgeführt. Durch dieses problemorientierte, ingenieurwissenschaftliche Vorgehen [Peffers et al. 2007, 5, 14], zeichnete sich ein hoher Bedarf ab und die Vision hinsichtlich der Digitalen Unternehmenssteuerung entstand. Diese Analyse der Problemstellung in der Praxis sowie bestehender Lösungen und wissenschaftlicher Artefakte bildeten den Grundstein für eine praxisrelevante Forschung [Österle/Otto 2010, 275].

Die aufgestellten Forschungsfragen sind überwiegend „Wie“-Fragen, für deren Beantwortung nach [Yin 2018, 9] die Durchführung einer Fallstudie eine geeignete Vorgehensweise darstellt. Eine Fallstudie ist „…an empirical inquiry that investigates a contemporary phenomenon (the “case”) in depth and within its real-world context, especially when the boundaries between phenomenon and context may not be clearly evident… A case study copes with the technically distinctive situation in which there will be many more variables of interest than data points, and as one result benefits from the prior development of theoretical propositions to guide design, data collection, and analysis, and as another result relies on multiple sources of evidence, with data needing to converge in a triangulating fashion.” [Yin 2018, 15] Sie zählt zu den Techniken der gestaltungsorientierten Wirtschaftsinformatikforschung [Österle/Otto 2010, 280] ebenso wie der Design Science nach [Hevner et al. 2004, 86], sodass diese geeignete Forschungsrahmen darstellen. Folglich wurde für die Entwicklung eines praxistauglichen Artefaktes eine Fallstudie über einen Zeitraum von drei Jahren durchgeführt.

In ihrer Literaturanalyse arbeitet [Wikfeldt 2016, 7] mehrere Autoren zitierend heraus, dass Fallstudien mit einer Mehrzahl an Anwendungsfällen, die zueinander in Beziehung gesetzt werden, eine bessere Generalisierbarkeit aufweisen als Einzelfallstudien und eine Balance zwischen Generalisierbarkeit und Datenrelevanz liefern. [Gustafsson 2017, 4] betont dabei die Möglichkeit, „…to analyse the data within the case analysis, between the case analyses and make a cross-case analysis.” Dies geschieht im Folgenden schwerpunktmäßig in Kapitel 5 anhand von in Kapitel 4 aufgestellten Leitmerkmalen. Auch [Mariotto et al. 2014, 360] stellen fest, dass eine Generalisierbarkeit von Fallstudien durch mehrere Anwendungsfälle herstellbar ist, wenn auch trotzdem gewisse (vertretbare) Grenzen der Generalisierbarkeit gegeben sind. Für die vorliegende Fragestellung überwiegen jedoch die Vorteile dieser Vorgehensweise, da sie ferner ermöglicht, ein hohes Maß an Analysetiefe zu erreichen und durch die chronologische Darstellung die Inhalte verständlich und kontextbezogen zu vermitteln [Gustafsson 2017, 3–4]. Daher erfolgt die Erarbeitung der Ergebnisse dieser Dissertation anhand einer Mehrzahl von heterogenen Anwendungsfällen innerhalb der Fallstudie.

Im Rahmen der Anwendungsfälle wurden mehrere Arten der Erfassung von Evidenzen durchgeführt. Diese beinhalteten Dokumentenanalysen, teilnehmende Beobachtung, Workshops, Interviews und die Entwicklung sowie den Einsatz von Software [Yin 2018, 12]. Im Sinne einer evolutionären Entwicklung wurden mehrere prototypische Softwareimplementierungen erzeugt, in den Anwendungsfällen eingesetzt und somit neue Erkenntnisse für die Folgevarianten generiert [Österle/Otto 2010, 282]. Demnach sind Elemente des Action Research, bei welchen „…der Forscher selbst an der Lösung von Problemen der betrieblichen Wirklichkeit mitwirkt“ [Senger/Österle 2004, 16] enthalten. Als Resultat entstand eine Anwendung im Stadium eines Minimum Viable Product (MVP). Dieses integriert in deduktiver Form Methoden und Modelle der Kybernetik, Statistik und Datenanalyse, welche in wissenschaftlichen Publikationen umfassend untersucht wurden [Österle/Otto 2010, 275].

Durch die Kombination bestehender Theorien und der praktischen Anwendung wurde in Anlehnung an das Methoden Engineering nach [Gutzwiller 1994] deduktiv eine in der Praxis validierte Methode zur quantitativen Analyse von Kennzahlenrelationen mit dem Namen „KPI Intelligence“ erzeugt. Sie unterstützt Unternehmen bei der Umsetzung der Digitalen Unternehmenssteuerung (siehe Kapitel 4). Der Name „KPI Intelligence“ findet bereits für eine Software zur klassischen Kennzahlenanalyse [Dassault Systèmes 2018], zur Datenanalyse im Energiemanagement [May et al. 2015] sowie zur Verwaltung von Immobilienportfolios [Delsol/Solloway 2018] Anwendung. Der Grund dafür, ihn ebenfalls zu verwenden, liegt in seinem Schlagwortcharakter. „KPI“ als internationaler Begriff für Kennzahlen macht deutlich, dass Kennzahlendaten Gegenstand der Analyse sind. „Intelligence“ ist der Business Intelligence (siehe dazu Kapitel 3.1) entnommen und wird als Einsicht oder Verständnis interpretiert [Gluchowski et al. 2008, 89]. Das Management ist also nicht nur Konsument der Analyseergebnisse bezüglich der Kennzahlen, sondern fügt diese in den strategischen und operativen Handlungsrahmen ein [Schön 2018, 433]. Die Methode stellt ein Artefakt für die Digitale Unternehmenssteuerung zur IT-basierten Lösung der identifizierten Problemstellung in Produktionsunternehmen dar [Hevner et al. 2004, 77; Peffers et al. 2007, 13], welche wiederum induktiv Erkenntnisse für die Theorie liefert. Somit ist die laut [Töpfer 2012, 67] angestrebte Kombination von deduktivem und induktivem Vorgehen in der Wissenschaft gegeben.

Die Diffusion der Ergebnisse erfolgte durch Konferenzbeiträge, die vorliegende Dissertation und unternehmensintern durch Managementpräsentationen sowie die produktive Anwendung.

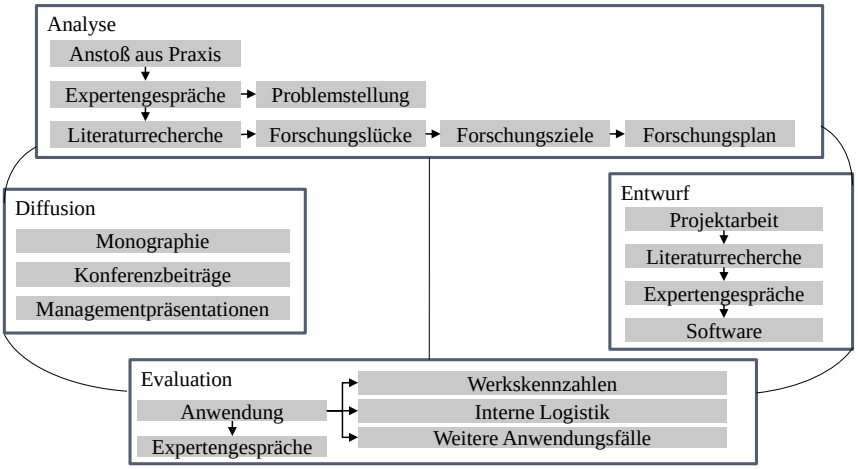

Abb. 1-3: Forschungsvorgehen [Österle et al. 2010, 4 f.]

Die Praxisnähe führte zu einer engen Verzahnung von Forschung, Softwareentwicklung und Anwendern während des gesamten Projektzeitraums. Einer der Experten eines Beratungsunternehmens wies darauf hin, dass die Berücksichtigung von Domänenwissen extrem wichtig ist, da es vorkommt, dass aufwendige Lösungen produziert werden, die letztlich nicht genutzt werden können, weil die Praxistauglichkeit außer Acht gelassen wurde [Interviews 01.02.2017 & 25.07.2018]. Zudem stellte die Verzahnung sicher, dass die Anforderungen wissenschaftlicher Strenge erfüllt sind [Österle/Otto 2010, 275]. Dieses ausbalancierte Vorgehen ist nach [Österle/Otto 2010, 276 f.] von zentraler Bedeutung, da in der Praxis sehr umfangreiches Wissen von hoher Wertigkeit bezüglich der Wirtschaftsinformatik vorhanden ist, welches permanent im Wettbewerb evaluiert wird. Fallstudien und Experteninterviews sind ein Element der gestaltungsorientierten Wirtschaftsinformatik, der Design Science und werden ebenfalls dem Action Research zugeordnet. Diese beziehen [Österle/Otto 2010, 280] als Techniken der Konsortialforschung ein. So sind die Ziele der Konsortialforschung nach [Österle/Otto 2010, 274] durch das beschriebene Vorgehen erfüllt:

- Durch die intensive Beteiligung der Praxis bei der Definition der Forschungsziele und Evaluation der Forschungsergebnisse wurde praxisrelevante Forschung betrieben.
- Der Forschungszeitraum, in welchem Zeit und Budget des Praxispartners einflossen, überschritt mit drei Jahren die geforderte Mindestgrenze von zwei Jahren deutlich.
- Durch umfangreiche Literaturanalysen ist bei der Gestaltung des Artefaktes die wissenschaftliche Strenge, aber auch die praktische Anwendbarkeit berücksichtigt worden (siehe dazu Kapitel 6.2).
- Die Ergebnisse werden sowohl in der Wissenschaft als auch in der Praxis verbreitet.

Fallstudien richten sich an Empfänger aus der Wissenschaft und der Praxis [Senger/Österle 2004, 23]. So werden in dieser Dissertation im Sinne der analytischen Generalisierung „…aus empirischen Untersuchungen Muster ermittelt und mit theoretischen Vorhersagen verglichen.“ [Senger/Österle 2004, 5] Sie richtet sich somit an Wissenschaftler, welche den Transfer von Advanced Analytics-Algorithmen in die praktische Anwendung sowie innovative Ansätze für die zukünftige Steuerung von Unternehmen untersuchen. Ferner adressiert sie Entscheidungsträger großer Produktionsunternehmen sowie Reportingstellen und das Controlling in den Unternehmen, welche gemäß einer erfahrungsbasierten Generalisierung aufgrund persönlicher Erfahrungen Schlussfolgerungen aus den Erkenntnissen ziehen können (vgl. [Senger/Österle 2004, 5 f.]).

1.5 Inhaltliche Struktur der Arbeit

Nach der Beschreibung der Herausforderungen für das Management bei der Steuerung großer Produktionsunternehmen aufgrund ihrer übermäßigen Komplexität im ersten Kapitel, gestaltet sich der weitere Aufbau der Dissertation zur Beantwortung der Forschungsfragen folgendermaßen:

Kapitel 2 legt mit den Grundlagen der Unternehmenssteuerung den theoriebasierten Grundstein für die Arbeit, indem die Sicht der systemtheoretischen Interpretation von Unternehmen eingenommen und zentrale Eigenschaften auf die prozessorientierte Steuerung von Unternehmen übertragen werden. Da Kennzahlen und Kennzahlensysteme zentrale Hilfsmittel für die Steuerung von Prozessstrukturen darstellen, schließen sich grundlegende Betrachtungen dieser aus theoretischer und praktischer Perspektive an und führen zur aktuellen Vorgehensweise der Analyse von Ursache-Wirkbeziehungen zur Entscheidungsunterstützung anhand von Kennzahlen als Repräsentanten für die zugehörigen Prozesse. Das Kapitel endet mit der Beantwortung der Teilforschungsfrage 1 und der Ableitung von Anforderungen an die kennzahlenbasierte Unternehmenssteuerung.

Angesichts der praktizierten Vorgehensweisen der empirischen Ermittlung von Ursache-Wirkbeziehungen und den erarbeiteten Anforderungen an die Unternehmenssteuerung ist die Erfassung des Status quo von Entscheidungsunterstützungssystemen für die Unternehmenssteuerung Gegenstand des dritten Kapitels. Das Hauptaugenmerk liegt dabei auf dem Einsatz von Advanced Analytics-Algorithmen in der Business Intelligence. Eine Erkenntnis daraus ist, dass Advanced Analytics unzureichend für die Analyse von Ursache-Wirkbeziehungen eingesetzt wird. Die Untersuchung wissenschaftlicher Ansätze ermöglicht die Identifikation von Defiziten, welche den flächendeckenden, praktischen Einsatz der Lösungen verhindern und somit die Ableitung von Leitmerkmalen für Analysesoftware zur Förderung des Einsatzes von Advanced Analytics für die Analyse von Kennzahlenrelationen. Die Leitmerkmale sind ein wesentlicher Bestandteil der Beantwortung der Teilforschungsfrage 2. Die bis dahin gewonnenen Erkenntnisse verdeutlichen den fachspezifischen Blickwinkel, aus welchem die Forschung betrieben wird [Töpfer 2012, 46].

Gleichermaßen sind die Leitmerkmale ein Element der KPI Intelligence Methode, einer Methode für die Digitale Unternehmenssteuerung. Deren Vorstellung erfolgt im vierten Kapitel. Sie stellt das zentrale Ergebnisartefakt der vorliegenden Dissertation dar. Ihre schrittweise Entstehung beziehungsweise Weiterentwicklung zeigt Kapitel 5 anhand einer Fallstudie bei der BMW Group, welche mehrere Anwendungsfälle umfasst. Daraus ergibt sich der Beitrag der Methode für die quantitative Analyse von Kennzahlenrelationen in der Praxis und beantwortet gleichermaßen Teilforschungsfrage 3.

Kapitel 6 fasst die Erkenntnisse der Dissertation durch die Beantwortung der Hauptforschungsfrage zusammen, ordnet das Forschungsvorhaben gemäß der Leitlinien des Design Science Research ein, enthält eine kritische Würdigung und schließt mit einem Ausblick hinsichtlich zukünftiger Forschungsbedarfe.

2 Grundlagen der Unternehmenssteuerung

In den vorangegangenen Ausführungen bezüglich der Unternehmenssteuerung großer Produktionsunternehmen stellen Prozesse, Systeme, deren Ursache-Wirkbeziehungen und deren kennzahlenbasierte Steuerung zentrale Aspekte dar. Ein einheitliches Verständnis dieser Begrifflichkeiten ist von großer Bedeutung für die Erarbeitung eines Lösungsansatzes für die Herausforderungen, denen sich das Management gegenübersieht.

2.1 Systemtheoretische Betrachtung von Unternehmen

Die Kapitel 1.1 und 1.2 legen unter anderem dar, dass Unternehmen als überaus komplexe, probabilistische Systeme interpretierbar sind. Nach [Beer 1959, 9] ist ein System alles, was aus miteinander verbundenen Teilen besteht. Auf ähnliche Weise beschreiben [Trier et al. 2013, 42] ein System als ein aus „…mehreren Teilen zusammengesetztes und gegliedertes Ganzes“. [Karnopp et al. 2012, 1 f.] und [Rüegg-Stürm 2014, 7 f.] ergänzen, dass diese Systeme von ihrer Umwelt unterscheidbar sind.

Im Folgenden stehen die Beziehungen und gegenseitigen Beeinflussungen, die innerhalb der Systeme und mit deren Umwelt bestehen, im Fokus, da diese ursächlich für die Systemkomplexität sind. Auf die vernetzten Elemente sind die Dynamik [Malik 2013, 29] und das Verhalten, die es zu verstehen [Beer 1959, 10] und zu steuern [Trier et al. 2013, 62] gilt, zurückzuführen. Die Dynamik bezieht sich dabei auf den Zeitbezug der Systemzustände und -eigenschaften von Unternehmen [Trier et al. 2013, 62]. Folglich gliedert sich diese Dissertation in die Systemtheorie, beziehungsweise Kybernetik[6], ein, welche [Schwaninger 2004, 4] als „…eine formale Wissenschaft von der Struktur, den Verknüpfungen und dem Verhalten komplexer Systeme“ auffasst.

Das Konzept der Kontrolle im Sinne der Kybernetik beinhaltet die Regulierung und Steuerung eines Systems zur Erreichung der übergeordneten Zielstellung [Schwaninger 2001, 139]. Dabei ist wichtig zu beachten, dass ein System in der Regel Teil eines umfassenderen Systems (Supersystem) sein und sich aus Teilsystemen (Subsystemen) zusammensetzen kann [Schwaninger 2004, 4]. Die Erreichung der Ziele eines Supersystems sollte also, eine ideale Zielsteuerung angenommen, von der Erreichung der Ziele der Subsysteme abhängen. Der wertschöpfende Beitrag, der dafür notwendig ist, wird durch das Durchlaufen von Prozessen erreicht [Rüegg-Stürm 2014, 13]. Diesem Gedanken folgend bietet es sich an, Unternehmen als Systeme von Prozessen, charakterisiert durch interdependente Elemente und

[6] [Schwaninger 2004, 4] nutzt die Begriffe Systemtheorie und Kybernetik synonym.

Aufgaben sowie Kunden- und Lieferantenbeziehungen, zu betrachten [Rüegg-Stürm 2014, 53]. Die in Kapitel 1.2 angesprochene Prozessstruktur der BMW Group fügt sich anhand ihrer Organisationsstruktur mit Vorgänger-Nachfolger-Beziehungen, Parallelprozessen und dem hierarchischen System der Prozesse (im Sinne von Super- und Subprozessen) in dieses Verständnis ein. Vor diesem Hintergrund lassen sich jene genannten Charakteristika von Systemen auf Prozesse übertragen und die prozessorientierte Steuerung von Systemen untersuchen.

2.2 Prozessorientierte Steuerung von Systemen

Das Auseinandersetzen mit der Steuerung von Unternehmen führt automatisch zum Controlling. Dieses richtet sich klassischerweise hauptsächlich nach monetären Ergebnisgrößen wie Umsatzentwicklung, Deckungsbeiträgen, Kostenstellen, -arten und -trägern und ist daher für die Unterstützung der Prozesssteuerung nur bedingt geeignet [Hirzel 2013, 47]. Für das Controlling von Prozessen bieten sich beispielsweise Größen wie Prozesskosten, Durchlaufzeit und Qualität an [Neumann et al. 2012, 308 f.]. Im Sinne eines integrierten Ansatzes sollte das Unternehmenscontrolling in Abstimmung mit der Prozesssteuerung fungieren, da letztere der strategiekonformen Ausrichtung der Prozesse dient [Gericke et al. 2013, 30]. Daher spielen Größen des Prozesscontrollings im Folgenden und insbesondere in den Kapiteln 5.3 und 5.5 eine zentrale Rolle.

[Guschlbauer/Lichka 2013, 281 ff.] beschreiben die Aufgaben der Prozesssteuerung anhand eines Regelkreises mit den Phasen der initialen Einführung, einem Controlling-Zyklus sowie einem Review-Zyklus. Die initiale Einführung beinhaltet die Erhebung notwendiger Grundlagen, die Validierung bestehender Inputs und die Definition eines Zielszenarios [Guschlbauer/Lichka 2013, 281]. Gegenstand des Controlling-Zyklus ist die Etablierung der Rahmenbedingungen für Entscheidungs- und Bewertungsgrundlagen und die daraus abgeleiteten Projekte und Maßnahmen [Guschlbauer/Lichka 2013, 281]. Letztlich befasst sich der Review-Zyklus mit der kontinuierlichen Verbesserung des Prozesscontrollings und der Anpassung an die Unternehmens- und Umwelterfordernisse [Guschlbauer/Lichka 2013, 281].

Bei der prozessorientierten Unternehmenssteuerung ist von zentraler Bedeutung, „…dass nicht die interne Unternehmensorganisation einen Mehrwert für den Kunden bildet, sondern die effiziente und effektive Gestaltung der zur Erfüllung der Kundenbedürfnisse notwendigen Aufgaben.“ [Alt/Puschmann 2016, 55] Daher erfolgt die Ausrichtung und Beurteilung der Prozessleistungen und Aufgaben des Unternehmens anhand der Anforderungen interner oder externer Kunden, die sowohl den Start- als auch Endpunkt der Prozesse bilden [Alt 2008, 103]. Damit beabsichtigt das Management die effiziente, geschäftseinheitsübergreifende Abwicklung von Prozessen ohne Effizienzverluste durch kostenstellen- oder abteilungsbedingtes Silodenken [Gladen 2014, 400] und die kontinuierliche Verbesserung der betrieblichen Abläufe [Linden 2016, 213].

Passend zu diesem Verständnis der Prozesssteuerung definiert [Alt 2008, 96], (Geschäfts-) Prozesse[7] als auf den Kundennutzen ausgerichtete Kernaktivitäten, welche ihrerseits auf der Infrastruktur und den Leistungen von Unterstützungsprozessen aufbauen.[8] Die ISO 9000:2015 beschreibt einen Prozess als einen „…Satz von in Wechselwirkung stehenden Tätigkeiten, der Eingaben in Ergebnisse umwandelt" [Deutsches Institut für Normung 2015, 15]. Insofern sind Prozesse eine Menge an Aufgaben und konsumieren und produzieren Leistungen [Legner 1999, 20, 92]. Diese Art der Prozessdefinition legt den Fokus stärker auf den Input-Transformation-Output-Gedanken und ergänzt die kundenzentrierte Interpretation von Prozessen nach [Alt 2008]. Die für die Transformation auszuführenden Tätigkeiten sind ferner in einer mehr oder weniger standardisierten Abfolge zu erledigen und können durch Informationssysteme unterstützt werden [Rüegg-Stürm 2014, 52]. [Legner 1999, 91] zur Folge konkretisieren Prozesse somit die Unternehmensstrategie.

Die Gestaltung von Abteilungshierarchien spielt für die Prozesssteuerung eine untergeordnete Rolle, während die Identifikation neuer Leistungen, die Eliminierung redundant ausgeführter Aufgaben, die Parallelisierung von Aufgaben und die Verbesserung der Leistungsfähigkeit des Gesamtunternehmens durch einen gesteigerten Beherrschungsgrad der Prozesse angestrebt werden [Alt 2008, 5]. Zu diesem Zweck sind klare, einfache und bereichsübergreifende Prozesse mit möglichst wenigen Ineffizienzen wie Koordinationsbedarfen durch Schnittstellen, Intransparenz und Redundanz zu erzeugen [Alt 2008, 102].

Demnach beinhaltet das Prozessmanagement Prozessentwurf und -führung und beschreibt sowohl die operativen, als auch die strategischen Maßnahmen zur Gestaltung, kontinuierlichen Kontrolle und Weiterentwicklung von Prozessen[9] [Alt 2008, 10]. Die Ergebnisse der Prozesse lassen sich anhand von Kennzahlen messen [Österle 1995, 19]. Diese unterstützen bei der Kontrolle, der Ableitung von Maßnahmen und der Schaffung von Transparenz. Daher folgt ein Überblick über die kennzahlenbasierte Steuerung von Prozessen.

---

[7] In der Literatur wird i. d. R. zwischen Prozessen und Geschäftsprozessen nicht unterschieden [Becker/Winkelmann 2014, 62].

[8] Dies spiegelt sich auch in der Unternehmensorganisation der BMW Group wider (siehe Kapitel 1.2), deren Prozesse auf die Erbringung des (internen sowie externen) Kundennutzens ausgerichtet sind.

[9] Siehe dazu auch: Business Engineering [Österle 1995]

2.3 Kennzahlenbasierte Prozesssteuerung

Kennzahlen stellen eine Grundvoraussetzung für die wirkungsvolle Steuerung großer Produktionsunternehmen dar [Zeise 2010, 64]. Dies unterstreicht die Norm ISO 9001, welche fordert, dass die Daten und Informationen, die bei der Überwachung, Messung, Analyse und Bewertung von Prozessen anfallen, zu analysieren und zu bewerten sind [ISO 2015, 40 ff.]. Der Großteil der Steuerungsmaßnahmen auf dieser Basis betrifft das laufende oder das kommende Geschäftsjahr. In diesem Zeitraum spricht man von operativer Steuerung [Steuernagel 2017, 21]. Allerdings werden auch zunehmend strategische Entscheidungen durch Kennzahlen quantifiziert [Steuernagel 2017, 5]. Vor diesem Hintergrund folgt in den nächsten Abschnitten die Betrachtung einiger bedeutsamer Charakteristika von Kennzahlen und Kennzahlensystemen sowie deren Erstellungsprozesse, Nutzenaspekte, Herausforderungen und Anforderungen. Diese geben jeweils einen kurzen Überblick für die fortlaufende Argumentation der vorliegenden Arbeit, bilden die jeweiligen Forschungsfelder jedoch nicht vollumfänglich ab.

2.3.1 Charakteristika von Kennzahlen

Sowohl in der deutsch- als auch in der englischsprachigen Literatur gibt es zahlreiche Definitionen und Begriffe für Kennzahlen (z.B. KPI, Messgröße, key metric, key figure, key measures) sowie zahlreiche Perspektiven, aus denen sie betrachtet werden (z.B. strategisch[10]/operativ). Eine Möglichkeit der Interpretation ist hierarchischer Natur: “Not all metrics are indicators, not all indicators are KPIs either, but all KPIs are indicators and all indicators are metrics…” [Peng et al. 2008, 196] Für den vorliegenden Beitrag ist ein praxistaugliches Verständnis notwendig, weshalb diese Begriffe ähnlich der Verwendung von ´metrics´ unter der Bezeichnung ´Kennzahlen´ subsumiert werden.

Kennzahlen lassen sich in absolute Zahlen und Verhältniszahlen unterteilen [Küpper 2013, 472]. Unabhängig von weiteren Subklassifizierungen ist eine absolute Kennzahl in der Automobilfertigung beispielsweise die Stückzahl produzierter Fahrzeuge oder die Zeitangabe für einen durchlaufenen Prozess. Aber auch externe Informationen wie die Temperatur an einem für den Prozess relevanten Ort stellen derartige Kennzahlen dar. Eine Verhältniszahl ist zum Beispiel die Direktläuferquote. Unter dem Gesichtspunkt, dass das Ziel dieser Arbeit ein Ansatz zur quantitativen Analyse von Kennzahlen, der sowohl strategische als auch operative, sowohl interne als auch externe und sowohl absolute als auch Verhältniszahlen berücksichtigt, ist, eignet sich die folgende Definition: Kennzahlen sind quantitative, für die

[10] Bspw.: „KPIs are defined as quantifiable and strategic measurements that reflect an enterprise’s critical success factors” [ISO 2014], V.

spezifischen Bedürfnisse der Unternehmensanalyse und -steuerung aufbereitete Informationen [Gladen 2014, 9]. Sie informieren über frühere Zustände und dienen als Grundlage fundierter Managemententscheidungen [Hesse/Groh 2014, 1].

In den vorangegangenen Kapiteln ging es wiederholt um die Steuerung im Sinne der übergeordneten Unternehmensziele. Der Hintergrund ist, dass die richtige Zielsetzung und -steuerung elementar für den Unternehmenserfolg sind [Steuernagel 2017, 18]. Diese Ziele können beispielsweise Gewinne, Wachstum, Kunden- und Mitarbeiterzufriedenheit oder ethische Ziele sein, die in Beziehungen zueinander stehen [Steuernagel 2017, 18]. Sie dienen der Unternehmenssteuerung direkt, indem Kennzahlen mit Zielwerten für diese versehen werden. Jene sind ´verzielte Kennzahlen´. Aus den quantifizierten Oberzielen in Form von verzielten Kennzahlen leitet das Management mittels Ursache-Wirkbeziehungen gleichermaßen quantifizierte Unterziele ab [Gladen 2014, 257]. Derartige Zielvereinbarungen zwischen Managern unterschiedlicher Hierarchieebenen setzen die Verfügbarkeit geeigneter Kennzahlen voraus. Dabei besteht die Möglichkeit, sich an bestehenden Größen wie denen der ISO 22400-2:2014 zu orientieren.

Weitere Kennzahlen erstellen Prozessexperten auf Grundlage ihres Fachwissens [Rodriguez et al. 2009, 104; Peng et al. 2008, 198] oder auf Grundlage von Methoden zur Erzeugung von Kennzahlensystemen. Letztere werden in Kapitel 2.3.5 genauer betrachtet. Ebenso besteht die Möglichkeit einer informationstechnischen Unterstützung durch Data Warehouse Systeme im strategischen Planungsprozess und bei der Kennzahlendefinition [Navrade 2008]. Um die Kennzahlen zur Unternehmenssteuerung nutzen zu können, sind bei der Definition bestimmte Anforderungen zu erfüllen. Diese hat [Richter 2007, 25 f.] auf wissenschaftlicher Literatur basierend in einer Übersicht dargestellt (siehe Tabelle 2-1).

Im vorliegenden Kontext besonders hervorzuheben sind die Anforderungen, dass Kennzahlen, anhand derer ein Prozess oder ein Unternehmen zu steuern sind, auch für das Top-Management anwendbar und durch den Zielenehmer beeinflussbar sein sollen. Dies verdeutlicht, dass Kennzahlen einen erheblichen Nutzen für die Unternehmenssteuerung haben, aber auch Herausforderungen mit sich bringen.

Kriterium	Erklärung
Aktualität	Eine Kennzahl ist aktuell, wenn sie den aktuellen Gegebenheiten entspricht, also betriebliche Tatbestände und Prozesse realistisch und zeitnah („up- to- date“) abbildet, und überdies tatsächlich für die Steuerung bzw. Diagnose genutzt wird.
Akzeptanz	Eine Kennzahl gilt als akzeptiert, wenn sie von allen Mitarbeitern und auch vom Top- Management als Mittel zur Leistungsmessung und -bewertung anerkannt und aktiv angewendet wird.
Beeinfluss-barkeit	Eine Kennzahl ist beeinflussbar, wenn bestimmte Maßnahmen eine entsprechende Auswirkung auf ihren Wert haben.
Empfind-lichkeit	Eine Kennzahl ist empfindlich, wenn sie bedeutende Fehler bzw. Störungen im Prozess reflektiert und ein schnelles Aufdecken von Prozessveränderungen ermöglicht.
Kompati-bilität	Eine Kennzahl ist kompatibel, wenn sie aus den vorhandenen betrieblichen Informationssystemen ableitbar ist.
Relevanz	Eine Kennzahl ist relevant, wenn sie ausschließlich entscheidungsrelevante Informationen abbildet und ein positiver Trend der Kennzahl im Zusammenhang mit einer signifikanten Leistungsverbesserung steht.
Validität	Eine Kennzahl besitzt die entsprechende Validität, wenn sie den zu messenden Sachverhalt spezifisch abbildet und die zu ihrer Ermittlung verwendete Messmethode die erforderliche Zuverlässigkeit aufweist.
Vergleich-barkeit	Eine Kennzahl ist vergleichbar, wenn sie von verschiedenen Benutzern vergleichbar interpretiert werden kann und damit sowohl eine inner- und zwischenbetriebliche als auch eine Vergleichbarkeit zu verschiedenen Zeitpunkten gewährleistet.
Verständ-lichkeit	Eine Kennzahl ist verständlich, wenn sie eine eindeutige und einheitliche Definition besitzt und ihre Darstellungsform für alle Mitarbeiter verständlich und nachvollziehbar ist.
Wirtschaft-lichkeit	Eine Kennzahl ist wirtschaftlich, wenn der Kosten- und Zeitaufwand der einmaligen Aufstellung sowie der laufenden Erhebung und Verarbeitung gegenüber dem Nutzen aus der Überwachung der Kennzahl in einem effizienten Verhältnis steht.

Tabelle 2-1: Anforderungen an Kennzahlen [Richter 2007, 25 f.]

2.3.2 Nutzen der Kennzahlensteuerung

Hinsichtlich der Aufgaben, die Kennzahlen zur Entscheidungsunterstützung erfüllen und den Nutzen, der durch sie erzeugt wird, gibt es in der Literatur ebenfalls umfassende Untersuchungen (siehe Kapitel 2.3.1). Einige dieser Aspekte sind jedoch von besonderer Bedeutung für die Komplexitätsbewältigung in der Unternehmenssteuerung.

Konkretisierung der Unternehmensziele. Die Festlegung der im vorherigen Kapitel angesprochenen Prozessziele geschieht basierend auf der strategischen Ausrichtung des Unternehmens. Dazu erfolgt die Übersetzung der Unternehmensziele in verzielte Kennzahlen [Gladen 2014, 183], was die Verbreitung der Ziele im Unternehmen fördert [Norreklit 2000, 70]. Sie geben die Richtung der operativen Steuerung vor, wodurch der Unternehmenserfolg langfristig gesichert werden soll [Steuernagel 2017, 4].

Orientierungsfunktion. Durch die Definition von Zielvorgaben stellen Kennzahlen eine Orientierungshilfe für das Management dar. Dieses richtet dadurch sein Handeln auf die Unternehmensstrategie aus [Gladen 2014, 183]. Somit dienen verzielte Kennzahlen als Steuerungsinstrument [Küpper 2013, 478; ISO 2014, VII].

Kontrolle der Zielerreichung. Die Festlegung von Zielwerten, Warn-/Eingriffsgrenzen sowie Zielkorridoren für Kennzahlen erlaubt die Überprüfung der Zielerreichung in Form von Soll-/Ist-Vergleichen oder den Abgleich mit erwarteten Werten [Steuernagel 2017, 23; ISO 2014, VII; Rodriguez et al. 2009, 104]. Sowohl kurz- (untertägig/live) als auch langfristiges Monitoring ist mit Kennzahlen realisierbar, weshalb sie sich ebenfalls gut zur Dokumentation eignen [Gladen 2014, 25; ISO 2014, VII].

Reduktion der Menge an Informationen und der Komplexität. Kennzahlen helfen dem Management angesichts der komplexen zu steuernden Prozesse, Informationen transparenter darzustellen und die Detailfülle zu reduzieren [Gladen 2014, 27]. So ist die relativ einfache Darstellung von Sachverhalten, Strukturen und Prozessen zur Erlangung eines schnellen Überblicks und als Grundlage für Analysen ein wichtiger Beitrag zur Unternehmenssteuerung [Gladen 2014, 10]. Beispielsweise geben Verhältniszahlen aufsummierte Auskünfte über Prozesse [Schmalzried et al. 2013, 209].

Transparenz über das Verhalten des Unternehmens. Durch den Einsatz von Kennzahlen steigt die Transparenz hinsichtlich prozessualer Beziehungen innerhalb eines Unternehmens, sodass entscheidende Zusammenhänge leichter erkennbar sind [ISO 2014, V; Zeise 2010, 64]. Somit geben sie Hinweise auf die Wirkungen bezüglich der angestrebten Ziele [Gladen 2014, 372], unterstützen die Identifikation von Problemen [ISO 2014, VII], die Ableitung von Maßnahmen [Steuernagel 2017, 5] sowie das Setzen von Prioritäten und die Konzentration auf Schwerpunkte [Gladen 2014, 27].

2.3.3 Herausforderungen der Kennzahlensteuerung

Neben den zahlreichen positiven Aspekten birgt die Kennzahlensteuerung auch Herausforderungen, die es zu berücksichtigen gilt. Im Kontext der Digitalen Unternehmenssteuerung werden dabei insbesondere diese Aspekte adressiert:

Reaktive Steuerung mit Kennzahlen. Wie in Kapitel 1.2 bereits angesprochen, erfüllt die retrospektive Abbildung von Kennzahlen die Reporting-Anforderungen von Führungskräften nicht mehr. Die klassische reaktive Steuerung muss durch eine antizipierende Steuerung ersetzt werden [Cokins 2013, 69]. Dabei sollten Kennzahlen nicht nur als Zusammenfassung für das Monitoring dienen, sondern als aktive Steuerelemente zur Erreichung der strategischen Ziele [Cokins 2013, 71]. [Hammer/Hershman 2010, 83] stellen darüber hinaus fest, dass die besten Kennzahlen die Leistungen von Prozessen vorhersagen, anstatt diese nur wiederzugeben. Ein extremes Beispiel für Kennzahlen, die nur eine reaktive Steuerung erlauben, liefern [Reichmann/Hoffjan 2011, 52], bei welchem bis zu 40 Tage zwischen dem Auftreten eines Fehlers und dessen Sichtbarkeit in der entsprechenden Kennzahl vergehen.

Zu große Menge an Kennzahlen. Eine Zielstellung von Kennzahlen ist die Reduktion der Menge an Informationen und Komplexität, denen das Management von Produktionsunternehmen ausgesetzt ist. Allerdings zeigt sich, dass Entscheidungsträger auch in der Vielzahl der Kennzahlen häufig den Überblick verlieren [Hesse 2015, 18]. Sie erwarten einen verbesserten Abgleich der zur Verfügung gestellten Informationen mit ihren Bedürfnissen sowie damit einhergehend eine Verringerung der Berichtsanzahl [Becker/Winkelmann 2014, 56].

Fehlsteuerung. Zwar unterstützen Kennzahlen die Unternehmenssteuerung und die Verbreitung der Unternehmensziele, allerdings ist kritisch zu prüfen, inwiefern sie tatsächlich zur Durchsetzung des Willens der steuernden Instanz beitragen [Gladen 2014, 31]. Die Verantwortlichen streben danach, die Zielstellungen von Kennzahlen zu erreichen (sogar, wenn dies kontraproduktiv ist), da diese ihren persönlichen Erfolg messen und Honorierungen daran geknüpft sein können [Hammer/Hershman 2010, 72]. So bestehen Gefahren der Fehlsteuerung und Ineffizienzen durch den Einsatz ungeeigneter Kennzahlen, die obendrein ein falsches Gefühl der Sicherheit vermitteln, wenn die Zielwerte erreicht sind.

Intransparente Ursache-Wirkbeziehungen. Die Kenntnis der Ursachen für bestimmte Ereignisse im Unternehmen ist von zentraler Bedeutung für das Management. Jedoch sind Kennzahlen häufig initial nicht gut definiert, sodass die Interpretation von deren Beziehungen und die Identifizierung von zur Steuerung geeigneten Kennzahlen eine sehr schwierige Aufgabe darstellen [Suwignjo et al. 2000, 232]. Zwar hat die Aggregation von Informationen zum Beispiel in Form von Verhältniskennzahlen eine komplexitätsreduzierende Wirkung, allerdings entsteht dadurch im Umkehrschluss ein Informationsverlust und die Berechnungsformeln sind nicht immer transparent. Die Bedeutung dieser theoretischen Erkenntnisse zeigt sich im nächsten Abschnitt bei der Analyse des praktischen Umgangs mit Kennzahlen.

2.3.4 Kennzahlensteuerung in der Praxis

Um ein umfassendes Verständnis für die kennzahlenbasierte Unternehmenssteuerung in der BMW Group zu erhalten, wurden zusätzlich zu bestehenden Analysen und zur aktiven Mitarbeit in mehreren Projekten und Workshops standortübergreifend zahlreiche Interviews und Expertengespräche geführt. Die teilnehmenden Personen (-gruppen) waren verschiedenen hierarchischen Ebenen (vom Meister bis zur Werkleitung), vielfältigen funktionalen Bereichen (Montage, Lackierung, Karosseriebau, Logistik) und diversen fachlichen Aufgaben (bspw. IT, Reportingstellen, Produktionssteuerung) zugeordnet.

Das Spektrum der durch diese Experten angewendeten Berichtstechnologien erstreckt sich von PDF/PowerPoint-Berichten und Excel-Dateien über Management-Cockpits und Dashboards bis hin zur Anwendung von Statistik-Software. Die jeweiligen Umsetzungen sind abhängig von den sehr unterschiedlichen Anforderungen der Führungskräfte, beinhalten aber überwiegend Diagramme und Kennzahlen (mit deren zeitlichem Verlauf) inklusive der Soll-, Ist- und weiterer Referenzwerte [Interview 15.02.2018].

Auf Arbeitsebene finden in Abhängigkeit des genauen Aufgabenbereiches in der Regel drei bis fünf relevante Kennzahlen Anwendung [Hesse 2015, 169]. Der Werkleiter des BMW Group Werks Leipzig hingegen erhält Zielvorgaben für 18 Kennzahlen. Diese werden im so genannten Zielemanagementsystem erfasst und auf die darunter liegenden Ebenen heruntergebrochen. Dies dient dem Nachweis für den praktischen Einsatz der verzielten Kennzahlen für die Steuerung, was bei externen Audits eine zentrale Anforderung ist [Interview 15.02.2018]. Das Herunterbrechen der Zielvorgaben erfolgt im Zielemanagementprozess (ZMP), in welchem vier Rollen definiert werden:

ZMP Steuerer	• Verantwortet die ressortspezifische Information und Kommunikation (Ressorts: siehe Kapitel 1.2). • Steuert die Vorbereitung der Zielvereinbarung und Zielereviews der zugeteilten Berichtsebene zentral.
Zielegeber	• Sorgt für die hierarchische Zielvereinbarung und stellt die eindeutige Zieldefinition sicher. • Gibt die Ziele vor und benennt einen Steuerungsverantwortlichen. • Fordert regelmäßig Reviews zum Zielestatus vom Zielenehmer.
Zielelenker	• Pflegt die Soll- und Ist-Werte der Kennzahlen und erstellt Abweichungsdokumente[11]. • Gibt Abschätzung zur Zielerreichung zum Jahresende. • Bricht gemeinsam mit dem Zielenehmer jährliche und monatliche Zielwerte auf vereinbarte Ebenen herunter.
Zielenehmer	• Verantwortet gemeinsam mit dem Steuerungsverantwortlichen die Erreichung der vereinbarten BSC und der operativen Ziele. • Verantwortet seinen Zielbeitrag und die termingerechte Bereitstellung geforderter Reviews. • Beurteilt die Machbarkeit der Erfüllung des Zielbeitrags. • Informiert über Status, Chancen und Risiken. • Definiert und setzt Maßnahmen zur Erfüllung des Zielbeitrags um.

Tabelle 2-2: Rollen des Zielemanagementprozesses [interne Dokumente]

Der ZMP bewirkt eine systematische **Konkretisierung der Unternehmensziele** sowie deren Verbreitung. Darüber hinaus werden diese Kennzahlen für die tägliche Steuerung um weitere Größen ergänzt. [Gladen 2014, 254 f.] stellt fest, dass die Auswahl zusätzlicher Kennzahlen in Unternehmen häufig nicht anhand von sachgerechten Kriterien, sondern induktiv anhand von Erfahrungswissen erfolgt. Dieses erwerben die Verantwortlichen üblicherweise in einem evolutionären Prozess. In der sich aktuell und zukünftig schnell und stark verändernden Unternehmensumwelt besteht aber die Gefahr, dass diese Größen den obersten und langfristigen Unternehmenszielen nicht dienen [Gladen 2014, 254 f.].

[11] Abweichungsdokumente werden erstellt, wenn Kennzahlen von Zielwerten abweichen [Interview 15.02.2018]. Sie enthalten insbesondere Ursachen für die Abweichungen und strategische sowie operative Maßnahmen mit Verantwortlichen, Fortschrittsmessung und Zieltermin.

Im Anschluss an die Definition und die Kommunikation einer Kennzahl sind Möglichkeiten zur Verbesserung von deren Werten zu entwickeln [Hammer/Hershman 2010, 89]. Die Führungskräfte **orientieren** sich also bei der Ableitung von Maßnahmen an ihren Kennzahlen [Interview 17.07.2018; Interview 23.02.2018; Interview 15.08.2018]. In der Konsequenz entsteht eine **Fehlsteuerung**, falls ungeeignete Kennzahlen vorliegen. Darüber hinaus kann es passieren, dass, sollten die Kennzahlen ungünstig gewählt worden sein, Mitarbeiter interdependenter Verantwortungsbereiche nicht kooperativ im Sinne der übergeordneten Ziele handeln, um die eigenen Zielwerte zu erreichen (Silodenken) [Interview 17.07.2018].

Sollte sich bei der **Kontrolle der Zielerreichung** zeigen, dass eine Kennzahl (z. B. durch Überschreiten einer Eingriffsgrenze) in einen als kritisch definierten Status gewechselt hat, suchen die Verantwortlichen unter Verwendung verfügbarer relevanter Informationen nach möglichen Ursachen dafür [Hesse 2015, 174]. Auf diese Weise erfolgt die **kennzahlenbasierte Unternehmenssteuerung reaktiv** [Interview 23.02.2018; Interview 15.08.2018; Interview 23.08.2018]. Im Bewusstsein der Defizite der reaktiven, kennzahlenbasierten Unternehmenssteuerung besteht großes Interesse an deren Verbesserung durch Prognosen und Simulationen [Interview 23.08.2018; Interview 23.02.2018; Peral et al. 2017, 76]. Um die Steuerung zu optimieren, fordern die obersten Führungskräfte des BMW Group Werks Leipzig zudem, Ursache-Wirkbeziehungen schneller zu verstehen, um wirksame Maßnahmen abzuleiten und Transparenz zu schaffen [Interview 23.08.2018]. Ein Vorschlag war, einen so genannten KPI-Baum zu erstellen, der die tatsächlichen Beziehungen zwischen den Kennzahlen visualisiert [Interview 23.08.2018]. Dazu sei es wichtig, die Korrelationen zwischen Kennzahlen zu erkennen [Interview 23.08.2018]. Zudem betonten die Interviewpartner, dass auch abseits der oberen Führungsebenen die Vernetzung zwischen den Prozessen essentiell ist [Interview 23.08.2018]. Auf der Arbeitsebene soll die Zielsetzung so erfolgen, dass die Auswirkungen vorgelagerter auf nachgelagerte Prozesse erkennbar ist [Interview 17.07.2018; Interview 14.02.2018].

Die Erzeugung neuer strategischer Kennzahlen erfolgt eher selten und ist in vielen Fällen durch Führungskräfte oder Mitarbeiter mit Prozessverantwortung zur **Reduktion der Informationsmenge und Komplexität** induziert [Hesse 2015, 176]. Auslöser sind üblicherweise (in Anlehnung an [Hesse 2015, 176])

1. interne Anreize, wie eine Strategieänderung,
2. eine Anforderung durch eine Fachabteilung,
3. individuelle Informationsbedarfe von Führungskräften oder
4. externe Faktoren, wie eine geänderte Gesetzgebung.

Auf operativer Ebene hingegen werden Kennzahlen beispielsweise in verschiedenen Meisterbereichen oder Montageabschnitten für individuelle Informationsbedarfe auf Basis impliziten Wissens zur Steuerung erzeugt. Diese sind mit den zugehörigen Zielgebern nicht vereinbart und es erfolgt keine Berichterstattung [Interview 17.07.2018; Interview 15.08.2018]. Allerdings existiert weder auf strategischer noch auf operativer Ebene ein Prozess für die Entfernung von Kennzahlen [Hesse 2015, 177], wodurch die **Menge an Kennzahlen steigt**. Bei Funktionswechseln werden die bestehenden Kennzahlen einfach an den Nachfolger weitergereicht [Interview 01.02.2018]. Die Tatsache, dass es sich im Zielemanagementprozess etabliert hat, dass eher mehr als weniger Kennzahlen mit Zielvorgaben versehen werden, fördert dies [Interview 15.02.2018].

Die Anzahl insgesamt in der BMW Group verwendeter Kennzahlen ist schwierig zu bestimmen. Während einerseits für den gesamten Order-to-Delivery-Prozess des Unternehmens 428 Stück zentral bekannt sind, beläuft sich allein die Anzahl verzielter, hierarchisch heruntergebrochener Kennzahlen im BMW Group Werk Leipzig auf 52 Stück. Hinzu kommen die angesprochenen, darüber hinaus in der operativen Prozesssteuerung erstellten Kennzahlen. Zwar erfolgt teilweise in Gesprächsrunden eine periodische Prüfung hinsichtlich der Relevanz bestimmter Kennzahlen für die Steuerung [Hesse 2015, 177], ein definierter Kommunikationsprozess bezüglich der Entfernung besteht jedoch nicht, da sich der Fokus häufig bereits auf andere, relevantere Kennzahlen gerichtet hat [Hesse 2015, 177]. Dies bewirkt, dass Kennzahlen mitunter redundant sind [Interview 15.08.2018], was wiederum zu einer Reduktion an Transparenz und einer Steigerung der Komplexität für die Führungskräfte führt. Dazu kommt es insbesondere, da manche Kennzahlen eine reine Indikatorfunktion einnehmen und die Problemlösung in der Menge gesucht wird [Gladen 2014, 255], obwohl für einzelne Mitarbeiter in der Regel nur wenige Größen relevant sind.

Die tägliche Arbeit mit Kennzahlen beläuft sich auf Anwenderseite auf etwa fünf bis 20 Minuten und beinhaltet überwiegend die Betrachtung von Problemfällen mit den jeweiligen Ursachen und die Ableitung von Maßnahmen [Hesse 2015, 170]. Somit stellen Kennzahlen ein zentrales Werkzeug zur Schaffung von **Transparenz über das Verhalten des Unternehmens** dar. Besonders wichtig ist dabei die Kenntnis von Ursache-Wirkbeziehungen zwischen den Kennzahlen, um effektive und effiziente Maßnahmen abzuleiten und fundierte Entscheidungen zu treffen. Dies könnte beispielsweise bei der Erstellung der Abweichungsdokumente oder der Priorisierung von konfliktären Zielen unterstützten. Aufgrund der aktuellen **Intransparenz** bezüglich der Ursache-Wirkbeziehungen besteht eine große Nachfrage nach einer Lösung [Interview 15.02.2018; Interview 23.02.2018]. Dies zeigt außerdem, dass die isolierte Betrachtung von Kennzahlen einen begrenzten Aussagewert liefert [Reichmann/Hoffjan 2011, 26] und für einen umfassenden Überblick zur Steuerung unzureichend ist [Linden 2016, 42]. Ein typisches Mittel, um sie in Beziehungen zueinander zu setzen, ist die Erzeugung von Kennzahlensystemen.

2.3.5 Kennzahlensysteme

Da die getrennte Nutzung mehrerer Kennzahlen leicht zu verwirrenden und widersprüchlichen Aussagen führt, ist es notwendig, diese in eine Ordnung zu bringen, sodass die als wichtig erachteten Beziehungen zwischen ihnen wiedergegeben werden [Küpper 2013, 472 f.]. Eine derartige „…geordnete Gesamtheit von Kennzahlen, die in einer Beziehung zueinander stehen und so als Gesamtheit über einen Sachverhalt … informieren“ ist ein Kennzahlensystem [Horváth 2009, 507]. Im Gegensatz zu Performance-Management-Systemen weisen Kennzahlensysteme häufig eine monetäre Ausrichtung der Kennzahlen auf [Hesse 2015, 21]. Diese Differenzierung ist für die vorliegende Arbeit nicht relevant, weshalb die beiden Begriffe synonym Anwendung finden. Jedenfalls sind Kennzahlensysteme Lenkungsinstrumente, welche die Messung von Kennzahlen ermöglichen und deren Interdependenzen sowohl auf strategischer als auch auf operativer Unternehmensebene darstellen [Linden 2016, 24]. Somit haben auch sie einen starken Einfluss auf das Verhalten von Managern und Mitarbeitern [Kaplan/Norton 1992, 71].

Im Top-Down-Verfahren werden Kennzahlensysteme aus den übergeordneten Zielen des Unternehmens abgeleitet und von strategischen bis auf operative Ebenen heruntergebrochen [Linden 2016, 43 f.]. Beim Bottom-Up-Vorgehen erfolgt die Konstruktion umgekehrt, indem zuerst auf operativer Ebene Kennzahlen erfasst werden, die den Kernprozessen und Geschäftsvorfällen des Unternehmens zugrunde liegen [Linden 2016, 43 f.]. Für beide Vorgehensweisen existieren Methoden, die ihre Erzeugung unterstützen. Sowohl [Becker/Winkelmann 2014] als auch [Hesse 2015] nennen und analysieren in der Praxis etablierte Vertreter.

Ein Beispiel ist die in Kapitel 2.3.4 erwähnte BSC, die auch bei der BMW Group Anwendung findet. [Becker et al. 2019, 49] fassen das Hauptziel der BSC als die „…Strategieumsetzung in die unternehmerische Praxis durch Bildung eines Handlungsrahmens für den strategischen Führungsprozess und die Unterstützung dessen zusammen.“ Die BSC hat sich also offensichtlich von ihrem originären Entwurf als Performance-Measurement-System zu einem Performance-Management-System weiterentwickelt [Navrade 2008, 43 f.]. Sie bildet das Fachwissen des Managements hinsichtlich der gegenseitigen Abhängigkeiten von strategischen Zielen ab und unterstützt bei der Übersetzung von Unternehmenszielen in quantitative Kennzahlen, was laut [Steuernagel 2017, 100] im digitalen Zeitalter aktueller denn je ist. Berücksichtigung finden sowohl finanzielle als auch nicht-finanzielle Kennzahlen, welche die Strategie in Form von Ursache-Wirkbeziehungen repräsentieren, um sie mittels Zielen und Maßnahmenplänen umzusetzen [Wallenburg/Weber 2006, 1]. "Dabei geht es insbesondere darum, nicht nur die Leistung vergangener Perioden zu messen, sondern auch Größen zu beobachten, deren Entwicklung die zukünftige Entwicklung der Unternehmung beeinflusst“ [Alpar et al. 2019, 54]. Sie hilft Managern, hochaggregierte Kennzahlen detaillierter zu analysieren und für den Fall, dass unerwartete Ereignisse eintreten, deren Ursprung zu identifizieren, um geeignete Maßnahmen abzuleiten [Kaplan/Norton 1992, 75]. Somit beinhaltet die BSC die Strategie in Form eines Zielsystems [Navrade 2008, 287]. Konkrete Anwen-

dungsfelder sehen [Becker et al. 2019, 49] beispielsweise angesichts aktueller Unternehmensanforderungen zur Entwicklung von Digitalisierungsstrategien. Ein weiteres sehr aktuelles unternehmerisches Anwendungsfeld adressierend, entwickeln [Entreß-Fürsteneck et al. 2017, 130] unter der Anwendung einer BSC Kennzahlen für die Industrie 4.0. Eine quantitative Analyse der Ursache-Wirkbeziehungen zwischen den relevanten Größen erfolgt jedoch in den Ansätzen nicht. Auch [Davenport 2007] kritisiert bei der Anwendung der BSC, dass in den Unternehmen Intransparenz bezüglich der Ursache-Wirkbeziehungen zwischen den nichtfinanziellen Kennzahlen besteht und folglich deren Wirksamkeit nicht überprüfbar ist. Somit ist ihm zufolge bei der Anwendung der BSC essentiell, die Beziehungen quantitativ zu untersuchen [Davenport 2007]. [Kober/Northcott 2020, 22] stellen ebenfalls fest, dass den qualitativen Beziehungen in der BSC durch zahlreiche Autoren in der Wissenschaft sowie Anwendern in der Praxis nur begrenztes Vertrauen geschenkt wird, weshalb sie diese quantitativ untersuchen und belegen.

Im Allgemeinen sollen Kennzahlensysteme das Verständnis der Strukturen und Beziehungen zwischen unterschiedlichen Kennzahlen vereinfachen und ein bewusstes Management unter Berücksichtigung unvermeidbarer Konflikte fördern [Bititci 1995, 138]. Dazu dienen sie als Simulationsmodelle und unterstützen das Abschätzen der Wirkungen verschiedener Handlungsalternativen [Gladen 2014, 27]. Für den erfolgreichen Einsatz von Kennzahlensystemen stellt [Gladen 2014, 96] Anforderungen an deren Eigenschaften:

- Objektivität und Widerspruchsfreiheit zur Einschränkung der Möglichkeiten der subjektiven Beliebigkeit von Interpretationen und widersprüchlicher Aussagen.
- Einfachheit und Klarheit durch eine sinnvolle Ordnung und begrenzte Anzahl an Kennzahlen.
- Informationsverdichtung, sodass sich obere Managementebenen zur Komplexitätsreduktion an wenigen Kennzahlen orientieren können.
- Multikausale Analyse durch die Aufspaltung von Kennzahlen übergeordneter Ebenen auf Kennzahlen darunter liegender Ebenen.
- Indikatorfunktion und Systemoffenheit, indem eine Einflussgröße auf untergeordneter Ebene auf mehrere Kennzahlen der übergeordneten Ebene bezogen werden kann.
- Partizipation fachkundiger Mitarbeiter bei der Erstellung von Kennzahlensystemen, um beratend zu unterstützen sowie Akzeptanz und Identifikation mit den Zielgrößen zu schaffen.

Die Beziehungen, die die Kennzahlen in diesen Kennzahlensystemen eingehen sind als logisch (definitorische oder mathematische Beziehungen), empirisch (deterministische oder stochastische Abhängigkeit) oder hierarchisch (gemäß sachlicher oder subjektiver Bewertung) klassifizierbar [Küpper 2013, 473]. [Becker/Winkelmann 2014, 75 f.] diskutieren Vor- und Nachteile dieser Ausprägungen sowie Mischformen. Vor dem Hintergrund dieser theoretischen Erkenntnisse liefert das folgende Kapitel einen Einblick in die praktische Unternehmenssteuerung mit einem Kennzahlensystem.

2.3.6 Kennzahlensysteme in der Praxis

Die Ableitung von Zielen in den Produktionsstandorten der BMW Group erfolgt in einem Drei-Ebenen-Gespräch. An diesem nehmen Mitarbeiter von drei Hierarchieebenen teil. Auf Werkskennzahlenebene sind das im Werk Leipzig beispielsweise der Produktionsvorstand, der Werkleiter sowie die Hauptabteilungsleiter [Richter 2017, 29]. Es bildet die Grundlage für einen strukturierten Prozess, dessen Ergebnis die durchgängige Definition der Ziele auch für alle Führungskräfte auf den untergeordneten Organisationsebenen ist [Richter 2017, 29]. Inwieweit die Ziele letztlich noch weiter bottom-down heruntergebrochen werden, ist abhängig von den jeweiligen Funktionsbereichen im Werk [Interview 15.02.2018]. In einem Beispiel, in welchem die Zielvorgabe bis auf Meisterebene erfolgt, vereinbart die Meisterin zwar dieselben Kennzahlen mit ihren Vorarbeitern, überwacht diese jedoch nicht konsequent, da die Werte zu kleinteilig sind [Interview 17.07.2018]. Stattdessen dienen sie als Grundlage, um Probleme miteinander zu besprechen [Interview 17.07.2018]. Anhand dessen zeigt sich ein weiteres Defizit dahingehend, dass die operative Prozesssteuerung anhand der Wirkbeziehungen mit der Kennzahlensteuerung zu verknüpfen ist.

Wie in Kapitel 2.3.4 erläutert, wäre eine Orientierung der Zielvorgaben und das Monitoring von Kennzahlen neben der hierarchischen Zielstruktur auch prozessübergreifend anhand der Vorgänger- und Nachfolgerprozesse sinnvoll. So überwacht beispielsweise ein Meisterbereich die Kennzahl Nacharbeitsminuten. Allerdings ist eine Aufgabe dieses Bereiches, die Fahrzeuge auf Fehler vorangegangener Prozesse zu prüfen und diese zu beseitigen. Somit fallen Nacharbeitsminuten in diesem Bereich an, die dort nicht verursacht wurden. Eine prozessübergreifende Analyse würde deutlich machen, dass das Ergebnis der Kennzahl von dem Input der Vorgängerprozesse dieses Meisterbereichs abhängt. In der Konsequenz wird diese Kennzahl zwar überwacht und berichtet, eignet sich jedoch für den Meister für die eigentliche Prozesssteuerung nicht [Interview 12.01.2018].

In einem anderen Fall können Aufwände durch Ausfälle von Anlagen entstehen. Diese Aufwände gehen wiederum zulasten des jeweiligen Bereiches, obwohl mit den verantwortlichen Anlagenbetreibern eine Anlagenverfügbarkeit kleiner als 100% vereinbart wurde. Somit ist auch dort die Aussagekraft der Kennzahl für die Leistungsfähigkeit des Prozesses reduziert, da Einflussfaktoren wirken, die durch den Prozessverantwortlichen nicht steuerbar sind. Dies bestätigt die Notwendigkeit der in Kapitel 2.3.1 an Kennzahlen gestellte Anforderung, dass der Zielenehmer auch im Kennzahlensystem die Erreichung der eigenen Ziele tatsächlich beeinflussen können muss.

Anhand dieser Beispiele zeigt sich die Bedeutung der Berücksichtigung der Interdependenzen zwischen der Vielzahl an Kennzahlen und Prozessen für eine effektive und effiziente Kennzahlensteuerung. Zielerreichungsgrade sollten aus empirischen Ursache-Wirkbeziehungen abgeleitet werden [Gladen 2014, 259]. Zudem muss angesichts der stetigen Veränderungen sowohl der Umweltfaktoren als auch der Unternehmensstruktur eine ständige Anpassung an die aktuellen Begebenheiten und

Pflege des Kennzahlensystems nach seinem Aufbau erfolgen, da andernfalls die Entscheidungsqualität im Zeitverlauf durch veraltete Indikatoren abnehmen kann [Linden 2016, 30]. Kennzahlensysteme bieten zwar Potentiale zur Steuerung durch die übersichtliche Darstellung und Strukturierung komplexer Systeme, sie müssen jedoch auch vollständig verstanden und folglich richtig bewertet werden [Posselt 2014, 8]. Ein weiterer wichtiger Aspekt für die Mitarbeiter ist, dass der eigene Beitrag für die Werkskennzahlen auf operativer wie auch strategischer Ebene nachvollziehbar sein muss [Interview 23.02.2018]. Die dafür notwendigen Ursache-Wirkbeziehungen finden aber bei der Präsentation der Kennzahlenwerte üblicherweise wenig Beachtung.

Hinsichtlich der Frage, ob es möglich ist, valide Ursache-Wirkungsketten herzuleiten, reicht das Spektrum von Skeptikern, die dies ausschließen, über Autoren, die dies über sachlogische Verknüpfungen als wahrscheinlich ansehen, bis hin zu denjenigen, die die exakte mathematische Ableitung[12] anstreben [Greiling 2009, 106]. Anhand dieser Diskussion zeigt sich wiederum, dass sowohl aus der Perspektive der Literatur als auch der Praxis die Analyse von Ursache-Wirkbeziehungen in der Unternehmenssteuerung eine zentrale Rolle einnimmt.

2.4 Ursache-Wirkbeziehungen in der Kennzahlensteuerung

Durch die komplexen und dynamischen Interdependenzen zwischen den Prozessen großer Produktionssysteme ergeben sich deren Eigenschaften. Daher ist die Analyse von Systemen in ihrer Vernetztheit ein sehr bedeutendes Element der allgemeinen Systemtheorie [Trier et al. 2013, 46]. Auch aus Sicht des Prozessmanagements sind Prozesse mit den wichtigsten Abhängigkeiten und Interaktionen abzubilden [Alt 2008, 102]. Also ist es von großer Bedeutung, dass sich Entscheidungsträger für eine effiziente Steuerung von Unternehmen mögliche Konstellationen von Ursachen und Wirkungen in der Prozesslandschaft bewusst machen. [Malina et al. 2006, 938] zeigen drei Arten von Ursache-Wirkbeziehungen auf:

1. Unabhängigkeit: Ereignis X (die Ursache) und Y (die Wirkung) sind logisch unabhängig, sodass Y nicht logisch sondern nur empirisch von X abgeleitet werden kann (siehe Kapitel 2.3.5 logische und empirische Abhängigkeiten zwischen Kennzahlen).
2. Zeitliche Sequenz: Ereignis X geschieht zeitlich früher als Y, wobei beide Ereignisse in zeitlicher und räumlicher Nähe auftreten.
3. Vorhersagefähigkeit: Das Auftreten von Ereignis X impliziert das spätere Auftreten von Y.

[12] Kapitel 3.5 gibt einen Überblick und eine Einordnung diverser Ansätze unter anderem aus den Bereichen Process Mining, System Dynamics und Statistik.

Diese Beziehungsarten verdeutlichen, dass angestrebte Wirkungen in der Regel nicht direkt, sondern nur indirekt, durch das Management beeinflussbar sind. Beispielsweise legt das Management die Qualität eines Produktes nicht direkt fest. Sie ergibt sich vielmehr als Ergebnis (Wirkung) eines vorgabegerechten Zusammenspiels der jeweiligen Produktelemente (Ursache). Übertragen auf die Prozessteuerung bedeutet dies, dass Entscheidungsträger für die Überwachung der zu erreichenden Wirkungen eines Prozesses Zielvorgaben definieren und ihre Maßnahmen auf diese ausrichten, um die Ziele zu erreichen (siehe Kapitel 2.3).

Die Ziele stehen ihrerseits sowohl auf derselben organisatorischen Ebene (horizontal), wie auch auf über- und untergeordneter organisatorischer Ebene (vertikal) in Ursache-Wirkbeziehungen. Es gibt drei Arten dieser Wirkungen [Gladen 2014, 258; Steuernagel 2017, 19]:

- Bei einer indifferenten Beziehung beeinflusst ein Ziel ein anderes nicht.
- Wirkt ein Ziel positiv auf die Erreichung eines anderen liegt eine komplementäre Beziehung vor.
- Hat ein Ziel einen negativen Einfluss auf ein anderes Ziel, ist dies ein konkurrierendes Ziel.

Folglich muss sich das Management nicht nur der Existenz von Ursache-Wirkbeziehungen in der Prozesslandschaft bewusst sein, sondern auch die Art und Weise der Wirkungen (indifferent, komplementär, konkurrierend) berücksichtigen. Derartige Analysen nehmen eine zentrale Rolle in den Kapiteln 4 und 5 ein. Zwangsläufig stellt sich in diesem Rahmen die Frage nach Kausalitäten. Zu den diesbezüglichen Diskussionen, soll in der vorliegenden Arbeit kein Beitrag geleistet werden. Stattdessen wird beispielhaft auf folgende Autoren verwiesen: [Simon 1977; Granger 1969; Shimizu et al. 2006; Malina et al. 2006].

Das Wissen über Ursache-Wirkbeziehungen zwischen den jeweiligen Zielen und Kennzahlen im Unternehmen ist nur sehr schwer analytisch zu erfassen. Der Grund dafür ist, dass es verteilt und meistens implizit bei Experten der jeweiligen Fachbereiche vorliegt, sodass die Entwicklung von Kennzahlensystemen eine sehr komplizierte Aufgabe ist [Hesse/Groh 2014, 20]. Dies legt nahe, dass Transparenz über diese Beziehungen große Vorteile für die Unternehmenssteuerung mit sich bringt.

2.4.1 Vorteile transparenter Ursache-Wirkbeziehungen zwischen Kennzahlen

Für die Implementierung von Strategien in großen Produktionsunternehmen sind Kennzahlen und ein umfassendes Verständnis der Interdependenzen zwischen ihnen unumgänglich [Strohhecker 2016, 94]. Dazu reichen definitionslogische Beziehungen zwischen den Zielen über- und untergeordneter Ebenen allerdings nicht aus, weshalb die Ursache-Wirkbeziehungen empirisch zu bestätigen sind [Gladen 2014, 260]. Damit soll erreicht werden, dass die **Konsistenz im Zieleverbund** im Sinne der übergeordneten Strategie sichergestellt ist.

[Strohhecker 2016, 112] zeigen in einer Studie auf, dass Probanden, die ein besseres Verständnis für Ursache-Wirkbeziehungen zwischen ihren Handlungen und relevanten Kennzahlen besitzen, bessere Ergebnisse erzielen als jene mit einem schlechteren Verständnis. Somit verbessern transparente Ursache-Wirkbeziehungen, die **Unternehmensleistung** [Ghalayini et al. 1997, 212].

Darüber hinaus unterstützt dies dabei, Kennzahlen, die sich zur unternehmerischen Zielsteuerung nicht mehr eignen, **anzupassen, anders** zu **gewichten,** zu **entfernen** oder neue **Größen hinzuzufügen** [Cai et al. 2009, 514; Gladen 2014, 372]. Ebenso werden mögliche **Redundanzen** im Kennzahlensystem deutlich [Rodriguez et al. 2009, 104].

Transparente Ursache-Wirkbeziehungen helfen zudem beim Abschätzen, ob die Auswirkung einer Maßnahme mit hoher Wahrscheinlichkeit oder notwendigerweise eintreten wird, was **Unsicherheiten** und **Fehlsteuerungen** reduziert [Hügens 2008, 127; Norreklit 2000, 71]. So steigert das Ergreifen **wirksamer Maßnahmen** die **Effektivität und Effizienz**[13] der Unternehmenssteuerung. Gleichermaßen reduziert eine generierte Vielfalt wirksamer Maßnahmen die Vielfalt möglicher Prozessergebnisse [Ashby 1956, 207]. Wenn die tatsächlichen Wirkungen den Erwartungen des Managements nicht entsprechen, ist es wichtig zu analysieren, weshalb diese Abweichungen entstanden sind [Cai et al. 2009, 514; Druzdzel/Flynn 2009, 7] und was die Ergebnistreiber waren.

Durch die Ursache-Wirkbeziehungen in Kennzahlensystemen erzeugt eine Kennzahl in der Regel zusätzliche Aufwände für eine oder mehrere andere Kennzahlen des Systems [Cai et al. 2009, 515]. Diesen Effekt steigern unvollständige Informationen, begrenzte Ressourcen oder Kommunikationsbarrieren sogar noch [Cai et al. 2009, 515]. Letztere existieren insbesondere, da sich Manager auf die Erreichung der Zielvorgaben der ihnen zugeteilten Prozesse konzentrieren, wodurch ein Denken in Silos entsteht (siehe auch Kapitel 2.3.4). Demnach sind isolierte oder punktuelle Lösungsansätze nicht ausreichend [Kemper et al. 2010, 8]. Es ist im Gegenteil notwendig, beeinflussende und beeinflusste Kennzahlen mit Hilfe von Ursache-Wirkbeziehungen zu untersuchen [Cokins 2013, 71]. Eine prozessübergreifende

[13] „Effizienz (Inputwirksamkeit – Die Dinge richtig tun) ist notwendig für den langfristigen Unternehmenserfolg, aber nicht hinreichend. Hinzukommen muss außerdem Effektivität (Outputwirksamkeit – Die richtigen Dinge tun).“ [Gladen 2014]

Transparenz der Ursache-Wirkbeziehungen fördert die funktionsbereichs- und somit **siloübergreifende Kommunikation** und vereinfacht das Abschätzen von Maßnahmen und Treffen von Entscheidungen; nicht nur im eigenen Verantwortungsbereich sondern im gesamten Kennzahlennetzwerk [Malina et al. 2006, 955]. Vor dem Hintergrund dieser zahlreichen Vorteile transparenter Ursache-Wirkbeziehungen zwischen Kennzahlen, liefert der folgende Abschnitt einen Einblick in den Umgang mit dieser Thematik in der Praxis.

2.4.2 Empirische Ermittlung von Ursache-Wirkbeziehungen in der Praxis

Das Management, welches üblicherweise zeitlich stark beansprucht wird, muss angesichts volatiler Rahmenbedingen und sich folglich ändernder Ziele sowie eng gesteckter Zeitvorgaben zügig Entscheidungen treffen [Cai et al. 2009, 514]. Dazu sollten die Interdependenzen zwischen Kennzahlen für Vergleiche von Optionen und die Optimierung der Zielerreichung bekannt sein [Cai et al. 2009, 514]. Eine Untersuchung im BMW Group Werk Leipzig ergab jedoch, dass die Abbildung abteilungs- und fachbereichsspezifischer Vernetzungen beziehungsweise deren Reproduktion aufgrund der Werksgröße eine große Herausforderung darstellen und die Verfügbarkeit aktueller Informationen für das Treffen fundierter Entscheidungen durch das Management steigerbar ist [Richter 2017, 47; Arndt 2017, 33]. Ein Grund dafür ist, dass kein gezieltes und gesteuertes Lernen von Zusammenhängen erfolgt, sondern ein eher subjektives und individuelles Bauchgefühl basierend auf den Erfahrungen und der Beschäftigungsdauer der Verantwortlichen die Grundlage für Maßnahmen darstellt [Hesse 2015, 172]. Dies ist ein weit verbreitetes Problem, da die meisten Unternehmen nicht versuchen, ihre Kennzahlen zu strukturieren, die Ursache-Wirkbeziehungen zu verstehen und anhand derer zu steuern [Suwignjo et al. 2000, 232].

In Kapitel 1 wurde angeführt, dass Menschen Systeme mit bis zu vier Variablen kognitiv verarbeiten können. In der Praxis geben Mitarbeiter an, durch ihr Erfahrungswissen die Beziehungen zwischen zwei bis drei Kennzahlen beschreiben zu können [Hesse 2015, 173]. Eine Betrachtung der tatsächlichen komplexen Abhängigkeitsnetze existiert daher in den meisten Fällen nicht [Hesse 2015, 174 f.]. Wenn überhaupt geschieht die Nutzung vorhandenen, prozessübergreifenden Wissens, indem ein Mitarbeiter aufgrund seiner Beobachtungen einen Kollegen über mögliche Einflüsse am folgenden Tag informiert [Hesse 2015, 173]. Das implizit vorhandene Wissen über Ursache-Wirkbeziehungen ist nicht dokumentiert [Hesse 2015, 174], wodurch es für andere nicht nutzbar ist und dem Unternehmen verloren geht, wenn der Wissensträger die Funktion wechselt. Außerdem herrscht durch das Fehlen von Informationen über Zusammenhänge oder Seiteneffekte unter den Kennzahlen ein unterschiedliches Verständnis zwischen den Kollegen [Hesse 2015, 175]. Somit liegen auch keine genauen Informationen über Maßnahmen zur zielgerichteten Beeinflussung der Kennzahlen vor [Hesse 2015, 173].

Ein wichtiger Grund für die unzureichende empirische Erfassung von Ursache-Wirkbeziehungen ist der große Ressourcenaufwand, der mit dem Einsatz aktuell verfügbarer, qualitativer Methoden verbunden ist. So wurde beispielsweise im Jahr 2009 ein Werksprojekt durchgeführt, in welchem die Einflussfaktoren, die Wirkintensität sowie die Wechselwirkungen zwischen den Faktoren und bezüglich der Kennzahl Termintreue (TT) [%] im Finish-Bereich der Montage analysiert wurden. Für die Werkleitung ist sie von zentraler Bedeutung, da sie die Quote der Fahrzeuge misst, die innerhalb der veranschlagten Zeiträume die Montage verlassen. Das Ziel des Projektes war die Identifizierung von Stellhebeln zur Erreichung der Zielvorgaben für die Termintreue. Über einen Zeitraum von 6 Monaten waren 13 Personen daran beteiligt, unter Zuhilfenahme der Sensitivitätsanalyse von Vester auf Grundlage von implizitem Wissen die Ursache-Wirkbeziehungen zwischen 25 Einflussfaktoren zu analysieren. In die von Vester beschriebene Matrix trugen die Experten Kennzahlen in die namensgebende Zeile und Spalte ein. Wie in Abb. 2-1 dargestellt, befüllten sie die Zellen anschließend je nach Art der Beziehung zwischen den Kennzahlen nach einer definierten Methodik mit Werten und bildeten Zeilen- und Spaltensummen. Zur Bestimmung der so genannten Rollenverteilung lässt sich daran ablesen, wie stark jede Kennzahl die anderen beeinflusst (aktiv) und wie stark sie von anderen beeinflusst wird (passiv) [Ropers 2013, 13]. Dies bildete die Grundlage für Folgeanalysen anhand von Visualisierungen und Simulationen und lieferte Erkenntnisse über die Möglichkeiten zur Erreichung der Ziele für die Termintreue.

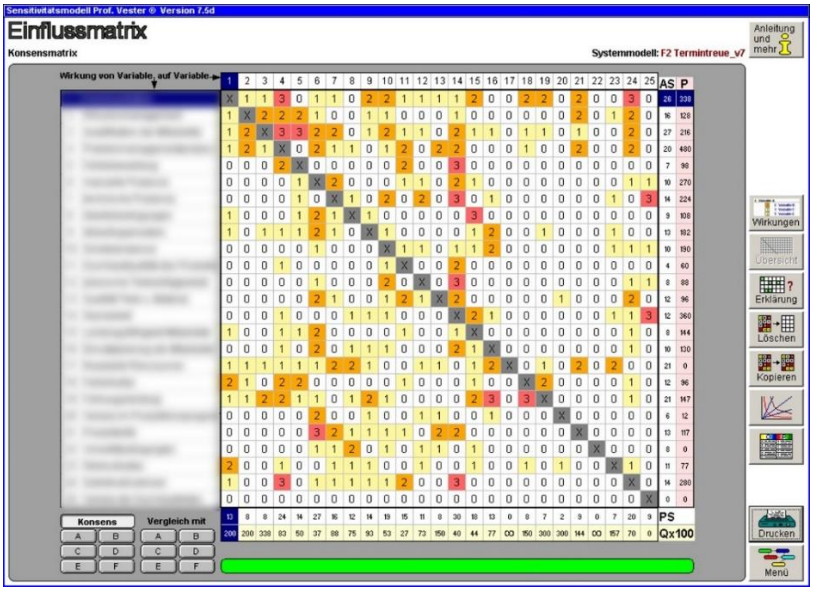

Abb. 2-1: Einflussfaktorenanalyse mit der Matrix von Vester [14]

[14] Aus Datenschutzgründen wurden die Einflussfaktoren unkenntlich gemacht.

Befragungen von Prozessexperten unterschiedlicher Funktionsbereiche hinsichtlich der Ursache-Wirkbeziehungen zwischen Kennzahlen führten in anderen Untersuchungen zu Visualisierungen wie der in Abb. 2-2 [Richter 2017, 70; Wolle 2016, 65]. Auch diese Methode trug zu mehr Transparenz bezüglich der betrachteten Prozesse bei.

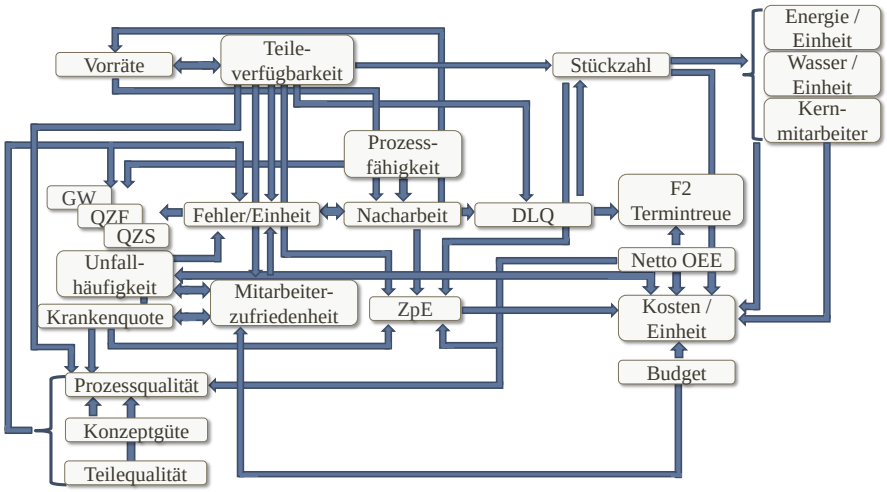

Abb. 2-2: Qualitativ erfasste Kennzahlenrelationen [Richter 2017, 70]

Jede der Vorgehensweisen beanspruchte umfassende personelle und zeitliche Kapazitäten. Somit beeinflussen sie das Kosten-Nutzen-Verhältnis negativ, weshalb sie nicht regelmäßig für eine Vielzahl von Prozessen durchführbar sind. Dies wäre jedoch für eine kontinuierliche Aktualisierung angesichts der sich verändernden Rahmenbedingungen und für ein detailliertes Verständnis der Ursache-Wirkbeziehungen notwendig. Darüber hinaus basieren diese Ansätze ausschließlich auf dem impliziten Wissen der Experten, sodass die Ergebnisse nur schwierig reproduzierbar sind: Ändert sich die Teilnehmerkonstellation, werden Informationen abwesender Teilnehmer fehlen und neues Fachwissen zusätzlich Anwesender einfließen. Auch ist es eine Herausforderung, alle relevanten Experten zu identifizieren und sicherzustellen, dass alle unter Berücksichtigung eines effizienten Einsatzes verfügbarer Kapazitäten teilnehmen können. Eine Aussage über die Aktualität deren mentaler Modelle (siehe dazu Kapitel 1.1) ist des Weiteren kaum zu treffen.

Zusammenfassend bestätigt sich, dass die Bemühungen, Ursache-Wirkbeziehungen empirisch zu fundieren eher sporadischer Natur und unzureichend sind, obwohl selbst vermeintlich einfache Prozesse in Produktionsunternehmen Teile komplexer

Systeme sind [Gladen 2014, 404]. Eine Informationsquelle, die bei diesen empirischen Analysen nicht ausführlich betrachtet wird, sind die Vergangenheitsdaten der Kennzahlen. Daher erfolgt im weiteren Verlauf eine Unterscheidung zwischen dem impliziten Wissen von Experten als qualitative und den verfügbaren Kennzahlendaten als quantitative empirische Informationsquelle.

2.5 Zusammenfassung: Herausforderungen bei der kennzahlenbasierten Steuerung großer Produktionsunternehmen

Teilforschungsfrage 1: Welche Herausforderungen stellen sich dem Management großer Produktionsunternehmen bei der kennzahlenbasierten Unternehmenssteuerung?

Wesentliche Eigenschaften großer Produktionsunternehmen ergeben sich daraus, dass sie aus einer Vielzahl interdependenter Prozesse bestehen. Das Management hat die Aufgabe, diese Systeme von Prozessen im Sinne der übergeordneten Unternehmensziele zu führen und zu steuern. Dies erfordert auf Grundlage bestehender Zusammenhänge das Bewerten von Alternativen, das Herbeiführen fundierter Entscheidungen und das Ergreifen von Maßnahmen zur Planung, Steuerung und Kontrolle. Zur Erhöhung der Leistungsfähigkeit des Unternehmens sind neue Potentiale zu identifizieren und redundant ausgeführte Aufgaben zu eliminieren. Als Ergebnis werden klare, einfache und bereichsübergreifende Prozesse angestrebt, die Ineffizienzen wie Koordinationsaufwände durch Schnittstellen, Intransparenz oder Redundanz minimieren. Dabei sind Zielvorgaben für Prozesskennzahlen ein etabliertes Hilfsmittel: Verantwortliche leiten sie ab, beziehungsweise definieren sie, überwachen ihre Erreichung und passen Kennzahlensysteme an veränderte Bedingungen und Ursache-Wirkbeziehungen an.

Dieser Verantwortung stellt sich das Management unter zunehmend unsicheren Bedingungen. Unternehmen sowie Prozesse sind durch steigende Komplexität und Dynamik gekennzeichnet. Die digitale Transformation verändert das Unternehmensumfeld und dringt in nahezu jeden internen und externen Prozess vor. Zusätzlich verändern globalisierte Märkte in Kombination mit politischen Maßnahmen das Marktumfeld massiv. In der Konsequenz steigen die Anforderungen an das zeitlich stark beanspruchte Management hinsichtlich immer schneller notwendiger Entscheidungen, deren Transparenz und Fundierung sowie folglich an das quantitative Berichtswesen.

Die Komplexität der zu steuernden Systeme ergibt sich aus der Menge an Beziehungen, die zwischen deren Elementen bestehen. Große Produktionsunternehmen sind derart komplex, dass das Management, welches in der Regel die Beziehungen zwischen zwei bis maximal vier Kennzahlen beschreiben kann (siehe Kapitel 1.1), kaum mehr die Möglichkeit hat, das Verhalten des Gesamtsystems intuitiv nachzu-

vollziehen oder zu antizipieren. Hinzu kommt, dass angestrebte Wirkungen üblicherweise nicht direkt, sondern nur indirekt beeinflussbar sind, sodass es von großer Bedeutung ist, das Ursache-Wirkgefüge zu kennen. Dessen Analyse erfolgt in der Regel qualitativ, was mit hohem personellem und zeitlichem Aufwand verbunden sowie von der Teilnahmebereitschaft der entsprechenden Experten abhängig ist [Becker/Winkelmann 2014, 61]. Wegen dieses Aufwandes basieren Entscheidungen in der Praxis häufig auf Arbeitshypothesen, Annahmen, Intuitionen und Erfahrungswissen, ohne konkrete Regeln zu befolgen und ohne die Möglichkeit der Beachtung komplexer Abhängigkeitsnetze. Insofern sind die Auswirkungen von Maßnahmen aufgrund von Wissensdefiziten schwer vorhersagbar und Fehlsteuerung und Ineffizienzen wegen des Einsatzes ungeeigneter Kennzahlen oder Zielvorgaben drohen.

Zur Reduktion derartiger Risiken sind viele Kennzahlen und Berichtstechnologien im Einsatz, deren kaum überschaubare Vielzahl wiederum einen Faktor für mehr Intransparenz, Komplexität und Redundanzen darstellt. Zudem fördert die retrospektive, isolierte Abbildung von Kennzahlen eine reaktive statt einer proaktiven Prozesssteuerung und das Denken in Silos.

Angesichts derartiger Herausforderungen leiten sich folgende Anforderungen an die kennzahlenbasierte Unternehmenssteuerung ab:

- Zielwertvorgaben für Prozesse und die Beurteilung der Prozessleistung orientieren sich an den Anforderungen interner und externer Kunden sowie an den übergeordneten Unternehmenszielen. Die resultierenden Kennzahlensysteme sind aktuell, konsistent, verständlich, richtig bewertbar und ermöglichen eine proaktive, zukunftsorientierte Unternehmenssteuerung.
- Effiziente und effektive Maßnahmen durch transparente Ursache-Wirkbeziehungen zwischen den Kennzahlen verbessern die Unternehmensleistung und verdeutlichen den eigenen Beitrag der Mitarbeiter zur Erreichung der Unternehmensziele.
- Ursache-Wirkbeziehungen zwischen Kennzahlen und Prozessen werden bewusst, nachvollziehbar und reproduzierbar gelernt, dokumentiert, aktualisiert und für andere nutzbar gemacht. Dadurch herrscht ein einheitliches Verständnis diesbezüglich und bezüglich zu ergreifender Maßnahmen.

Anhand der Anforderungen zeigt sich, dass die Transparenz hinsichtlich der Ursache-Wirkbeziehungen zwischen Prozessen einen zentralen Schlüssel zum Erreichen des Zielbildes darstellt. Für die Analyse jener Beziehungen eignen sich Kennzahlendaten, die maßgebliche Einfluss- und Ergebnisfaktoren der Prozesse repräsentieren, wodurch umfassende, siloübergreifende Informationen in Entscheidungssituationen einbezogen werden können.

Dies reduziert Unsicherheiten sowie Fehlsteuerungen und erlaubt die Anpassung, Gewichtung, Ergänzung oder Beseitigung von Kennzahlen. Es trägt dazu bei, objektivere, stärker fundierte, weniger abstrakte und weniger vom Wissen von Einzel-

personen abhängige Entscheidungen zu treffen und Entscheidungen nach Bauchgefühl aus dem Fokus rücken. Darüber hinaus steigen die Nachvollziehbarkeit von Veränderungen und die Verständlichkeit und Beherrschbarkeit von Kennzahlensystemen. Darauf aufbauend können Vorhersagen und Simulationen durchgeführt werden, welche das schnelle Ableiten und Treffen wirksamer Maßnahmen im Sinne der übergeordneten Ziele ermöglichen.

In der Praxis herrscht Bewusstsein bezüglich der Defizite der reaktiven, kennzahlenbasierten Unternehmenssteuerung und der „…Notwendigkeit der Erzeugung eines unternehmensweit verbindlichen Modells zur Schaffung eines einheitlichen Verständnisses zu Zusammenhängen, Herkunft und Auswirkung von Kennzahlen.“ [Hesse 2015, 206] Daher besteht großer Bedarf an Lösungen und Methoden, die Entscheidungsträger mit relevanten Kennzahleninformationen versorgen und Prognosen und Simulationen ermöglichen. Somit erzeugen die hier gewonnen Erkenntnisse sowohl aus wissenschaftlicher wie auch praktischer Perspektive ein umfassendes Verständnis für die Anforderungen, die sich bei der Erzeugung von Kennzahlensystemen stellen und die Herausforderungen, die sich ergeben. Daher ist der erste Teil des definierten Erkenntniszieles erreicht worden.

Trotz der Schwierigkeiten, die sich bei der Analyse stellen, sind sich Autoren wie [Norreklit 2000, 70] der empirischen Abbildbarkeit von Ursache-Wirkbeziehungen sicher. [Hügens 2008, 122] hält es aber für denkbar, „… dass zurzeit noch keine Möglichkeit besteht, einen empirischen Nachweis zu führen, da entsprechende Methoden fehlen oder nicht genügend Beobachtungen vorliegen, um eine fundierte empirische Aussage zu ermöglichen.“ Daher liegt der Fokus im folgenden Kapitel auf der Analyse bestehender Entscheidungsunterstützungssysteme für die Identifikation von Ursache-Wirkbeziehungen zwischen Kennzahlen.

3 Entscheidungsunterstützungssysteme für die kennzahlenbasierte Unternehmenssteuerung

Ein entscheidender Mehrwert für Unternehmen besteht in der Möglichkeit und der Fähigkeit, Informationen aus den unübersichtlichen Datenmengen und deren heterogenen Strukturen zu identifizieren und zur Entscheidungsunterstützung zur Verfügung zu stellen [Felden 2016]. Berücksichtigt man zum Beispiel, dass sich die Anzahl der zentral bekannten Kennzahlen des Order-to-Delivery-Prozesses bei der BMW Group auf eine Anzahl von 428 Stück beläuft (siehe Kapitel 2.3.4) und diese in unterschiedlichen Zeitintervallen in den Datenbanken vorliegen (z. B. pro produziertem Fahrzeug, täglich, wöchentlich, monatlich, quartalsweise), ist schon in diesem vergleichsweise kleinen Ausschnitt der verfügbaren Datenmenge die Übersichtlichkeit für den Menschen stark eingeschränkt. Das Extrahieren von Informationen aus den in den Informationssystemen abgelegten Datenmengen und das Erzeugen von Mehrwert für die Unternehmen, stellt diese demnach vor Herausforderungen [van der Aalst 2011, 2]. Entscheidungsunterstützungssysteme als interaktive, modell- und formelbasierte IT-Systeme helfen dem Anwender, für definierte Aufgaben beziehungsweise Aufgabenklassen die richtigen Aktivitäten auszuwählen [Mertens/Meier 2009, 12; Druzdzel/Flynn 2009, 1]. Durch die Integration verschiedener Informationsquellen und die Anwendung heuristischer, statistischer, finanzmathematischer oder prognostischer Methoden beispielsweise aus dem Ingenieurwesen oder dem Operations Research (OR) erhält der Anwender Zugriff auf relevante Informationen, was den Entscheidungsprozess stärker strukturiert und die Abwägung von Alternativen unterstützt [Kemper et al. 2010, 112; Druzdzel/Flynn 2009, 1]. Der geeignete Einsatz von Entscheidungsunterstützungssystemen trägt zur Steigerung der Produktivität, Effizienz und Effektivität bei und kann sogar einen Wettbewerbsvorteil darstellen [Druzdzel/Flynn 2009, 1 f.]. Im Kennzahlenkontext fällt insbesondere Business Intelligence-Systemen eine bedeutsame Rolle zu.

3.1 Business Intelligence

Business Intelligence (BI) hat sich in zahlreichen Unternehmen zu einem mannigfaltig genutzten Begriff entwickelt. Dies spiegelt sich auch in der Wissenschaft wider. Ursprünglich wird er [Luhn 1958, 315] zugesprochen, der ihm die Funktion der Verfügbarkeit und des Sammelns neuer Informationen, deren Speicherung, Verbreitung, Abfrage und Übertragung zuweist. Fortan entwickelte sich dessen Anwendung weiter. So definierte Howard Dresner 1989 BI als Prozess, welcher Daten in Information und weiter in Wissen wandelt [Kottbauer 2015, 6]. Heutzutage beschreiben [Kemper et al. 2010, 9] BI allgemein als einen integrierten, unternehmensspezifischen, IT-basierten Gesamtansatz für die betriebliche Entscheidungsunterstützung. [Gluchowski et al. 2008, 91] betonen eher die Aufbereitung operativen Datenmaterials zur Informations- und Wissensgenerierung einschließlich Spei-

cher-, Auswertungs- und Präsentationsfunktionalitäten. [Linden 2016, 116] hingegen stellt die Bereitstellung hochaggregierter Kennzahlen zur strategischen Planung und Kontrolle heraus. Andere Autoren betrachten BI als Kombination von Betriebswirtschaftslehre, Statistik und Wirtschaftsinformatik [Steuernagel 2017, 22] oder teilen sie dem operativen Controlling verschiedener Funktionsbereiche wie Produktion, Logistik, IT und Personalwesen zu [Schön 2018, 112]. Unter anderem die zunehmende Anwendung fortgeschrittener analytischer Verfahren führte zur Entstehung zusätzlicher Begrifflichkeiten. Abb. 3-1 ordnet diese ein.

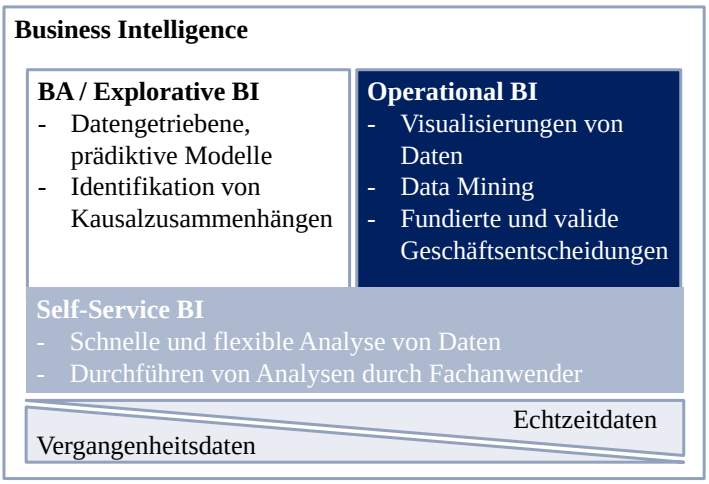

Abb. 3-1: Begrifflichkeiten in der Business Intelligence

Laut [Chamoni/Gluchowski 2017, 9] grenzt sich zum Beispiel der Begriff Business Analytics (BA) von BI durch den Fokus auf datengetriebene Analysen zur Ableitung von Vorhersagemodellen mit Kausalzusammenhängen für eine optimale Planung unter Einsatz innovativer Technologien wie anspruchsvollen statistisch-mathematischen Verfahren und dem maschinellen Lernen ab. Für [Felden 2012] zeichnet sich BA dadurch aus, dass Erkenntnisse aus der kontinuierlichen Erforschung und Untersuchung von Daten vergangener Geschäftstätigkeiten in zukünftige Aktivitäten einfließen. Verbesserte Handlungen entstehen dabei durch das Nachvollziehen der bisherigen Tätigkeiten und das kontinuierliche Beantworten neu entstehender Fragen [Felden 2012]. [Schön 2018, 429, 431, 433] setzt BA mit der Bezeichnung explorative BI gleich und betont das Erkunden und Erforschen von Daten, um bisher wenig genutztes Wissen und Zusammenhänge unter Einsatz von modellbasierten statistischen Analysen, Prognosen und Maßnahmenableitungen zu nutzen. Auf diese Weise kann BA als eine Erweiterung der BI analog mit beschreibendem und ergänzend mit erklärendem Charakter interpretiert werden [Felden 2016]. Dabei legt BA den Fokus eher auf Detaildaten für die Analyse einzelner Aktivitäten [Felden 2016].

Operational BI ist ein Konzept zur Entscheidungsunterstützung im Kontext operativer Prozesse mittels analytischer Informationen [Cundius 2018, 9]. Sie dient der Herleitung besser fundierter und validerer Geschäftsentscheidungen basierend auf der Nutzung von echtzeitnahen Daten [Cundius 2018, 123] zur schnellen Ermittlung von Handlungsempfehlung beispielsweise im maschinellen Umfeld [Gluchowski 2015, 227]. Dies schließt Funktionalitäten zur Konsolidierung und Visualisierung von Daten in der Produktion ein und unterstützt durch Data Mining und Datenanalysen eine Mensch-Maschine-Interaktion [Hänel/Felden 2015, 270, 278]. Operational BI integriert Informationen ingenieurswissenschaftlicher, fertigungstechnischer und managementorientierter Perspektiven [Hänel/Felden 2013, 7].

Das Durchführen kontinuierlicher Datenanalysen und die tägliche Arbeit mit Analysetools durch Fachanwender führen zu einem weiteren Zweig der BI: So genannte Self-Service BI-Systeme (SSBI) sind zunehmend verbreitet [Bange 2015, 104]. Ursache dessen ist, dass Fachabteilungen ihre Daten schnell und flexibel analysieren möchten, um auf Veränderungen in ihren Prozessen reagieren zu können, anstatt auf die Programmierung von Abfragen durch IT-Abteilungen warten zu müssen [Diekmann/Sümmchen 2016, 25]. Die Anwendungen bieten Werkzeuge sowohl für gelegentliche Nutzer als auch fortgeschrittene Funktionalitäten mit methodischer Tiefe [Gluchowski 2015, 235]. Je nach abgerufener Funktion steigen die Systemunterstützung und die Eigenständigkeit des Anwenders von der reinen Nutzung von Informationen über die Erzeugung von Informationen bis zur selbständigen Anpassung der Quellen für die Informationen (siehe Abb. 3-2). Dies vereinfacht die zielgerichtete Erstellung und intensive Nutzung von Analyseergebnissen und ist dadurch begünstigt, dass in vielen Fachabteilungen zunehmend der Anteil an BI-Powerusern, die über das Standardreporting hinaus Analyse- und Prognosefunktionen nutzen und somit Berichte weiterentwickeln, steigt [Schön 2018, 247]. Zu beachten ist allerdings der damit einhergehende Übergang der Verantwortung für die Planung, Bereitstellung, Weiterentwicklung, Überwachung, Wartung und Pflege der SSBI-Lösungen auf die Fachanwender. Gleichermaßen sind Aufwände für den Datenschutz, Datenkonsistenz, Zugriffsmodelle sowie laufende Betriebs- und Lizenzkosten effizient abzuwickeln.

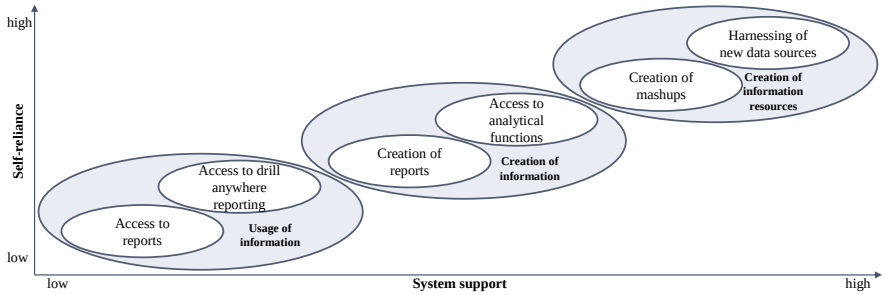

Abb. 3-2: Levels der Self-Service BI [Alpar/Schulz 2016, 152]

Da die Digitale Unternehmenssteuerung IT-basiert prozess- und hierarchieübergreifende Datenanalysen unter Anwendung innovativer Technologien zur Generierung von Informationen und Wissen aus Kennzahlendaten ermöglichen soll, sind wesentliche Eigenschaften jeder der genannten Charakterisierungen von BI, BA, operational BI und SSBI enthalten. Führungskräfte und Fachanwender nutzen je nach Analyseszenario und Bedarf Kennzahlen jeder Art perspektivenübergreifend (z. B. aggregierte, strategische Kennzahlen oder Detaildaten in Form von Störmeldungen von Maschinen). Daten und deren Ursache-Wirkbeziehungen werden explorativ untersucht sowie Vorhersagemodelle gelernt. Da der Begriff Business Intelligence nicht technologie-einschränkend, sondern technologie-offen definiert ist [Schön 2018, 432] und keine Vorgaben hinsichtlich der Datengewinnung, -auswertung, dem Einsatzzweck oder der Schnelligkeit der Analyse macht [Dittmar et al. 2016, 4], wird dieser als Überbegriff genutzt. Unter Anwendung dieses Verständnisses gibt Kapitel 3.2 Einblicke in die Praxis.

3.2 Business Intelligence in der Praxis

Die differenzierenden Begrifflichkeiten für verschiedene Typen von BI Systemen deuten an, wie viele Möglichkeiten der Analyse im BI-Umfeld in der Theorie existieren. In den Unternehmen zeigt sich jedoch, dass Reporting-Prozesse zum Großteil aus veralteten und starren Berichtsstrukturen bestehen [Diekmann/Sümmchen 2016, 22]. Fachbereiche bereiten Ist-Daten und Vergangenheitsdaten visuell auf und führen Abfragen auf diesen Daten durch [Diekmann/Sümmchen 2016, 23; Kaplan/Norton 1992, 75]. Dazu greifen die Anwender auf zahlreiche Grafikelemente wie beispielsweise Ampeldarstellungen, Linien- oder Balkendiagramme zurück [Hesse 2015, 20]. Allerdings besitzen sie häufig nur sehr eingeschränkten Zugang zu Daten. Dies betrifft teilweise sogar die durch den eigenen Bereich erzeugten Daten. Außerdem sind die Datenqualität, Detailtiefe, Flexibilität und Forecasting in vielen Fällen unzureichend [Diekmann/Sümmchen 2016, 22]. Dies gilt es zu optimieren, da sich die in Kapitel 3.1 angesprochene Self-Service-Fähigkeit der Fachbereiche in einer umfassenden, standortübergreifenden Untersuchung unter Beteiligung mehrerer Reportingexperten der BMW Group als eine sehr bedeutsame Anforderung an das zukünftige Berichtswesen herausgestellt hat.

Die in den Kapiteln 2.3.3 und 2.3.4 angesprochenen Herausforderungen der reaktiven Unternehmenssteuerung mit Kennzahlen sind auch dadurch bedingt, dass diese reine Visualisierung von Vergangenheits- oder Echtzeitdaten mit Angabe von Soll- und Istwerten, Vorjahres- oder Durchschnittswerten Usus in der deutlichen Mehrheit der Unternehmen ist [Interview 15.02.2018; Laney et al. 2012, 6]. Anstatt eine Maßnahme zu ergreifen und zurückblickend zu prüfen, ob diese erfolgreich war, sollte der Anwender eine Kennzahl in ein BI-System einfügen, dessen Einfluss auf das Verhalten und die Performance eines Prozesses untersuchen und entsprechende Maßnahmen ergreifen können [Peng et al. 2008, 197]. Jedoch finden in der Praxis solche Untersuchungen von Ursache-Wirkbeziehungen nur vereinzelt und selten

mit Unterstützung von BI-Software statt [Interview 15.02.2018] (siehe auch Kapitel 2.4.2), sodass eine integrierte Sicht auf die Vielzahl von Zusammenhängen fehlt [Hesse 2015, 20].

Während häufig suggeriert wird, dass Managementaufgaben zukünftig per Klick und Rechenalgorithmus lösbar sein werden, empfindet das Management selbst häufig eher eine Überversorgung mit Informationen ohne richtig informiert zu sein [Schön 2018, 9]. Wo schnelle, aktuelle, relevante, zuverlässige und zumeist zukunftsbezogene Informationen nötig sind, stehen überwiegend veraltete und vergangenheitsbezogene Daten zur Verfügung [Schön 2018, 20]. Zur Prüfung der Gründe dafür dient die Einschätzung der Analysefähigkeiten in diesem Feld.

3.3 Analysefähigkeiten in der Business Intelligence

Ein wesentlicher Effekt der Digitalisierung und Evolution von Software zeigt sich im Wandel des Umgangs von Unternehmen mit Daten und den enorm steigenden Erwartungen an IT-Systeme sowie Analysemöglichkeiten und -ergebnisse [Lambeck 2015, 35]. Verschiedene Komponenten der IT-Systeme werden zusammengeführt, wodurch Entscheidungsträger deutlich schneller auf Veränderungen reagieren können [Felden 2016]. Die Transformation großer Datenmengen in Informationen erlaubt das Testen von Hypothesen, die Identifikation von Trends und die Verbesserung der Entscheidungsqualität [Cokins 2013, 69]. Dies verdeutlicht den strategischen Mehrwert von Analytics [Felden 2016].

Vor diesem Hintergrund fordern die Entscheidungsträger in Unternehmen im Bewusstsein der Schwächen der reaktiven Unternehmenssteuerung auch einen Wandel zugunsten einer proaktiven kennzahlenbasierten Steuerung, unterstützt durch Analytics. Einen Schlüsselfaktor dafür stellen transparente Ursache-Wirkbeziehungen dar. Insbesondere Kapitel 2.4.2 macht deutlich, dass deren Analyse bisher überwiegend unter Einsatz qualitativer Verfahren erfolgt, also das implizite Wissen von Experten zugrunde liegt und auf diese Weise Erkenntnisse gewonnen werden. Damit gehen aber auch Nachteile wie hoher Ressourcenaufwand oder die Abhängigkeit von Inputgebern einher.

In Ergänzung zu den genutzten qualitativen Methoden stehen quantitative Informationen in Form der Kennzahlendaten zur Verfügung. Diese ermöglichen die Analyse der Ursache-Wirkbeziehungen mittels fortgeschrittener Algorithmen [Wallenburg/Weber 2006, 2]. Gartner stellen den Erkenntnisgewinn von verschiedenen Analytics-Gruppen anhand des Wertbeitrages und der Schwierigkeit, sie zu implementieren, gegenüber, wobei der Wertbeitrag mit dem Schwierigkeitsgrad steigt (siehe Abb. 3-3[15]).

[15] Die Darstellungen potentieller Umsetzungsmöglichkeiten in Abb. 3-3 dienen ausschließlich deren Verortung in den Gruppen und enthalten keine Aussage bezüglich ihres relativen Wertbeitrages.

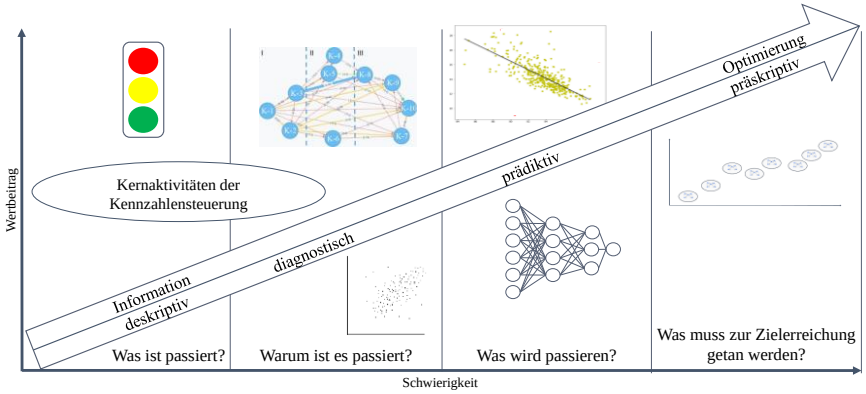

Abb. 3-3: Gartner Analytics Ascendancy Model (in Anl. an [Laney et al. 2012, 6])

Die vier Gruppen besitzen folgende Charakteristika: Die **deskriptive** Analyse beschreibt auf menschlich interpretierbare Weise, was passiert ist [Fayyad et al. 1996a, 44]. Ziel dessen ist die Überwachung relevanter Kennzahlen zur Ableitung von Aussagen über die Vergangenheit oder den Status Quo von Prozessen [Gluchowski et al. 2008, 219]. Hier haben bestehende BI-Lösungen besonders große Stärken durch Datenabfragen mit Hilfe von Queries, dem ´Slicing´ und ´Dicing´ von Daten und den in Kapitel 3.2 erwähnten Visualisierungsformen wie Ampeldarstellungen [van der Aalst 2011, 22; Halper 2014, 6]. Diese finden in der Automobilindustrie häufig zum Beispiel bei der Analyse der Über- oder Unterschreitung definierter Zielwerte von Kennzahlen Anwendung. Allerdings sind die erzeugten Berichte und Dashboards häufig unflexibel und monolithisch [Halper 2014, 6; Riexinger et al. 2015, 69]. Deshalb erfolgen aktuell bei vielen Anbietern Funktionserweiterungen, die dem Benutzer erlauben, einfache mathematische Formeln oder Operationen einzubinden (z.B. Spalten-/Zeilensummierungen) sowie Ad-hoc-Berichte[16] zu erstellen [Kemper et al. 2010, 85 f.].

Mathematische Formeln wie beispielsweise Korrelationen unterstützen die Analyse der Beziehungen der Kennzahlen untereinander, um zu prüfen, warum etwas in der Vergangenheit passiert ist [Rezgui 2018, 153]. Ein Anwendungsbeispiel ist die Analyse der statistischen Zusammenhänge der Daten verschiedener Sensoren bei der Qualitätsprüfung von Fahrzeuggetrieben. Derartige **diagnostische** Analysen finden jedoch trotz großer Nachfrage wenig Anwendung [van der Aalst 2011, 22; Halper 2014, 6]. Zahlreiche Autoren kritisieren, dass verflochtene Ursache-Wirkbeziehungen bisher nicht quantitativ und systematisch abgebildet werden können [Groesser/Jovy 2016, 64 f.; Hesse 2015, 1; Cai et al. 2009, 513]. Die Erweiterungen der Funktionsumfänge vieler Anwendungen lassen eine zunehmende Verbreitung

[16] siehe auch SSBI in Kapitel 3.1.

zukünftig jedoch annehmen, sodass deskriptive und diagnostische Analysen miteinander verschmelzen. Aufgrund dessen und der Gemeinsamkeit, dass beide Gruppen retrospektive Analyseformen zur Informationsdarstellung sind, werden sie gemeinsam betrachtet.

Komplementär zu den deskriptiven/diagnostischen Analysen verhalten sich modellorientierte Systeme [Kemper et al. 2010, 85 f.]. So können zum Beispiel lineare Regressionsmodelle, Neuronale Netze oder Entscheidungsbäume gelernt werden, welche anhand von Variablen unbekannte oder zukünftige Werte vorhersagen [Fayyad et al. 1996a, 44] und die Beantwortung der Frage nach dem, was passieren wird, ermöglichen. Diese **prädiktiven** Verfahren unterstützten das Abschätzen von Prozessergebnissen [Halper 2014, 6], das in die Zukunft gerichtete Ableiten von Maßnahmen und demnach eine proaktive Unternehmenssteuerung [Kieninger et al. 2015, 6]. Die Bedeutung solcher unterjähriger Prognosen nimmt zu; insbesondere bei Einschätzungen von Führungsverantwortlichen für Planungsänderungen [Schön 2018, 13]. Die Grundlage dafür bildet die wachsende Fülle an Daten in Unternehmen, die immer exaktere Vorhersagen ermöglicht [Diekmann/Sümmchen 2016, 25]. Sogar die vergleichsweise einfachen linearen Modelle besitzen dazu bereits eine sehr hohe Leistungsfähigkeit [Druzdzel/Flynn 2009, 2].

Obwohl sich prädiktive Analyseverfahren in Unternehmen sehr schnell verbreiten, sind sie für viele Fachanwender zunächst neu [Halper 2014, 7]. Der Grund dafür ist, dass die Anwendungen mit Prognosefunktionalitäten üblicherweise auf spezifische Anwendungsfelder zugeschnitten und demnach nicht übertragbar sind [Castellanos et al. 2005, 13]. In der Automobilindustrie nutzt sie beispielsweise die Instandhaltung zur Vorhersage von Zeitpunkten, an denen Wartungsarbeiten an Maschinen durchzuführen sind. Anwendungen, die prädiktive Prozessanalysen ohne kostenintensive und komplexe Vorarbeiten oder die Einbeziehung von Analyseexperten ermöglichen, sind nicht bekannt [Castellanos et al. 2005, 12; Halper 2014, 8].

Präskriptive Verfahren generieren spezifische Empfehlungen für Maßnahmen, welche zu ergreifen sind, um ein definiertes Ziel zu erreichen [Gröger et al. 2014, 34]. So bildet der Anwender Hypothesen und sichert diese anschließend ab [Schön 2018, 381]. Dazu finden ebenfalls modellorientierte Systeme Anwendung, was einen großen Schritt in Richtung einer automatisierten Prozesssteuerung darstellt. Präskriptive Analysen sollen für die Prozesssteuerung analog zum Tempomat in einem Fahrzeug funktionieren: Der Fahrer definiert eine gewünschte Geschwindigkeit und anhand der Informationen aus den verfügbaren Sensoren im Fahrzeug (z. B. Abstandssensoren) sowie der verfügbaren Eingriffsmechanismen (z. b. Abbremsen, Beschleunigen) bestimmen Algorithmen, was zu tun ist, um die gesetzte Geschwindigkeit zu erreichen. Ähnlich sollen Entscheidungsträger Zielwerte für Prozesskennzahlen definieren und die für deren Erreichung notwendigen Werte der beeinflussenden Kennzahlen erhalten. Derartige praktische Anwendungen sind nicht bekannt.

Diese Betrachtung verdeutlicht wiederum, dass Advanced Analytics-Algorithmen nicht umfassend zur Entscheidungsunterstützung genutzt werden [Halper 2014, 8]. [Druckenmiller/Acar 2009, 222] identifizieren eine funktionale und konzeptionelle Lücke zwischen qualitativen und quantitativen, analytischen Techniken, welche unzureichend adressiert ist. [Cokins 2013, 74] zeigt ein großes Defizit zwischen der aktuellen Nutzung und den Potentialen von Analytics auf, während [Malina et al. 2006, 940] von minimalem empirischem Support sprechen. [Horkoff et al. 2014, 1016] erkennen eine Diskrepanz zwischen den Bedarfen des Business und den durch die IT und Analytiker bereitgestellten Informationen.

Einige Anbieter von BI-Lösungen liefern zumindest grundsätzliche Werkzeuge mit mathematischen Funktionen [Schön 2018, 334] und bieten Schnittstellen zu fremden Softwarelösungen wie R oder Python für die Implementierung fortgeschrittener Analysemethoden. Diese sind jedoch nur für Spezialisten anwendbar. Als Resultat fasst ein Manager eines global agierenden IT-Beratungsunternehmens in einem Interview die Situation so zusammen, dass BI und Data Analytics in der Praxis streng getrennt sind [Interviews 01.02.2017 & 25.07.2018]. BI und Reporting-Experten der BMW Group bestätigten, dass es kaum Advanced Analytics-Funktionen in aktuellen Anwendungen im Kennzahlenumfeld gibt. Somit schöpfen Unternehmen deren großen Potentiale für die Untersuchung von Kennzahlendaten zur Deckung des Bedarfes nach quantitativer Entscheidungsunterstützung nicht aus.

Angesichts dessen sind die Analytics-Kernaktivitäten im Umfeld der Kennzahlensteuerung im deskriptiven und teilweise diagnostischen Bereich einzuordnen (siehe Abb. 3-3). In Übereinstimmung damit stellen [Heath/Hull 2015, 176] fest, dass die Integration von Advanced Analytics-Funktionen in die operative Unternehmenssteuerung zur Ergänzung von Erfahrungswissen in vielen Fällen übersehen wird. Dies zeigt sich auch im Umgang mit den Kennzahlen, da häufig „…eine Kennzahl solange unbeachtet bleib[t], wie sie einen guten Status (grün) [einhält]. Die Betrachtung einzelner Kennzahlen erfolg[t] erst beim Wechsel zu gelb beziehungsweise rot“ [Hesse 2015, 172]. Der Eingriff erfolgt also erst bei Verfehlung der eigentlichen Zielstellung [Interview 23.02.2018]. Besonders problematisch ist, dass selbst eine fundierte Entscheidung einen negativen Effekt erzielen kann, wenn sie zu spät getroffen wurde [Hesse 2015, 174].

Da aber die Anforderungen an eine immer stärkere Verzahnung zwischen operativen und analytischen Tätigkeiten in der unternehmerischen Praxis wachsen, ist ein Umdenken hinsichtlich dieser Trennung vonnöten [Knabke/Olbrich 2015, 188]. Der bereits seit einiger Zeit bestehende Wunsch, nützliche Informationen computergestützt aus bestehenden Datenmengen zu extrahieren (siehe z. B. [Fayyad et al. 1996b, 1]), überträgt sich zunehmend auf Kennzahlendaten. Es wird erwartet, dass der Anwender durch analytische Methoden in der Lage ist, sich ein vertieftes Verständnis über die Ursache-Wirkbeziehungen der durch die Kennzahlen repräsentierten Prozesse anzueignen [Schieder 2015, 25; Hesse 2015, 206]. Darüber hinaus empfinden Entscheidungsträger retrospektive Darstellungen von Kennzahlen nicht mehr als ausreichend, sondern fordern deren Vorhersage zur Senkung von Kosten

und der Steigerung der Effizienz und folglich der Wettbewerbsfähigkeit [Castellanos et al. 2005, 1; Laney et al. 2012, 1]. Dies wird die im Feld der BI bisher vernachlässigte Einbindung von Advanced Analytics-Algorithmen und die Endbenutzer-Autonomie beleben [Dittmar 2015, 58] und ihnen ein stärkeres Gewicht als bisher zukommen lassen [Schön 2018, 430]. Es wird sogar erwartet, dass „…qualitativ-theoretische Ursache-Wirkungsketten sukzessive durch datenbasierte, quantitativ-statistische Zusammenhänge ersetzt und kontinuierlich auf ihre Validität hin überprüft…“ werden [Mehanna et al. 2015, 30]. In der Praxis zeigt sich dabei, dass der Endnutzer es präferiert, ein Werkzeug mit umfangreicheren Informationen intensiv als mehrere Werkzeuge punktuell zu nutzen [Hesse 2015, 170], wobei der Aufwand vor der Nutzengenerierung (z. B. durch eine aufwendige Anbindung an produktive Systeme) möglichst gering ausfallen sollte.

Da im Bereich der Datenanalyse Begriffe wie Advanced Analytics (oder fortgeschrittene Analysemethoden) und Data Mining unterschiedlich ausgelegt werden, dienen die folgenden Betrachtungen der Schaffung eines gemeinsamen Verständnisses.

3.4 Advanced Analytics und Data Mining

Gartner definieren Advanced Analytics mit direktem Bezug zur BI als „…the analysis of structured data and content (such as text, images, video and audio), using sophisticated quantitative methods (for example, statistics, descriptive and predictive data mining, simulation and optimization) to produce insights that traditional approaches to BI — such as query and reporting — are unlikely to discover”. [Laney et al. 2012, 5] Während diese Definition deskriptive Analysefunktionalitäten der Advanced Analytics zurechnet, schließt Gluchowski in Abb. 3-4 lediglich prädiktive und präskriptive Verfahren ein. Eine scharfe Trennung dieser Begrifflichkeiten ist in der Praxis jedoch nicht möglich, sodass fließende Übergänge zwischen den Funktionalitäten (beispielsweise der kontextabhängigen Zuordnung diagnostischer Verfahren) anzunehmen sind. Daher subsumiert [Felden 2016] unter Advanced Analytics „…moderne Verfahren der Auswertung großer Datenvorräte, vor allem Data Mining und maschinelles Lernen auf Grundlage der Künstlichen Intelligenz und statistischer Methoden.“ Schließlich beinhaltet Advanced Analytics für Entscheidungsverantwortliche in der Praxis ein Spektrum an Technologien und Methoden zur Entscheidungsunterstützung durch die Abschätzung der Folgen von Handlungsoptionen, Priorisierung, Identifikation und Gewichtung relevanter Einflussgrößen sowie Vorhersagen [Felden 2016].

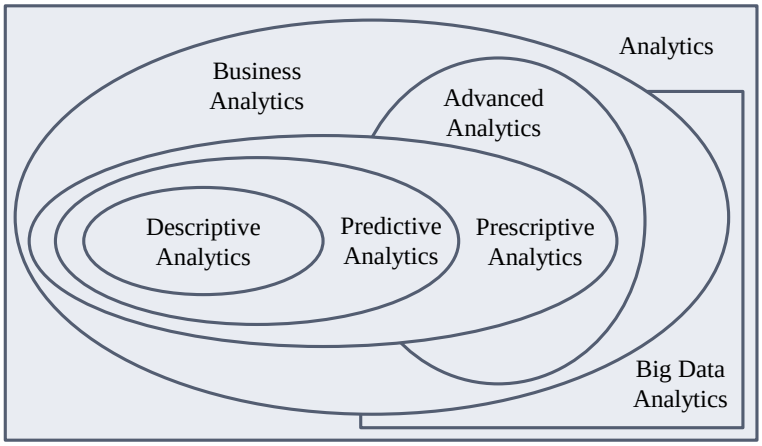

Abb. 3-4: Einordnung unterschiedlicher Analytics-Ausprägungen [Gluchowski 2016, 277]

Wie bereits bei den Definitionen von Advanced Analytics zu erkennen war, führt die Auseinandersetzung mit Datenanalysen unweigerlich zu dem Begriff Data Mining. Allgemein beschreibt [Gluchowski 2016, 275] Data Mining als das Fördern wertvoller Informationen aus großen Datenbeständen. Etwas konkreter wird es als die Anwendung spezifischer Algorithmen für die Extraktion Nutzen stiftender Muster aus Daten bezeichnet [Fayyad et al. 1996a, 39; Witten et al. 2011, 5] und als ein Schritt der „Knowledge Discovery in Databases“ (KDD) zugeordnet. Die Primärziele seien die Deskription und Prädiktion [Fayyad et al. 1996a, 44]. Andere Autoren wiederum setzen Data Mining mit Predictive Analytics gleich [Bange 2015, 124 f.; Domingos 2012, 69]. Die dem Data Mining zugeordneten Methoden, stammen aus den Bereichen Statistik, künstliche Intelligenz, maschinelles Lernen oder klassischer Mustererkennung [Gladen 2014, 33 f.; Kemper et al. 2010, 115], wobei in Abhängigkeit von der Aufgabenstellung eine oder mehrere dieser Methoden zum Einsatz kommen [Kemper et al. 2010, 115]. Die übergeordnete Absicht ist die Entdeckung neuer Zusammenhänge sowie Strukturen [Gladen 2014, 33 f.] und somit die Aufdeckung von Ursache-Wirkbeziehungen [Chamoni/Gluchowski 2017, 11].

Es zeigt sich, dass umfassende Überschneidungen zwischen den Definitionen von Data Mining und Advanced Analytics existieren. Dies geht auch aus der eingangs des Kapitels erläuterten Definition von Gartner hervor. Angesichts dessen interpretiert [Gluchowski 2015, 227] Advanced Analytics vereinfachend als neue Begrifflichkeit für Data Mining. Dieser Einordnung folgend, ist für die vorliegende Dissertation unter Advanced Analytics die Anwendung von Analysemethoden für die Gewinnung von Erkenntnissen aus Kennzahlendaten, die über die reine Abfrage, Visualisierung oder (Dis-) Aggregation hinausgeht, zu verstehen. Somit liegt der Schwerpunkt auf der Datenanalyse mit Hilfe fortgeschrittener, quantitativer Methoden. Vor diesem Hintergrund erfolgt die Prüfung wissenschaftlicher Ansätze für die empirische Analyse von Kennzahlenrelationen und der Einsatz von Advanced Analytics-Algorithmen im nächsten Abschnitt.

3.5 Ansätze für die empirische Analyse von Kennzahlenrelationen

Sowohl in der Praxis als auch in der Wissenschaft stößt die empirische Analyse von Kennzahlenrelationen auf großes Interesse. In Tabelle 3-1 erfolgt die Schaffung eines Überblicks über aktuelle wissenschaftliche Ansätze. Sie unterteilen sich grob in qualitativ und quantitativ geprägte Vorgehensweisen. Die angewandte Suchmethodik entsprach der Erzeugung einer initalen Datenbasis auf Grundlage der Ergebnisse umfassender Stichwortsuchen (auf deutsch und englisch) in wissenschaftlichen Datenbanken und Online-Quellen. Die Nutzung von Suchstrings ermöglichte jedoch angesichts der Interdisziplinarität der Fragestellung, der Vielzahl möglicher nutzbarer Algorithmen sowie zahlreicher synonymer Begrifflichkeiten in deutscher und englischer Sprache nur eine bedingt geeignete Eingrenzung des Forschungsfeldes. Daher schloss sich auf relevante Beiträge aufbauend eine umfangreiche Forward- sowie Backward-Recherche an, welche zur Auswahl folgender Ansätze führte.

3.5.1 Qualitativ geprägte Ansätze für die empirische Analyse von Kennzahlenrelationen

Für die Bewertung der aufgeführten wissenschaftlichen Ansätze erfolgt eine Einordnung nach fünf Eigenschaften: Prozesse in großen Produktionsunternehmen werden durch eine Vielzahl von Kennzahlen beeinflusst oder erhalten Zielvorgaben für diese. Jene Kennzahlen haben unterschiedliche Einheiten (z. B. Stückzahl, Zeit), welche die Analyse der Relationen zwischen diesen nicht behindern dürfen (Eigenschaft 1: **Verschiedene Einheiten**). Die Beziehungen und deren Intensität werden, wie in Kapitel 2.5 erläutert, qualitativ oder quantitativ ermittelt (Eigenschaft 2 und 3: **Ermittlung Relationen** und **Analyse Relationsstärke**). Zudem ist es wichtig, insbesondere angesichts des großen Zeitdrucks, unter welchem Prozessverantwortliche häufig stehen, die identifizierten Relationen zu visualisieren, um eine effektive Nutzung der Ergebnisse zu ermöglichen [Heimes et al. 2019, 58; Peral et al. 2017, 77] (Eigenschaft 4: **Visualisierung der Relationen**). Außerdem können die Ansätze den Gruppen der Analysefähigkeiten zugeordnet werden: Deskriptiv/diagnostisch, prädiktiv, präskriptiv.

Quelle	Ermittlung Relationen	Analyse Relations-stärke	Verschie-dene Ein-heiten	Visualisie-rung der Relationen	Analyse-gruppe
[Muschter 1999]	Qualitativ	Qualitativ	Ja	Ja	Deskriptiv/ Diagnostisch
[Kotzanikolaou et al. 2013]	Qualitativ	Qualitativ	Ja	Ja	Deskriptiv/ Diagnostisch
[Malik 2013]	Qualitativ	Qualitativ	Ja	Ja	Deskriptiv/ Diagnostisch
[Lange et al. 2007]	Qualitativ	Qualitativ	Ja	Nein	Deskriptiv/ Diagnostisch
[Saaty 2008]	Qualitativ	Qualitativ	Ja	Nein	Deskriptiv/ Diagnostisch
[Suwignjo et al. 2000]	Qualitativ	Qualitativ	Ja	Ja	Deskriptiv/ Diagnostisch
[Cai et al. 2009]	Qualitativ	Quantitativ	Ja	Ja	Deskriptiv/ Diagnostisch
[Berrah/Foulloy 2013]	Qualitativ	Qualitativ	Ja	Ja	Deskriptiv/ Diagnostisch
[Forrester 2009]	Qualitativ	Qualitativ	Limitiert	Ja	Deskriptiv/ Diagnostisch
[van der Aalst 2011]	Quantitativ	Quantitativ	Nein	Ja	Deskriptiv, Prädiktiv
[Schwanin-ger/Kaiser 2007]	Quantitativ	Quantitativ	Ja	Nein	Deskriptiv, Prädiktiv
[Youngblood/Col-lins 2015]	Quantitativ	Qualitativ & Quantita-tiv	Ja	Nein	Deskriptiv, Prädiktiv
[Shimizu et al. 2006]	Quantitativ	Keine	Ja	Nein	Deskriptiv/ Diagnostisch
[Arnold et al. 2007]	Quantitativ	Keine	Ja	Ja	Deskriptiv/ Diagnostisch
[Patel et al. 2008]	Quantitativ	Keine	Ja	Ja	Deskriptiv/ Diagnostisch
[Malina et al. 2006]	Quantitativ	Quantitativ	Ja	Ja	Deskriptiv, Prädiktiv
[Rodriguez et al. 2009]	Quantitativ	Quantitativ	Ja	Ja	Deskriptiv, Prädiktiv

Quelle	Ermittlung Relationen	Analyse Relations-stärke	Verschie-dene Ein-heiten	Visualisie-rung der Relationen	Analyse-gruppe
[Rupp-recht/Schweinber-ger 2008]	Quantitativ	Keine	Ja	Nein	Deskriptiv/ Diagnostisch
[Peng et al. 2008]	Quantitativ	Keine	Ja	Nein	Deskriptiv/ Diagnostisch
[Sultan et al. 2017]	Quantitativ	Quantitativ	Ja	Nein	Deskriptiv/ Diagnostisch
[Imran/Zoha 2014]	Quantitativ	Quantitativ	Ja	Nein	Deskriptiv, Prädiktiv
[Shin et al. 2015]	Quantitativ	Quantitativ	Ja	Nein	Prädiktiv
[Maggi et al. 2014]	Quantitativ	Quantitativ	Ja	Nein	Prädiktiv
[Metzger et al. 2015]	Quantitativ	Quantitativ	Ja	Nein	Prädiktiv
[Castellanos et al. 2005]	Quantitativ	Quantitativ	Ja	Nein	Prädiktiv
[Hesse 2015]	Qualitativ & Quantitativ	Quantitativ	Ja	Ja	Deskriptiv/ Diagnostisch
[Peral et al. 2017]	Quantitativ	Quantitativ	Ja	Ja	Deskriptiv/ Diagnostisch
[van Helden et al. 2018]	Qualitativ	Quantitativ	Ja	Ja	Präskriptiv
[Gröger et al. 2014]	Quantitativ	Quantitativ	Ja	Ja	Präskriptiv

Tabelle 3-1: Ansätze der empirischen Analyse von Ursache-Wirkbeziehungen

Die Verbreitung qualitativer Verfahren zur Analyse von Ursache-Wirkbeziehungen in der Praxis spiegelt sich in der Literatur wider. Beispielsweise nutzen [Muschter 1999] und [Kotzanikolaou et al. 2013] dazu Expertenbefragungen und Methoden, wie einen paarweisen Vergleich. Sowohl bei [Malik 2013] als auch bei [Lange et al. 2007] kommt alternativ, wie in dem Praxisbeispiel in Kapitel 2.4.2, die Sensitivitätsanalyse von Vester zum Einsatz. Ebenfalls auf Basis des Erfahrungswissens von Experten erfassen [Saaty 2008; Suwignjo et al. 2000; Cai et al. 2009] mit Hilfe des Analytic Hierarchy Process (AHP) die relativen Wichtigkeiten von Kenngrößen für bestimmte Fragestellungen.

Erfasstes qualitatives Wissen übersetzen [Berrah/Foulloy 2013] in mathematische Formeln. Gleiches bildet die Grundlage für die Erzeugung von Modellen in der sehr umfangreichen System Dynamics Forschung; hier repräsentiert durch [Forrester

2009]. Flussdiagramme, welche Bestandsgrößen, Flussgrößen, Hilfsgrößen und weitere Elemente beinhalten, bilden dabei formale Simulationsmodelle mit quantitativen Informationen (Gleichungen, Input-/Outputtabellen) [Schwaninger 2004, 22], die die Annahmen mentaler Modelle reflektieren [Forrester 2009, 9]. Eine wesentliche Anforderung bei der Anwendung von System Dynamics ist, dass die genutzten Größen im Modell hinsichtlich ihrer Einheiten wie Stückzahl oder Zeit mathematisch aufgehen, wofür Hilfsvariablen zum Einsatz kommen. Wegen dieses Zwischenschrittes erfolgt die Einschätzung der Anwendbarkeit für verschiedene Einheiten der Kennzahlen als limitiert.

3.5.2 Quantitative Ansätze für die empirische Analyse von Kennzahlenrelationen

Ein großes Forschungsfeld zur quantitativen Erfassung der Beziehungen zwischen Kennzahlen ist das Process Mining, für welches stellvertretend der Beitrag von [van der Aalst 2011] steht. Es erlaubt anhand der Analyse von Logfiles den Vergleich zwischen Soll- und Ist-Prozessverläufen, die Visualisierung unbekannter Prozessverläufe oder die Vorhersage verbleibender Prozesszeiten. Insofern beantwortet dies andere Fragestellungen und nutzt eine andere Datengrundlage als für die empirische Analyse von Kennzahlenrelationen gefordert.

[Patel et al. 2008] erzeugen Causal Loop Diagramme auf Basis von Strukturgleichungsmodellen, um Ursache-Wirkbeziehungen zwischen Kennzahlen zu analysieren. In der Praxis sind derartige Modelle jedoch nur mit hohem Aufwand aktualisierbar, wenn sich die Begebenheiten verändern.

Eine quantitative Analyse von Kausalitäten auf Basis von Daten führen [Shimizu et al. 2006] sowie [Arnold et al. 2007] und [Malina et al. 2006] unter Anwendung der Granger-Kausalität durch. Diese Methode kombinieren [Rupprecht/Schweinberger 2008] mit Korrelationsanalysen. Letztere nutzen ebenfalls [Sultan et al. 2017; Hesse 2015] und [Youngblood/Collins 2015] zur deskriptiven/diagnostischen Analyse von Kennzahlenrelationen. Dabei ist zu bemerken, dass die Arbeit von [Hesse 2015] in einem vergleichbaren Umfeld entstand und folglich als Gesamtkonzept der Digitalen Unternehmenssteuerung von den diskutierten Ansätzen insgesamt am nächsten kommt und eine gute Grundlage bildet.

[Peng et al. 2008] analysieren mittels Dynamic Time Warping zeitliche Latenz und ebenfalls Kausalitäten nach Granger. Anschließend erfolgt eine Dimensionsreduktion unter Einsatz einer Hauptkomponentenanalyse und die Identifikation redundanter Kennzahlen mit Clustering-Algorithmen. Dabei zeigt sich deutlich, dass die Kombination mehrerer komplementärer Analysemethoden zu sich ergänzenden Erkenntnissen führen kann.

Ebenso finden bei [Peral et al. 2017] mehrere Methoden wie Korrelationsanalysen, Zeitreihenanalysen, lineare Regression und Entscheidungsbäume für die Überprüfung vorher erstellter Hypothesen Anwendung. Auch [Schwaninger/Kaiser 2007] kombinieren Korrelationen und lineare Regressionen. Die Einflüsse bestimmter

Messgrößen auf Netzwerkparameter in selbstorganisierenden Netzwerken untersuchen [Shin et al. 2015] ebenfalls unter Einsatz von multivariaten linearen Regressionsmodellen. Anhand dieser Ansätze zeigt sich die große Verbreitung der linearen Regression und von Korrelationsanalysen im Kennzahlenkontext, weshalb diese näher betrachtet werden sollten.

Die Hauptkomponentenanalyse ist eine weitere Analysemethode, die wiederholt Anwendung findet. Sie erlaubt, die Daten mit einem reduzierten Satz von Variablen, den Hauptkomponenten, die eine gewichtete Summe der ursprünglichen Variablen darstellen, zu beschreiben [Ng/Soo 2018, 43]. [Rodriguez et al. 2009] nutzen ihre Datenreduktionsfunktion[17] beispielsweise für die Identifikation der relevantesten Kennzahlen zur Unternehmenssteuerung und [Imran/Zoha 2014] für die Selbststeuerung von Kapazitäten in 5G Netzwerken (ein weiteres Beispiel liefern [Moellers et al. 2019] im System Dynamics-Umfeld). Das Ziel der Hauptkomponentenanalyse ist demnach eher, Objekte anhand ihrer wichtigsten Faktoren einfacher zu beschreiben [Schön 2018, 382], als das dahinterliegende Ursache-Wirkgefüge zu verstehen. Entscheidungsbäume sind ebenfalls weit verbreitete Modelle, welche in ihren unterschiedlichen Ausprägungen sowohl für Regressionsprobleme als auch für Klassifikationsprobleme wie bei [Maggi et al. 2014] genutzt werden.

Wie zuvor beschrieben, besteht einerseits die Möglichkeit, unterschiedliche Analysemethoden zu kombinieren, um deren unterschiedliche Erkenntnisse zusammenzuführen (bspw. Korrelation zur Deskription und lineare Regression zur Prädiktion). Andererseits bietet es sich in vielen Fällen an, unterschiedliche Verfahren hinsichtlich ihrer Eignung zur Lösung eines spezifischen Problems zu vergleichen. [Metzger et al. 2015] beabsichtigen die Vorhersage der Einhaltung von Lieferzeiten von Prozessen während deren Durchführung und stellen für diesen konkreten Anwendungsfall die Vorhersagegüte dreier unterschiedlicher prädiktiver Verfahren gegenüber. Auf diese Weise finden sie die beste Lösung für das untersuchte spezifische Problem. Ähnlich gehen [Castellanos et al. 2005] vor, die für unterschiedliche Problemstellungen automatisiert mehrere Algorithmen (wie z. B. Entscheidungsbäume) zur Prädiktion anwenden, deren Vorhersagegüte vergleichen und den am besten geeigneten Algorithmus nutzen. Die Entscheidung, welche der Analysemethode angewendet wird, trifft die Software automatisch.

Als Repräsentanten für präskriptive Ansätze seien [van Helden et al. 2018] und [Gröger et al. 2014] genannt. [van Helden et al. 2018] schlagen anhand von linearen Optimierungsmodellen und Einflussdiagrammen automatisiert konkrete Maßnahmen in Entscheidungssituationen vor. [Gröger et al. 2014] fokussieren sich auf die Echtzeit-Vorhersage von Prozessergebnissen und leiten bei einer vorhergesagten Verfehlung der Zielvorgaben Vorschläge für Maßnahmen ab.

[17] Siehe hierzu auch [Cleff 2015, 221].

3.5.3 Schlussfolgerungen der Analyse wissenschaftlicher Ansätze

Zwar erhebt diese Übersicht keinen Anspruch auf Vollständigkeit, sie vermittelt jedoch einen Eindruck, wie fortgeschrittene Analysemethoden in der Wissenschaft schwerpunktmäßig eingesetzt werden. Dies erfolgt überwiegend im deskriptiven/ diagnostischen Bereich. Prädiktive Funktionalitäten erfahren ebenfalls viel Aufmerksamkeit, während präskriptive Ansätze in der Minderheit sind. Darüber hinaus zeigt sich deutlich, dass quantitative Analysemethoden dabei helfen, Erkenntnisse über das Verhalten von Prozessen zu gewinnen. Zu diesem Zweck kommen häufig kombinierte Analysemethoden zum Einsatz, um deren sich ergänzende Funktionen für einen erweiterten Erkenntnisgewinn zu nutzen. Wiederholt angewandte Methoden sind z. B. Korrelationsanalysen, Granger-Kausalität, lineare Regressionen, Hauptkomponentenanalysen oder Entscheidungsbäume. Zu berücksichtigen ist dabei, dass verschiedene Methoden in der Regel für die Beantwortung diverser Fragestellungen unterschiedlich gut geeignet sind. Daher sollten nicht nur mehrere komplementäre Analysen durchgeführt, sondern insbesondere im prädiktiven Bereich mehrere Methoden im Sinne einer Werkzeugoptimierung komparativ eingesetzt werden. Um jene Analysen durchführen zu können, ist eine Grundvoraussetzung, dass die Daten aussagekräftig sind, sodass mögliche, die Qualität beeinflussende Eigenschaften der Daten wie durch den Realprozess verursachte zeitliche Latenz das Analyseergebnis nicht verfälschen.

Die durchgeführte Analyse zeigt, dass diagnostische, prädiktive und präskriptive Analysen im BI-Umfeld in der Praxis kaum Anwendung finden (siehe Kapitel 3.3). Auch in der Wissenschaft beschäftigen sich vergleichsweise wenige Studien mit der Identifikation und Auswahl von Kennzahlen unter Einsatz von Datenanalysen [Sultan et al. 2017, 60]. Die vorhandenen Ansätze wiederum finden keine breite praktische Anwendung, was anhand der vorliegenden Literaturanalyse auf mehrere Punkte zurückzuführen ist. So sind wenige umsetzbare Vorschläge bekannt, wie Analysen von Kennzahlendaten in die unternehmerische Praxis einzubinden sind, um das Management bestmöglich zu unterstützen. Zudem müssen die Ansätze dergestalt sein, dass die Vorteile quantitativer Analysen wie gesteigerter Objektivität tatsächlich nutzbar sind: [Rodriguez et al. 2009, 106] kritisieren, dass es zwar eine Menge an Methoden und Frameworks gibt, die die Leistungsmessung und das Management adressieren, jedoch subjektive Annahmen bei jedem Schritt verlangen und somit die Objektivität der Ergebnisse reduzieren.

Hinzu kommt, dass bei der Erweiterung der traditionellen BI um eine explorative BI die Wirtschaftlichkeit zu wahren ist, da letztlich nüchtern über Investitionen in IT und Know-how zu entscheiden ist [Schön 2018, 438, 441]. Die Bedeutung dieses Faktors zeigt sich darin, dass sich die meisten Organisationen bereits mit der sehr schwierigen Quantifizierung des Kosten-Nutzen Verhältnisses von Data Analytics beschäftigt haben [Laney et al. 2012, 3].Studien aus der betrieblichen Praxis bestätigen dies [Heimes et al. 2019, 59]. Zentrale Faktoren für den wirtschaftlichen Einsatz von Advanced Analytics sind die einfache Aktualisierung und die Übertragbarkeit der Modelle auf andere Probleme, um die eingesetzten Ressourcen effizient zu

nutzen. Zahlreiche wissenschaftliche Ansätze setzen ihren Schwerpunkt jedoch weniger auf generisch einsetzbare und skalierbare Softwarelösungen, die die explorative Analyse von Ursache-Wirkbeziehungen ermöglichen (beispielsweise externe und interne Daten versuchsweise oder hypothesenbasiert einem Modell hinzufügen oder entfernen), sondern erzeugen Modelle für spezialisierte Einzelprobleme[18]: „Existing predictive process monitoring approaches are tailor-made for specific prediction tasks and not readily generalizable." [Tax et al. 2017, 477] Ein positives Beispiel liefern [Metzger et al. 2015], die anhand einer Auswahl definierter Methoden automatisiert das in Relation beste Modell für einen importierten Datensatz lernen und somit eine Lösung mit einem vergleichsweise hohen Maß an Generalisierung schaffen. Dazu wählen sie bewusst generische Parametrisierungen der Modelle mit dem Ziel der Übertragbarkeit auf andere Probleme mit ähnlichen mathematischen Begebenheiten und akzeptieren im Einzelfall etwas weniger genaue Analyseergebnisse [Metzger et al. 2015, 278]. Diese in der Echtzeit-Prozesssteuerung genutzte Generik kann auf die kennzahlenbasierte, explorative Analyse von Kennzahlenrelationen übertragen werden, wobei es wichtig ist, dass die Fachanwender durch den Prozess der Modellbildung geführt werden, um zuverlässige Ergebnisse zu erzeugen.

Ein solches unterstütztes Vorgehen hilft außerdem, Vertrauen der Anwender in die durchzuführende Analyse aufzubauen, was Grundlage für dessen Akzeptanz ist [Schön 2018, 314]. Gerade in der Einführungsphase neuer Softwarelösungen muss das erlernte Modell ein für den Anwender interpretierbares Verhalten besitzen, um langfristig Vertrauen aufzubauen [Heimes et al. 2019, 58]. [Caruana et al. 2015, 1721] schildern beispielsweise, dass im medizinischen Kontext, in welchem Entscheidungsträger ebenfalls eine sehr hohe Verantwortung tragen, die etwas schlechteren Ergebnisse eines Algorithmus mit höherer Interpretierbarkeit den besseren Ergebnissen eines Algorithmus mit geringerer Interpretierbarkeit vorgezogen wurden. Unter Interpretierbarkeit ist zu verstehen, dass der Anwender den Beitrag der einzelnen Variablen durch eine Quantifizierung dessen Einflusses verstehen kann [Lou et al. 2012, 150]. Insbesondere bei prädiktiven Analysen stehen die Interpretierbarkeit und die Aufdeckung von Ursache-Wirkbeziehungen üblicherweise nicht im Fokus, sondern die Erreichung einer größtmöglichen Vorhersagegenauigkeit, wodurch die Interpretierbarkeit in vielen Fällen erschwert wird [Kuhn/Johnson 2013, 4].

[18] Analog zu Problemen wie Predictive Maintenance, wo solche Methoden bereits eingesetzt werden.

„Ein „gutes“ Planungs- und Analysesystem kann […] nur ein System sein, das auf die Bedürfnisse der Anwender zugeschnitten ist.“ [Schön 2018, 314] In vielen Fällen sind die vorhandenen Systeme aber nicht optimal in Unternehmen nutzbar, da das Know-how der Mitarbeiter hinsichtlich statistischer Methoden und Modelle nicht entsprechend ausgebaut ist [Schön 2018, 314]. Die meisten Data Mining Tools benötigen beispielsweise für das Parametertuning[19] oder die Auswahl der Algorithmen und deren Interpretation umfassende Erfahrungen des Anwenders [Castellanos et al. 2005, 7]. Eine in den genannten Ansätzen wiederholt genutzte Software zur Datenanalyse ist Weka (siehe [Peral et al. 2017; Metzger et al. 2015; Maggi et al. 2014]. Diese ist auf Analysespezialisten ausgerichtet und für Fachbereichsanwender nur schwierig zu nutzen und zu interpretieren. Als anderes Extrem ist es für den Fachanwender nicht nachvollziehbar, wie die Auswahl der am besten geeigneten Methode bei dem Ansatz von [Castellanos et al. 2005] erfolgt. Überdies kritisieren [Peral et al. 2017, 81] die geringe Transparenz von Verfahren wie Neuronalen Netzen oder Entscheidungsbäumen.

Es zeigt sich, dass, während grundlegende deskriptive Datenanalyseverfahren für die meisten Entscheidungsträger vergleichsweise gut verständlich sind, sie hinsichtlich fortgeschrittener Analysemethoden auf Spezialisten angewiesen sind [Kowalczyk/Gerlach 2015, 3]. Insbesondere in Kapitel 3.1 wurde im Zusammenhang mit der Diskussion von Self-Service BI jedoch deutlich, dass Anwender eigentlich mehr Unabhängigkeit von Spezialisten anstreben. Anwender sollten also durch ein hohes Maß an Anwenderfreundlichkeit unabhängig von der IT oder Analysespezialisten Daten schnell und einfach zu Modellen hinzufügen oder entfernen und diese analysieren können. [Halper 2014, 13] nennt dies ´Demokratisierung´ von Analysesoftware. Demnach ist eine wichtige Voraussetzung für den flächendeckenden Einsatz von fortgeschrittenen Analysemethoden im Kennzahlenkontext, dass die Entscheidungsträger sie selbst anwenden können, sie verstehen, ihnen vertrauen und somit akzeptieren [Cleff 2015, 13; Kowalczyk/Gerlach 2015, 12]. Letztlich muss aber auch bewusst sein, dass das Interesse der Entscheidungsträger weniger in technischen und methodischen Details, sondern in Qualität, Zuverlässigkeit und Vertrauenswürdigkeit liegt [Felden 2016].

---

[19] Tuningparameter sind Optionen für die Variation der Einstellungen von Algorithmen, welche bei falscher Konfiguration die Leistungsfähigkeit der Modelle reduziert [Ng/Soo 2018, 12]. Sie können einerseits eine Überempfindlichkeit des Algorithmus bewirken, sodass zufällige Abweichungen als reale Muster fehlinterpretiert werden (Overfitting) [Ng/Soo 2018, 12]. Andererseits besteht die Gefahr der Unteranpassung, wenn der Algorithmus zu unempfindlich ist und offensichtliche Strukturen in den Daten ignoriert (Underfitting) [Ng/Soo 2018, 12]. Zwischen diesen Möglichkeiten ist beim Parametertuning die Balance zu finden. Die Schwierigkeit ist, dass sie sich von Datensatz zu Datensatz unterscheiden [Di Francescomarino et al., 364]. Allerdings kann dies weder direkt aus dem Datensatz abgeleitet werden, noch existiert eine analytische Formel, die geeignete Werte bestimmt [Kuhn/Johnson 2013, 64 f.]. Folglich legen Fachfremde häufig Standardwerte, empfohlene Werte oder zufällig bestimmte Werte fest [Thornton et al. 2013, 847]. Die beiden einfachsten Wege für das systematisch Parametertuning sind Random Search und Grid Search [Di Francescomarino et al., 364].

Im Rahmen akademischer Untersuchungen werden zwar eine Vielzahl analytischer Verfahren vorgestellt, deren Anwendbarkeit in der betriebswirtschaftlichen Praxis jedoch nicht hinreichend beantwortet [Knobloch/Weidner 2013, 364]. Die Diskussion hinsichtlich rein technischer Aspekte ist deutlich umfassender als deren Anwendungsmöglichkeiten für die Unternehmenssteuerung [Hänel/Felden 2013, 3 f.]. Eine Integration von Prozessdaten und Daten aus Management-Systemen erfolgt zudem nicht [Gröger et al. 2014, 25]. Eine Studie, die das Institut für Angewandte Informatik e. V. in Zusammenarbeit mit der BMW Group durchgeführt hat, kommt unter anderem zu dem Schluss, dass nicht automatisch ein Mehrwert für Unternehmen erzeugt wird, wenn Kennzahlenrelationen mittels Advanced Analytics analysiert werden [Hoberecht/Alt 2018]. In Ergänzung dazu fasst [Schön 2018, 314] treffend zusammen: „Je komplexer die Systeme im Aufbau und in ihrer Funktionalität sind, desto mehr Vertrauen muss dem System entgegengebracht werden. Der Output eines IT-gestützten Systems erscheint dem Anwender aufgrund der undurchschaubaren Informationsprozesse oftmals wie ein Ergebnis aus einer „Blackbox“. Hier besteht die Gefahr einer Systemgläubigkeit, dass z. B. IT-gestützte Planungsfunktionen einfach genutzt und errechnete Planergebnisse unreflektiert übernommen werden. Die IT-Bausteine und Funktionen stellen allerdings nur Instrumente bzw. Werkzeuge dar und dienen demnach als Hilfsmittel…“ Insbesondere in der Unternehmenssteuerung ist eine unreflektierte Übernahme von Ergebnissen mit Risiko belegt, weshalb errechnete Ergebnisse für den Anwender bestmöglich interpretierbar sein sollten. Die Befragung von potentiellen Fachanwendern bei der BMW Group ergab ebenfalls, dass die Interpretierbarkeit und Transparenz der Ergebnisentstehung für einige von ihnen sehr wichtig ist [Casares 2019, 87, 112]. In welcher Form Black Boxes dennoch für die Digitale Unternehmenssteuerung vorteilhaft sein können, wird in Kapitel 3.6 untersucht.

3.6 Quantitative Analyse von Kennzahlenrelationen in der Black Box

Die inhärente Systemkomplexität großer Produktionsunternehmen stellt Entscheidungsträger vor die Herausforderung, die richtigen und notwendigen Informationen zu identifizieren und zu nutzen. Gerade beim Treffen intuitiver Entscheidungen neigt man dazu zu glauben, dass alle verfügbaren Informationen nützlich und größere Mengen an Informationen kleineren Mengen vorzuziehen sind [Saaty 2008, 83]. Allerdings trifft dies nicht zu, da zu viele Informationen gleichermaßen schlecht sein können wie zu wenig Informationen [Saaty 2008, 83]. In der Praxis zeigt sich, dass es kaum möglich ist, die betriebliche Wirklichkeit und somit Entscheidungsprozesse mit all ihren Ursache-Wirkbeziehungen detailliert und umfassend zu beschreiben [Cleff 2015, 9]. Die Komplexität der betrieblichen Realität verbietet deren Erfassung in allen Einzelheiten [Cleff 2015, 9].

Die Prozesssteuerung mit der Hilfe von Kennzahlen dient bereits der Komplexitätsreduktion für das Management. Bei der Analyse von Ursache-Wirkbeziehungen zwischen jenen Kennzahlen ist in erster Linie zu beantworten, ob und wie diese Kennzahlen miteinander interagieren. Warum bestimmte Relationen existieren, ist bei Bedarf anschließend im Einzelfall durch Detailanalysen zu klären.

Im vorangegangenen Kapitel wurde der Begriff „Black Box“ im Zusammenhang mit Intransparenz erwähnt. Der bewusste Einsatz einer Black Box-Logik kann allerdings dabei helfen, einen Mittelweg zwischen zu detaillierten Modellierungen und zu starken, irreführenden Vereinfachungen zu finden [Beer 1959, 70]. So behandeln viele Unternehmen Managemententscheidungen als Black Box [Rezgui 2018, 44]. Auch der Einsatz von Analytics-Algorithmen stellt dies in gewisser Weise dar, indem datenbasiert Modelle gelernt werden, die die Ursache-Wirkbeziehungen zwischen Kennzahlen widerspiegeln, ohne die physischen Kausalbeziehungen im Detail abzubilden. Für die initiale Modellierung der Kennzahlen eignen sich Modelle zur Input-Manipulation und Output-Bestimmung [Beer 1959, 52] verbunden durch das Element einer Prozess-Black Box in Form von Analysemodellen. Die Idee ist ähnlich dem Design of Experiments, bei welchem funktionale Systemzusammenhänge durch die gezielte Manipulation von Einflussgrößen und die Erfassung der erzielten Wirkung mathematisch beschrieben werden, ohne die exakte Wirkkette im System zu verfolgen. Der entscheidende Unterschied im Rahmen der Digitalen Unternehmenssteuerung ist, dass die Analyse der Kennzahlendaten die Grundlage für die Beschreibung der Systemzusammenhänge darstellt und nicht manuelle Eingriffe, sodass anschließend Eingaben zur Prädiktion gemacht werden können.

3.7 Zusammenfassung: Leitmerkmale für die Analyse von Kennzahlenrelationen in der Unternehmenssteuerung

Teilforschungsfrage 2: Wie können Kennzahlenrelationen zur Entscheidungsunterstützung in der Unternehmenssteuerung analysiert werden?

Eine wichtige Grundvoraussetzung für die Unterstützung von Managemententscheidungen ist, dass den Entscheidungsträgern schnelle, aktuelle und relevante Informationen zur Verfügung stehen. Angesichts der Flut an Informationen und Daten, die kontinuierlich erzeugt werden, wird dabei immer wichtiger, dass es für die jeweilige Aufgabe die richtigen und notwendigen Informationen in der richtigen Menge sind. Dies können Advanced Analytics-Algorithmen unterstützen. Die Analysefähigkeiten von fortgeschrittenen Analysemethoden unterteilen sich in deskriptiv/diagnostisch, prädiktiv und präskriptiv. In der Praxis sind vor allem deskriptive und diagnostische Funktionsumfänge im Einsatz. Insbesondere nach prädiktiven Analysefunktionen besteht jedoch zunehmend großer Bedarf. Wissenschaftlich stehen ebenfalls überwiegend deskriptive/diagnostische und prädiktive Ansätze im Kontext der Kennzahlenanalyse im Fokus.

Die Visualisierung oder Prognose singulärer Informationen nutzt die technischen Möglichkeiten nicht aus, sodass Potentiale ungenutzt bleiben. Insbesondere für die Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen müssen Informationen in Beziehung gesetzt werden, um neue Einblicke zu erlangen. Das Erkenntnisziel ist, unter Einbeziehung von Kennzahlen jeglicher Art, die Vernetztheit und Komplexität des realen Prozessbetriebes zu erfassen und dessen Steuerung zu optimieren. Dies geschieht in der unternehmerischen Praxis in der Regel qualitativ auf Basis impliziten Wissens, verlangt hohen Ressourceneinsatz und erzeugt Abhängigkeiten von einzelnen Wissensträgern.

Auch wenn in solchen Fällen eine Mehrzahl an Kennzahlen in Beziehung zueinander gesetzt wird, ist es für die Umsetzung der Digitalen Unternehmenssteuerung nicht ausreichend, einzelne Prozesse zu analysieren. Ursache-Wirkbeziehungen sollten **prozess- und hierarchieübergreifend** transparent sein. Entscheidend ist nicht die Abbildung künstlich erzeugter Kennzahlensysteme, sondern die explorative Erfassung tatsächlich erfolgter Interaktionen zwischen den Prozesskennzahlen. Angesichts der enormen Menge und Vielfalt an Interdependenzen ist die qualitative Erfassung aufgrund kognitiver Einschränkungen für den Menschen jedoch kaum umsetzbar. „In der Produktion können Lösungen Abhilfe schaffen, die Daten über Fertigungslinien, Werke und Standorte hinweg reichen [sic!] und diese mit betriebswirtschaftlichen Daten anreichern.“ [Gluchowski/Chamoni 2015, 298] Die quantitativen Analysemethoden können dabei unterstützen, Erkenntnisse über das Verhalten von Prozesssystemen zu gewinnen und eine integrierte Sicht auf eine Vielzahl an Zusammenhängen erzeugen. Dabei geht es nicht notwendigerweise darum, bisher unbekannte Optima zu identifizieren, sondern dem Management auf eine pragmatische Art und Weise zu besseren Entscheidungen zu verhelfen (vgl. [Simon 1965, 31]). Quantitative Analysemethoden, die nicht nach Optima, sondern nach Lösungen, die „gut genug“ sind, suchen, nennt man heuristische Methoden [Simon 1965, 33]. Darauf aufbauende, bereichsübergreifende Analytics-Prozesse zur Beherrschung hochgradiger Interdisziplinarität sind allerdings noch nicht bekannt [Heimes et al. 2019, 60].

IT-basierte Lösungen werden komplexer, leistungsfähiger und halten zunehmend Einzug in viele Unternehmensbereiche. Gleichzeitig haben die Entscheidungsträger gerade im Bereich der Kennzahlensteuerung eine hohe Verantwortung und Fehlentscheidungen ziehen mitunter schwerwiegende Konsequenzen nach sich. Daher besteht die Nachfrage nach Selbständigkeit, was die Durchführung von Analysen unter Anwendung der Software angeht. Während fortgeschrittene Analysen bisher üblicherweise durch Spezialisten durchgeführt wurden, streben Führungskräfte und Fachanwender nach Unabhängigkeit. Dies betrifft das einfache Einfügen von Daten sowie deren **anwenderfreundliche Analyse**. Anwender, die funktional geschlossene Systeme mehreren Teillösungen vorziehen, sollten ohne die Notwendigkeit größerer IT-Kenntnisse oder Schulungen durch die notwendigen Schritte geführt und durch verständliche Visualisierungen unterstützt werden.

Aufgrund der angesprochenen Kritikalität der Entscheidungen, die im Kennzahlenumfeld zu treffen sind, ist **Vertrauen** in die angebotenen Lösungen besonders wichtig[20]. Daher sollten die erzeugten Ergebnisse für interessierte Fachanwender bestmöglich interpretierbar sein, um einen breiten Anwenderkreis anzusprechen. Dies betrifft insbesondere prädiktive Funktionalitäten, die für diese Nutzergruppe üblicherweise neues Terrain darstellen.

Ebenfalls von zentraler Bedeutung für die Verbreitung einer solchen Software ist deren **Wirtschaftlichkeit**. Generische Parametrisierungen von Analysemethoden sollen diese auf verschiedene Anwendungsfälle übertragbar und skalierbar machen und Aktualisierungen der Modelle auf Grundlage neuer Datensätze ermöglichen. In der wissenschaftlichen Literatur liegt jedoch häufig ein besonderes Augenmerk auf der Lösung sehr spezifischer einzelner Fragestellungen (vor allem im prädiktiven Umfeld) und weniger auf der generischen Einsetzbarkeit von Modellen. Letztere ist jedoch eine Voraussetzung, um explorative Datenanalysen durch Fachanwender zu ermöglichen. Ein wesentlicher Meilenstein in der Digitalen Unternehmenssteuerung ist weniger die höchstmögliche Vorhersagegenauigkeit als eher die Schaffung eines tiefgreifenden Verständnisses des Ursache-Wirkgefüges von Systemen. Angesichts dessen entstehen Spannungsfelder, für die es geeignete Kompromisse zu finden gilt: Erstens sollten Erkenntnisse nicht durch zu viele oder zu wenige Informationen blockiert werden. Zweitens sollten Lösungen für Fachanwender bei Bedarf methodisch interpretierbar und generisch einsetzbar sein, aber auch eine hinreichend hohe Genauigkeit aufweisen.

Darüber hinaus beinhalten einige Ansätze wiederkehrend prägende subjektive Einflüsse des Anwenders. Dies bedeutet, dass implizites Wissen der Fachexperten über die Ursache-Wirkbeziehungen in die Modellierung einfließen. Dadurch reduziert sich die **Objektivität** der Modelle. Gerade die größtmögliche Objektivität der Datenanalysen durch das Lernen der Beziehungen zwischen den Kennzahlen anhand der Daten ohne die Hinzugabe impliziten Wissens ist jedoch wesentlich für den Erkenntnisgewinn zusätzlich zum impliziten Wissen der Entscheidungsträger. In anderen Fällen werden automatisiert Entscheidungen getroffen, was neben übermäßig komplexen Analysealgorithmen ein weiterer Grund für die unzureichende **Nachvollziehbarkeit** der Ergebnisentstehung für einen Fachanwender ohne fortgeschrittene IT-Kenntnisse ist.

Allerdings liefern die untersuchten Ansätze auch wichtige Ansatzpunkte für die Umsetzung der Digitalen Unternehmenssteuerung, die auf zu entwickelnde Lösungen zu übertragen sind. So bewährt sich der Einsatz **komplementärer Analysemethoden**, um den Erkenntnisgewinn zu steigern. Gleichermaßen ist, insbesondere im prädiktiven Bereich, der automatisierte **komparative Einsatz** mehrerer Methoden im Sinne einer Werkzeugoptimierung sinnvoll. Dabei zeigte sich, dass bereits vergleichsweise einfache lineare Modelle einen hohen Erkenntnisgewinn erzeugen, was die weite Verbreitung linearer multivariater Regressionsmodelle erklärt.

---

[20] „Beteiligten Mitarbeitern muss die Möglichkeit gegeben werden, Vertrauen in die Data-Analytics-Modelle zu entwickeln.“ [Heimes et al. 2019, 60]

Ebenso werden sowohl lineare als auch nichtlineare Korrelationen und Entscheidungsbäume in mehreren Beiträgen eingesetzt. Einen weiteren zu berücksichtigen Aspekt stellt die Aufbereitung der Datenbasis, wie beispielsweise im Falle zeitlicher Latenz der Ursache-Wirkbeziehungen**,** dar.

Im zweiten Kapitel der vorliegenden Arbeit wurden die Herausforderungen, denen sich das Management großer Produktionsunternehmen stellen muss, dargestellt und Anforderungen an die kennzahlenbasierte Unternehmenssteuerung abgeleitet. Darauf aufbauend analysiert das dritte Kapitel den Status Quo der BI sowohl in der Praxis als auch in der wissenschaftlichen Literatur hinsichtlich verfügbarer Methoden für die Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen und leitet wesentliche Leitmerkmale für eine erfolgreiche Implementierung der Digitalen Unternehmenssteuerung her. Die in Kapitel 3.5 erwähnte und durch das Institut für Angewandte Informatik e. V. durchgeführte Studie kam in Übereinstimmung mit der vorliegenden Analyse zu dem Schluss, dass eine Lösung für die beschriebene Problemstellung nicht verfügbar ist. Dies bestätigte ebenfalls ein Vertreter eines Beratungsunternehmens [Interviews 01.02.2017 & 25.07.2018]. Demnach besteht nach bestem Wissen eine Lücke, die methodisch und softwaretechnisch zu schließen ist. Somit ist die Analysephase des in Kapitel 1.4 definierten Forschungsvorgehens abgeschlossen. Sie trägt zu einem umfassenden Verständnis der Anwendung und der Herausforderungen der Gestaltung von Kennzahlensystemen bei (Beantwortung Teilforschungsfrage 1) und verdeutlicht den Status quo betrieblicher Informationssysteme und deren Anwendungsbereiche (Beantwortung der Teilforschungsfrage 2). Somit ist das definierte Erkenntnisziel erfüllt. Daher folgt in der Entwurfsphase im anschließenden Kapitel die Entwicklung einer Methode als Grundlage für die Einführung der Digitalen Unternehmenssteuerung in Produktionsunternehmen.

4 Elemente der Digitalen Unternehmenssteuerung

Zukunftsorientierte Entscheidungen basieren immer auf internen und externen sowie quantitativen und qualitativen Informationen mit Bezug zum Ergebnis [Vasile et al. 2011, 270]. Großen Nutzen stiften dabei Transparenz über unternehmerische Zusammenhänge, eine objektive Entscheidungsbasis und die Integration klassischer Steuerungsinstrumente (z. B. Balanced Score Card, Kennzahlensysteme) [Kieninger et al. 2015, 6]. Dazu sollte eine Auswertung laufend erhobener und erfasster Daten relevanter Prozesse und Bereiche erfolgen [Becker/Winkelmann 2014, 59]. Insbesondere Produktions- und Logistikbereiche sind dafür geeignet, da in diesen relativ große Datenmengen wie Durchlaufzeiten oder Mengeninformationen anfallen [Becker/Winkelmann 2014, 59]. Die Daten- und Kennzahlenauswertungen sollen mit dem Ziel einer integrierten Unternehmenssteuerung Entscheidungsträger befähigen, einen unternehmensweiten Ansatz zu nutzen [Diekmann/Sümmchen 2016, 29]. Indem Analysen Wahrscheinlichkeiten bestimmter Ergebnisse aufzeigen, welche Fachbereiche zur Steuerung und für ihre Entscheidungen nutzen, geht der Einfluss reiner Expertenschätzungen drastisch zurück [Kieninger et al. 2015, 7 f.]. Der entscheidende Vorteil neuer digitaler Steuerungsinstrumente entsteht allerdings erst durch Expertenwissen, Methodenkompetenz und interdisziplinäre Zusammenarbeit bei der Interpretation der Ergebnisse [Kieninger et al. 2015, 8]. In der Wirtschaftsinformatik hat das Methoden Engineering in Situationen eines solchen (zunehmenden) Ausmaßes an Komplexität der betrieblichen Realität einen hohen Stellenwert für die die Realität abbildenden Informationssysteme [Gutzwiller 1994, 11].

4.1 Methoden Engineering

Im Methoden Engineering erfolgt der ingenieurmäßige Entwurf von Informationssystemen für die Erzeugung von Entwurfsmethoden [Gutzwiller 1994, 11]. [Gutzwiller 1994, 13] beschreibt den Zusammenhang zwischen fünf allgemeingültigen Elementen zur Beschreibung jener Entwurfsmethoden nach [Heym/Österle 1992a a; Heym/Österle 1992b b]. [Alt 2008, 128] greift diesen Beitrag auf und ergänzt in Anlehnung an [Odell 1996] mit dem Tool ein weiteres Element inklusive der entsprechenden Beschreibung der Zusammenhänge. Die Elemente sind folgendermaßen charakterisiert:

- Das erste Element, eine (Entwurfs-) **Aktivität**, ist eine Verrichtungseinheit mit dem Ziel, ein oder mehrere definierte Ergebnisse zu erzeugen und kann in mehrere Subaktivitäten zerlegt und in eine Ablauffolge gebracht werden. Werden Aktivitäten-Ablauffolgen in ihrer Gesamtheit betrachtet, spricht man von einem Vorgehensmodell.
- Personen in bestimmten **Rollen** nehmen die Aktivitäten wahr. Die Rollen beziehen sich auf die Sicht des Aufgabenträgers (z. B. Projektleiter, Analytiker) und richten sich beispielsweise nach zu treffenden Entscheidungen sowie zur Ergebniserstellung notwendige Fachkenntnisse.
- **Entwurfsergebnisse** entstehen durch die Verwendung anderer Ergebnisse als Input für Entwurfsaktivitäten und sind in ihre Bestandteile zerlegbar.
- Ein **Metamodell** stellt die Bestandteile der Entwurfsergebnisse übersichtlich dar. Es besteht aus Entitätstypen, Attributen und Beziehungen. Metamodell-Komponenten sind beispielsweise Organisationseinheiten.
- **Techniken** beschreiben detailliert, wie Entwurfsergebnisse erzeugt werden können, indem das Vorgehen gemäß der Aktivitäten durchlaufen wird.
- **Tools** dienen der elektronischen Unterstützung bei der Anwendung der Techniken.

Abb. 4-1 stellt die angesprochenen Zusammenhänge zwischen den Elementen nach [Alt 2008, 128; Gutzwiller 1994, 12–14] dar. Diese Konzepte der Methodenbeschreibung sind die Grundlage für die zu entwickelnde Methode für die Umsetzung der Digitalen Unternehmenssteuerung.

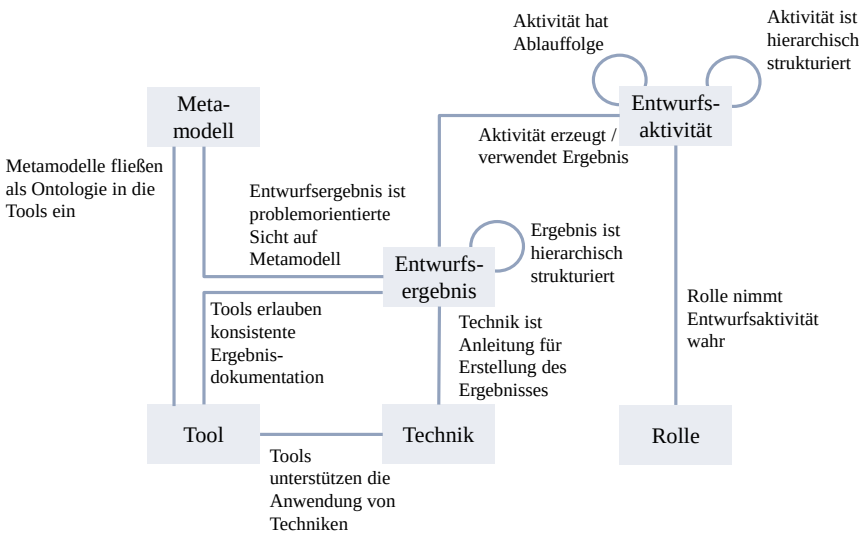

Abb. 4-1: Elemente des Methoden Engineering [Alt 2008, 128; Gutzwiller 1994, 13]

4.2 Aktivitäten

Die Analyse betriebswirtschaftlicher Daten beschränkt sich nicht auf die bloße Anwendung von Analysealgorithmen [Knobloch/Weidner 2013, 20]. Vielmehr stellt die eigentliche Untersuchung der Daten den geringsten Aufwand innerhalb eines Analyseprojektes dar [Knobloch/Weidner 2013, 20]. [Piatetsky-Shapiro et al. 1996, 90] schätzen die Aufwendungen für Aktivitäten wie die Datenextraktion, -modellierung, -bereinigung etc. auf 75 bis 85 %. Um die Tätigkeiten zu strukturieren und effizienter zu gestalten, wurden generische Modelle für Datenanalysen erzeugt. [Cios et al. 2007, 17 f.] stellen mehrere solcher Modelle, inklusive des weit verbreiteten CRISP-DM und des Knowledge Discovery in Databases Process, gegenüber. Dabei zeigt sich, dass die vorgeschlagenen Schritte relativ ähnlich sind und zu einem iterativen Vorgehen geraten wird. Allerdings sind die Modelle nicht feingranular genug, um einen Fachanwender ohne fortgeschrittene Kenntnisse im Bereich der Datenanalyse in dem Anwendungsfall der Kennzahlenanalyse zu führen. Dazu ist eine detailliertere Darstellung der zu durchlaufenden Aktivitäten vonnöten, die die komplexen Fragestellungen auf einzelne, handhabbare Aspekte herunterbrechen, an denen sich die Anwender orientieren und sie schrittweise bearbeiten.

In Kapitel 4.1 wurde die gesamtheitliche Betrachtung der Ablauffolgen von Aktivitäten als Vorgehensmodell bezeichnet. [Alt 2008, 127] ergänzt, dass Vorgehensmodelle in der Regel allgemeingültig definiert sind und die durchzuführenden Aktivitäten mit den dabei zu erarbeitenden Inhalten festlegen. Sie liefern ein systematisches Umsetzungsinstrumentarium [Alt 2008, 127] und stiften auf unterschiedliche Weise Nutzen:

- Dokumentation bewährter Schritte bei dem Entwurf und der Umsetzung von Architekturen und Fehlervermeidung sowie Ergebnisdokumentation [Alt 2008, 127].
- Unterstützung bei der Einarbeitung neuer Projektmitarbeiter [Alt 2008, 127].
- Verringerung der Komplexität von IT-Projekten durch die Zerlegung in überschaubare, zeitlich aufeinander folgende Teilaufgaben [Breitner 2012].
- Berücksichtigung sämtlicher Gestaltungsaspekte und Stakeholder [Alt 2008, 127].
- Effizienzsteigerung des Entwicklungsprozesses durch reduzierte Entwicklungszeiten und -kosten [Alt 2008, 127].

Das in Abb. 4-2 dargestellte Vorgehensmodell detailliert die Schritte der genannten Datenanalysemodelle auf der Grundlage der Durchführung zahlreicher Datenanalysen in der betrieblichen Praxis und führt Fachanwender durch die für die Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen zu tätigenden Aktivitäten. [Cleff 2015, 5] definiert analog zu Dresner (siehe Kapitel 3.1) drei Schritte der Wissensgenerierung: Als Ausgangslage dienen Daten, deren Analyse zu Informationen

und deren Interpretation wiederum zu Wissen führen. Diese Schritte bilden die Ergebnisse der einzelnen Phasen des Vorgehensmodells. Die Phasen sind die Initialisierung, welche alle vorbereitenden Tätigkeiten vor der Anwendung der Analysealgorithmen einschließt, die Analyse, in welcher jene Algorithmen Anwendung finden, und die Realisierung, wo aus den erzeugten Informationen Wissen generiert wird. Allerdings sind die Schritte der Wissensgenerierung nicht trennscharf aufteilbar, sondern dienen der Orientierung. Dies verdeutlicht [Alt 2018, 399], der die Verfügbarkeit von Daten und Informationen als technologische Digitalisierung bezeichnet und als Grundlage der Digitalisierung betrachtet. Die anschließende angewandte Digitalisierung betrifft hingegen die individuen-, organisations- sowie gesellschaftsspezifische Kontextualisierung dessen [Alt 2018, 399].

Die Umrandung der Phasen weist darauf hin, ob die Phase überwiegend qualitativer (grau-blau) oder quantitativer (hellblau) Natur ist. Jede der Phasen besteht aus der Ablauffolge von drei bis fünf Aktivitäten, von denen jede einen zu erarbeitenden Inhalt definiert (siehe dazu [Alt 2008, 127]). Die Phasen und Aktivitäten sind iterativ zu durchlaufen, wobei nicht zwingend jede Aktivität für jede Analyse notwendig ist. Je nach Anwendungsfall ist eine bedarfsgerechte Auswahl zu treffen. Um fortlaufend Erkenntnisse über die vergangenen wie auch kommenden Geschäftsaktivitäten für die weiteren Planungen zu erhalten, sind die Analysen in regelmäßigen, zu definierenden Zeitintervallen durchzuführen. Somit erfolgen eine langfristige, kontinuierliche Einbindung von Datenanalysen und die Überführung der gewonnenen Erkenntnisse in die betriebliche Praxis.

Bei der Anwendung des Modells können einerseits im Vorhinein bestehende Hypothesen geprüft oder aber Daten explorativ analysiert werden. Beispielsweise vermuten die Meister in der Montage des Automobilherstellers, dass sich die technische Verfügbarkeit von Anlagen verschlechtert, wenn die Hallentemperatur zu hoch steigt. Das Vorgehensmodell leitet durch die notwendigen Schritte, um quantitativ zu prüfen, inwiefern sich letztere auf die relevanten Prozesskennzahlen einschließlich der Anlagenverfügbarkeit auswirken. Somit erfolgt quantitativ eine Verifizierung oder Falsifizierung der Hypothese. Im Rahmen explorativer Analysen entstehen häufiger Fragen als abschließende Antworten, welche ihrerseits für das Nachvollziehen der Geschäftstätigkeit und die Verbesserung zukünftiger Handlungen gleichermaßen zu untersuchen sind [Felden 2016]. Jede dieser Analysen beginnt mit der Initialisierung als erste Phase.

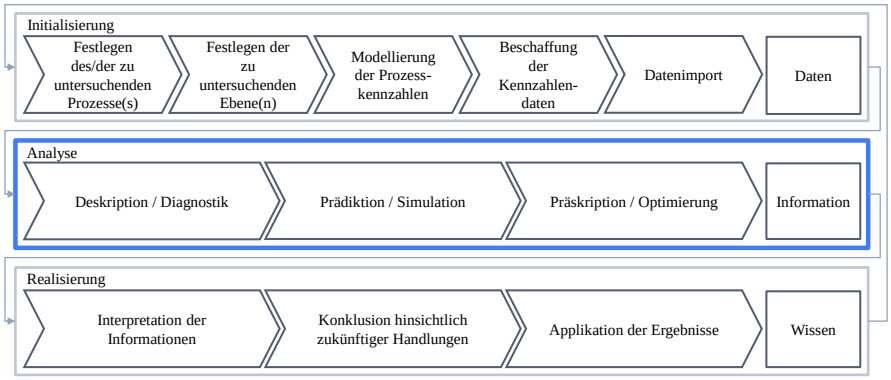

Abb. 4-2: Vorgehensmodell für die Digitale Unternehmenssteuerung

4.2.1 Initialisierung

Die Initialisierungsphase des Vorgehensmodells für die Digitale Unternehmenssteuerung untergliedert sich in fünf Aktivitäten, nach deren Durchführung die für die Analyse notwendige Datengrundlage zur Verfügung steht:

4.2.1.1 Festlegen des/der zu untersuchenden Prozesse(s)

Zur Entscheidungsunterstützung ist es die Aufgabe des Controllings, relevante Daten zu ermitteln und zu Informationen zu verarbeiten [Becker/Winkelmann 2014, 55]. "Dabei muss die Informationsbedarfsmodellierung ebenso wie die Geschäftsprozessmodellierung den Anforderungen in Bezug auf Kosten und Qualität in Form einer Kosten-Nutzen-Relation gerecht werden". [Becker/Winkelmann 2014, 55] Angesichts dynamischer Marktveränderungen, Unternehmensumstrukturierungen und kürzerer Produktzyklen sind diese Modellierungen kontinuierlich neu zusammenzustellen, um für aktuelle Entscheidungsaufgaben relevant zu sein [Schön 2018, 9]. Dies erzeugt maßgeblichen Aufwand für Unternehmen und erfordert immer wieder die Beantwortung der Frage, welche Daten für das Treffen fundierter Entscheidungen relevant sind und nicht zu viel oder zu wenig Informationen beinhalten. Die Gefahr von zu vielen Informationen ist beispielsweise eine gesteigerte Wahrscheinlichkeit zufälliger Parallelen, sodass Zusammenhänge interpretiert werden, die in der Realität nicht vorliegen. Eine viel zitierte Regel ist Occam´s Razor, die besagt, dass nicht mehr erklärende Variablen als nötig für die Beschreibung eines Sachverhaltes genutzt werden sollten und dass das einfachste sinnhafte Modell zu nutzen ist.

Die Auswahl ist zusammen mit Fachanwendern zu treffen, um die richtigen Daten zu bestimmen. Dies gestaltet sich jedoch schwierig, wenn keine methodische Unterstützung zur Verfügung steht, um die Kennzahlen in einen Kontext zu setzen,

ohne jedoch übermäßig viel implizites Wissen einfließen zu lassen und somit die Objektivität der Datenanalyse zu reduzieren. Tatsächlich wählen Anwender die Variablen in Analyseprojekten häufig nach Versuch und Irrtum durch das Streichen oder Hinzunehmen von Variablen abhängig von den ermittelten (Zwischen-) Ergebnissen aus [Ng/Soo 2018, 5]. Um die Effizienz dieses Vorgehens zu steigern helfen bei der Entscheidung, was wichtig und was weniger wichtig ist, Modelle, indem sie Rahmen schaffen, die Beziehungen abbilden und in Situationen mit hoher Unsicherheit und Mehrdeutigkeit eine zügige Orientierung ermöglichen [Rüegg-Stürm 2014, 3].

Da eine prozessorientierte Unternehmenssteuerung wesentliche Vorteile mit sich bringt (siehe Kapitel 2), ist die Prozesslogik weit verbreitet und demnach vielen potentiellen Anwendern vertraut. (Prozess-) Modelle sind (vereinfachte) Abbilder von Wirklichkeiten [Schwaninger 2004, 9] und eignen sich als Orientierung mit einer geringen Einstiegshürde. Sie leiten Anwender dazu an, Anfang und Ende eines Prozesses zu definieren und somit den Fokus der Analyse festzulegen. Gleichermaßen erlauben Sie, dem in Kapitel 3.6 erläuterten Gedanken der Input-Manipulation und Output-Bestimmung[21] zu folgen.

Allerdings ist im Falle einer Soll-Ist-Abweichung der Unternehmensleistung das Lernen aus vermeidbaren Fehlern nur dann möglich, wenn beeinflussbare (kontrollierbare) und nicht beeinflussbare (nicht kontrollierbare) Einflussgrößen unterscheidbar sind [Gladen 2014, 270]. Daher ist eine detailliertere Betrachtung über die Input- und Outputgrößen hinaus vonnöten. [Astatkie 2013, 68] nutzt in seinem Prozessmodell eben diese vier Größen: Input-, Output-, kontrollierbare und unkontrollierbare Faktoren. [Schumacher/Maurer 2014, 3] unterteilen in kontrollierte Einwirkungen, Stellgrößen, Nebeneffekte auf die Umgebung, unkontrollierte Einwirkungen und Störungen, umweltbedingte Änderungen dynamischer Eigenschaften und technisch relevante, messbare Ausgangsgrößen. In Anlehnung an das Regelkreisprinzip modelliert [Schwaninger 2004, 12] Prozesse mit Input-, Output-, Lenkungs- und Störgrößen und bezieht Mechanismen wie Rückkoppelungen von Informationen ein. Demgegenüber ist das Prozessmodell von [Ropers 2013, 13] einfacher gehalten und beinhaltet Input- und Störgrößen sowie Prozessziele.

Um Prozesse so einfach wie möglich zu repräsentieren und den Anwender trotzdem anzuleiten, das richtige Maß der Menge an Informationen zu finden, verbindet das Prozessmodell in Abb. 4-3 Eigenschaften aller dieser Beiträge. Es beinhaltet vier Arten von Größen: Eine Inputgröße ist eine Kennzahl, die misst, inwiefern für den betrachteten Prozess notwendige Voraussetzungen erfüllt sind, sodass dieser wie geplant durchgeführt werden kann (z. B. Qualität des Outputs des vorgelagerten Prozesses). Outputgrößen sind Kennzahlen, die darstellen, inwiefern durch Steuerungsmaßnahmen innerhalb des betrachteten Prozesses die Ziele, anhand derer ihr Erfolg gemessen wird, erreicht werden (z.B. Termintreue). Steuergrößen repräsentieren direkte Steuermöglichkeiten für die Verantwortlichen des betrachteten Prozesses zur Erreichung der Zielvorgaben in Form von Kennzahlen (z. B. Einsatz von

[21] [Hammer/Hershman 2010, 76] nutzen die Terminologie „Drivers“ und „Outcomes“.

Personal). Eine Störgröße ist eine Kennzahl, welche durch die Verantwortlichen des betrachteten Prozesses nur indirekt oder gar nicht beeinflussbar ist und sich negativ auf die Erreichung der Zielvorgaben auswirkt (z. B. Anlagenverfügbarkeit). Die Orientierung an diesen Klassifizierungen bei der Modellierung von Prozessen trägt zur Lösung eines der in Kapitel 3.7 genannten Spannungsfelder, dass Erkenntnisse nicht durch zu viele oder zu wenige Informationen blockiert werden sollten, bei. Somit stellt dieses Modell die fachliche Ausgangsbasis für die Datenanalyse dar und bereitet den Weg zur Anwendung digitaler Werkzeuge für die Unternehmenssteuerung.

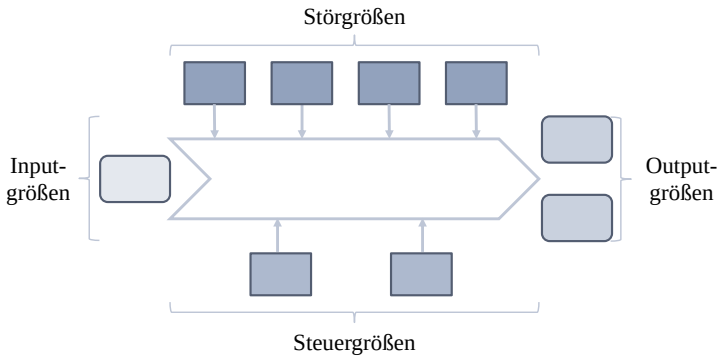

Abb. 4-3: Prozessmodell der Digitalen Unternehmenssteuerung (in Anl. an [Schwaninger 2004, 12])

Bei der Anwendung des Modells ist zu berücksichtigen, dass die Klassifizierung derselben Kennzahl abhängig von der Prozessperspektive unterschiedlich sein kann. So ist beispielsweise die Anlagenverfügbarkeit für einen Meister in der Montage eine Störgröße, während sie für die Verantwortlichen der Instandhaltung eine Outputgröße darstellen. In einem anderen Fall stellt der Output eines vorgelagerten Prozesses den Input des nachgelagerten Prozesses dar. Dies verdeutlicht einen wesentlichen Vorteil dieser Prozessmodellierung: Sie ist auf unterschiedliche Szenarien (z. B. Montageprozesse, Logistikprozesse, Personalprozesse) und unterschiedliche Perspektiven generisch anwendbar und somit effizient. Zu letzterem tragen auch die leichte Verständlichkeit und Anpassbarkeit des Modells bei. Zudem kann der Anwender analog zu Systemen (siehe Kapitel 2.1), die Teil von Supersystemen sein und aus Subsystemen bestehen können, Prozesse als Teile von Superprozessen und aus Subprozessen bestehend darstellen. So sind einerseits z. B. die einzelnen Meisterbereiche der Montage eher feingranular oder die gesamte Montage grobgranular mit derselben Logik modellierbar[22]. Darüber hinaus können Prozesse kennzahlenbasiert miteinander verglichen oder zueinander in Beziehung gesetzt werden.

[22] „Just as it is always possible to expand the system to a scope of wider perspective, it is also possible to cut down the system to a smaller version.“ [Beer 1959, 9]

4.2.1.2 Festlegen der zu untersuchenden Ebene(n)

Um effektiv zu sein, müssen Strategien die Komplexität der gesamten Situation betrachten, anstatt nur Lösungen für einzelne Probleme zu erzeugen [Druckenmiller/Acar 2009, 226]. Schließlich beeinflussen sich die Prozesse in prozessorientiert organisierten Unternehmen untereinander. Die Interessen übergeordneter Prozesse sind zum Beispiel von den untergeordneten Prozessen nicht losgelöst [Schwaninger 2001, 144], da die Zielvorgaben von Hierarchieebene zu Hierarchieebene heruntergebrochen werden, sodass die Zielerreichung übergeordneter Ebenen von denen untergeordneter Ebenen abhängt [Berrah/Foulloy 2013, 652]. Je nach Anwendungsfall kann demnach die Managementaufgabe darin bestehen, die Ursache-Wirkbeziehungen innerhalb einzelner Prozesse zu betrachten oder die Interdependenzen mehrerer Prozesse untereinander zu untersuchen. Jedes der Prozessmodelle repräsentiert dabei eine Organisationseinheit, die mit einer anderen interagiert. Die Ebenen in den Abb. 4-4, Abb. 4-5, Abb. 4-6 und Abb. 4-7 stellen übersichtlich dar, wie diese in Beziehung stehen, wobei die eingezeichneten Kanten nur der beispielhaften Illustration dienen und in Abhängigkeit der tatsächlich untersuchten Prozesse variieren. Welche Ebenen tatsächlich zu untersuchen sind, hängt von dem jeweiligen Anwendungsfall ab und ist durch den Anwender situativ zu entscheiden.

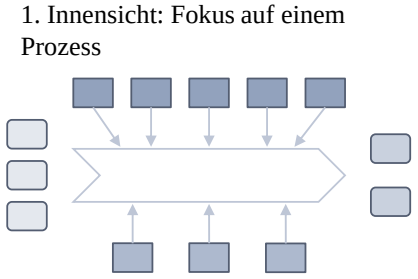

Abb. 4-4: Ebenenmodell Digitale Unternehmenssteuerung (Ebene 1)

Eine Analyse gemäß der ersten Ebene setzt den Fokus auf die Innensicht, also einen Einblick in einen einzelnen Prozess (Abb. 4-4). Der Prozess kann dabei grob- oder feingranular modelliert sein und wird insofern untersucht, dass die Ursache-Wirkbeziehungen zwischen den Input-, Output-, Stör- und Steuergrößen betrachtet werden. Zum Beispiel könnte man prüfen, ob gemäß dem Controllability Prinzip Kompetenz und Verantwortung für den Entscheidungsträger kongruent sind [Gladen 2014, 183]. Dies bedeutet, dass Zielgrößen einem Bereich nur dann zurechenbar sind, wenn diese innerhalb der Organisationseinheit auch wirklich beeinflussbar sind [Gladen 2014, 183]. In der Praxis zeigt sich häufig, dass strategische Kennzahlen auf mehrere Hierarchieebenen heruntergebrochen und mit Zielvorgaben versehen werden, diese in letzter Instanz aber nicht durch den jeweiligen Bereich steuerbar sind. Daher ist dort die Kongruenz zwischen Kompetenz und Verantwortung

verletzt und diese Zielvorgabe für den Teilprozess ungeeignet. Die Analyse der Daten des zuvor erläuterten Beispiels, bei welchem Fahrzeuge auf Fehler vorangegangener Prozesse zu prüfen und diese zu beseitigen sind, würde zeigen, dass die Outputgröße Nacharbeitsminuten mit den Steuergrößen, welche der Prozessverantwortliche zur Verfügung hat, nicht kontrollierbar ist.

2. Vorgänger- /-Nachfolgeprozess: Fokus auf Inputgebern für den eigenen Prozess und Outputnehmern dessen

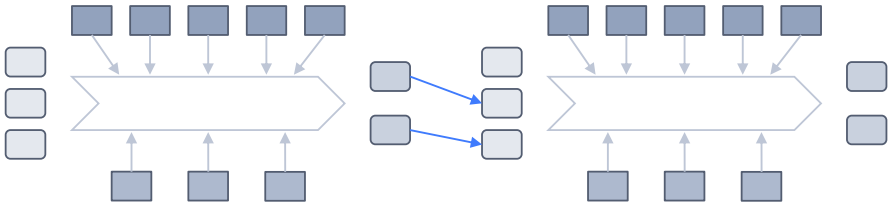

Abb. 4-5: Ebenenmodell Digitale Unternehmenssteuerung (Ebene 2)

Kapitel 2.2 legt unter anderem dar, dass die Ausrichtung ebenso wie die Beurteilung von Prozessleistungen und Aufgaben auf allen Hierarchieebenen an den Anforderungen interner oder externer Kunden auszurichten ist, sodass sie sowohl den Start- als auch den Endpunkt der Prozesse bilden. Daher dient die zweite Ebene der Analyse den Ursache-Wirkbeziehungen zwischen Vorgänger- und Nachfolgerprozessen (Abb. 4-5). Beispielhafte Anwendungsfälle sind erstens die Überprüfung, ob die Zielerreichung eines vorgelagerten Prozesses den Inputbedarf des nachgelagerten Prozesses erfüllt, sodass letzterer seinen Beitrag zum Unternehmenserfolg leisten kann oder die Zielvorgaben den Entscheidungsträger möglicherweise in eine falsche Richtung lenken. Ein zweiter Anwendungsfall ist das zuvor erläuterte Nacharbeitsszenario. Die Analyse der Kennzahlendaten der sequentiellen Prozesse würde belegen, dass der Output eines vorgelagerten Prozesses die Nacharbeitsminuten des nachgelagerten Prozesses verursacht. Somit entsteht Transparenz über die realen Ursache-Wirkbeziehungen und eine Verbindung sämtlicher Prozessteile, sodass gemäß des kybernetischen Regelkreisprinzips eine Versorgung mit Feedback- und Feedforward-Informationen erfolgt [Alt 2008, 138].

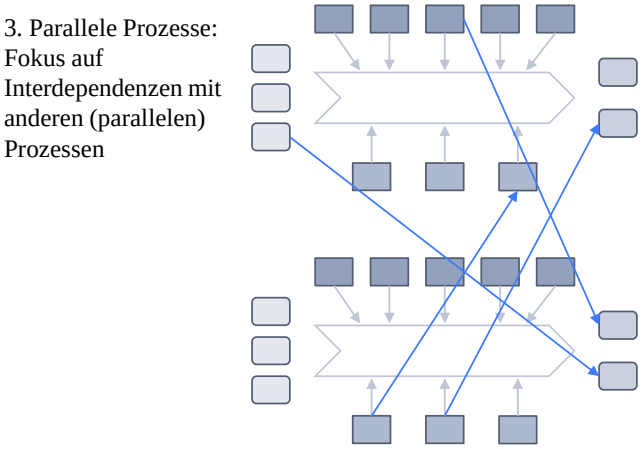

Abb. 4-6: Ebenenmodell für die Digitale Unternehmenssteuerung (Ebene 3)

Obwohl Kennzahlen unterschiedlichen Unternehmensbereichen zugeteilt sind, sind diese aufgrund systeminterner Interdependenzen häufig korreliert [Cai et al. 2009, 514]. So können in Prozessen Probleme entstehen, ohne dass die eigentliche Ursache deutlich ist [Hammer/Hershman 2010, 80; Sterman 2001, 8]. Maßnahmen zur Behebung der Probleme können also nicht greifen, da die Wirkung an Stelle der Ursache bekämpft wird, weshalb die tatsächliche Ursache zu isolieren und diesbezüglich Maßnahmen abzuleiten sind [Hammer/Hershman 2010, 80]. Zu diesem Zweck ermöglicht die Verknüpfung und Analyse der Kennzahlendaten von Parallelprozessen gemäß Ebene 3 zu prüfen, wie sich Veränderungen in dem einen Prozess auf einen parallel stattfindenden Prozess auswirken.

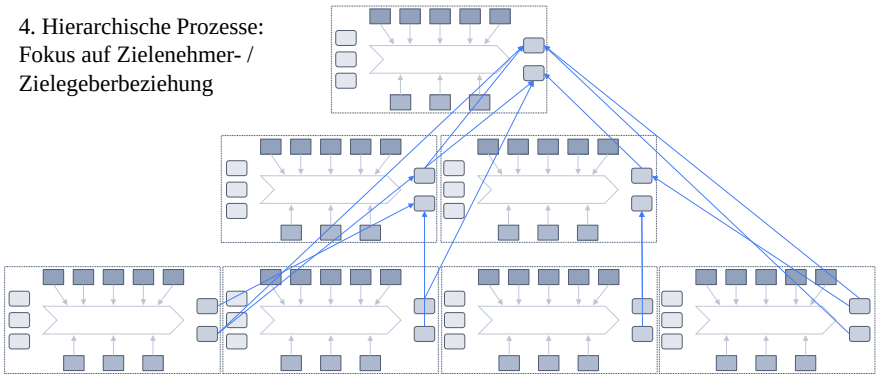

Abb. 4-7: Ebenenmodell für die Digitale Unternehmenssteuerung (Ebene 4)

In der Praxis im Einsatz befindliche Software-Lösungen verbinden in der Regel Planungs- und Steuerungsinstrumente nicht von der strategischen bis zur operativen Planung, weshalb das Reporting nicht stringent ist [Schön 2018, 26 f.]. Mögliche Ursachen sind mangelnder Umsetzungswille sowie eine unzureichende Verfügbarkeit von (IT-) Werkzeugen. Nichtsdestotrotz sind strategische, taktische und operative Aufgaben konzern- und weltweit miteinander zu verzahnen [Schön 2018, 9]. Daher ist zu prüfen, inwiefern die Erreichung der Ziele von Subprozessen die Erreichung der Ziele von Superprozessen herbeiführt. Die Analyse gemäß der vierten Ebene unterstützt die Überprüfung der Wirksamkeit der verwendeten Kennzahlen im Hierarchiegefüge und somit die Eignung des verwendeten Kennzahlensystems. Eine derartige Herangehensweise hilft ferner, Software-Lösungen gezielter zur Schließung der analytischen Lücke zwischen operativer und strategischer Planung einzusetzen.

Es sei jedoch darauf hingewiesen, dass in Ordnungssystemen mit Ursache-Wirkbeziehungen nicht zwangsläufig auch eine Hierarchie von Kennzahlen mit nach oben zunehmendem Verdichtungsgrad vorliegen muss [Gladen 2014, 101]. Bei der Entscheidung, welche Ebenen zu untersuchen sind, sind demnach ebenfalls die Charakteristika des jeweiligen Unternehmens zu berücksichtigen. Des Weiteren setzt diese Vorgehensweise voraus, dass bereits ein Kennzahlensystem und eine entsprechende Datenbasis existieren, sodass die Wirksamkeit des Kennzahlensystems überprüfbar und Schwächen identifizierbar sind[23]. Da das Management unterschiedlicher Hierarchieebenen unterschiedliche Informationsbedarfe hat, hilft eine derartige Betrachtung auch bei der Auswahl der richtigen zu berichtenden Kennzahlen. Dies unterstützt bei der Lösung des in Kapitel 3.2 angesprochenen Problems zu vieler Informationen, ohne richtig informiert zu sein.

Die Ebenenmodelle sollen die Strukturierung der Datenanalyse unterstützen. Gemäß welcher Ebene die Kennzahlen zu analysieren sind, hängt von dem jeweiligen Anwendungsfall ab. Dabei sind die Ebenen bedarfsgerecht zu erfassen, ohne dass dies einer Sequenz bedarf: So setzt eine Analyse sequenzieller Abhängigkeiten gemäß Ebene 2 nicht eine vorhergehende Analyse einzelner Prozesse gemäß Ebene 1 voraus. Nachdem einer oder mehrere Prozesse für eine Analyse definiert und die gewünschte Analyseebene ausgewählt wurden, erfolgt die Modellierung der Prozesskennzahlen.

[23] Die initiale Erstellung von Kennzahlensystemen ohne Kennzahlendaten ist nicht Gegenstand dieser Dissertation.

4.2.1.3 Modellierung der Prozesskennzahlen

Komplementär zu kodifizierbarem Wissen existiert in den Köpfen von Fachanwendern Wissen, welches aufgrund der Komplexität und Unstrukturiertheit nicht oder nur mit hohem Aufwand in elektronischer Form ablegbar ist [Kemper et al. 2010, 144]. Andererseits besitzen Entscheidungsträger häufig eine eingeschränkte Perspektive hinsichtlich der für eine Entscheidung notwendigen Informationen und richten ihre Aufmerksamkeit auf einzelne wenige Kennzahlen [Laney et al. 2012, 8]. Dabei ignorieren sie die Tatsache, dass Informationen Ergebnisse einer Vielzahl an Korrelationen mit anderen Daten sind, deren Berücksichtigung ihre Perspektive erweitern würde [Laney et al. 2012, 8]. Allerdings ist auch hier wieder die Balance zwischen zu vielen Informationen mit teilweise begrenzter Relevanz und zu wenigen Informationen zu finden. Um dies zu unterstützen, ist es sinnvoll, eine innerhalb eines Analyseprojektes konsistente und für alle zu betrachtenden Prozesse anwendbare Systematik für die Modellierung der Prozesskennzahlen zu nutzen. In der Praxis bewährten sich semi-strukturierte Interviews zwischen einem Methodenspezialisten und einem Prozessexperten unter Anwendung eines Leitfadens. Mit dem Ziel der Gewinnung spezifischen Wissens, welches aus anderen Quellen als dem impliziten Wissen von Experten nicht oder nur eingeschränkt ermittelbar ist, stellen leitfadengestützte Interviews stärker strukturierte Befragungen dar [Kaiser 2014, 35]. Sie helfen Fachanwendern ausschließlich Kennzahlen (und keine weiteren Einflussparameter) zu erfassen und gedanklich keine physischen oder organisatorischen Perspektiven einzunehmen.

Vor der Abfrage der Input-, Output-, Stör- und Steuergrößen bieten sich ein bewusstes Abgrenzen des zu untersuchenden Prozesses im Unternehmen und das Herausstellen des konkreten Beitrages für den Unternehmenserfolg an. Anschließend eignet sich die SIPOC-Logik (Supplier, Input, Process, Output, Customer) für die Erfassung vorgelagerter Prozesse und von diesen benötigter Inputs sowie nachgelagerter Prozesse und diesen zur Verfügung gestellter Outputs. Zuletzt sind Einflussmöglichkeiten zur Steuerung des Prozesses sowie störende Einflussgrößen zu erfragen. Auf diese Weise erreicht man mittels eines standardisierten Vorgehens relevante und vergleichbare Ergebnisse basierend auf implizitem Wissen von Experten. Überdies schafft man somit Bewusstsein über die Unternehmensprozesse, deckt Defizite auf und regt zur Reflexion an. Nicht zuletzt wird in diesem Schritt validiert, ob die ausgewählten Kennzahlen gemäß ihrer Berechnungs- und Prozesslogik für das jeweilige Analyseziel geeignet sind [Interview 09.02.2018].

Mit Hilfe einer solchen Systematik erfolgt eine qualitative Erfassung von Informationen. Diese stellt im Gegensatz zu den in Kapitel 3.5 dargelegten qualitativen Ansätzen der Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen jedoch nur eine initiale Informationsbasis dar, welche Kennzahlen quantitativ zu analysieren sind und welche Rolle sie in dem entsprechenden Prozess einnehmen. Eine Diskussion oder Erfassung von Beziehungen zwischen diesen erfolgt nicht. Auf diese Weise reduziert sich der zeitliche Aufwand der Erfassung. Ein Beispiel für einen solchen Leitfaden befindet sich in Abb. 0-2 im Anhang. Nach der Durchführung eines solchen Interviews steht fest, welche Daten für die Analyse notwendig sind.

4.2.1.4 Beschaffung der Kennzahlendaten

In der Praxis liegen Daten häufig über viele Tabellen oder diverse (Sub-) Systeme verteilt vor, weshalb diese zunächst extrahiert werden müssen [van der Aalst 2011, 9]. Dies erzeugt bereits vor der eigentlichen Analyse erhebliche Aufwände. Hinzu kommen Zugriffsbeschränkungen, welche in Kombination mit den übrigen genannten Faktoren den in Kapitel 3.2 angesprochenen begrenzten Zugriff auf die Daten für die Fachbereiche begründen. Um prozess- und hierarchieübergreifende Daten zusammenzuführen, sind zusätzlich je nach Unternehmensbereich häufig Hierarchie-, Ressort- oder Abteilungsgrenzen zu überwinden. Sind diese Hürden genommen, folgen Herausforderungen aufgrund unterschiedlicher Konventionen zur Datenablage, unterschiedlicher gespeicherter Zeiträume sowie unterschiedlicher Aggregationsgrade der Kennzahlen [Witten et al. 2011, 52].

Angesichts dessen ist, bis sich flächendeckende Konzepte zur Lösung dieser Probleme in den Unternehmen etabliert haben, die Beschaffung der Kennzahlendaten ein nicht zu unterschätzendes Element für die Durchführung von Analysen. Nicht zuletzt, da der Fachanwender bei der eigenverantwortlichen Analyse Kriterien, die an die Daten gestellt werden (z. B. Vollständigkeit, Relevanz, Konsistenz [Schön 2018, 291]) sicherstellen muss. Je nach technischer Implementierung sind zudem weitere Anforderungen an den Datensatz zu erfüllen (beispielhafte Anforderungen für konkrete Umsetzungsfälle sind in Kapitel 5 genannt).

4.2.1.5 Datenimport

Die zusammengetragenen Daten müssen anschließend je nach technischer Lösung vor oder nach dem Import der Daten in die Software, in Tabellen zusammengeführt werden. Dabei sind zum Beispiel mögliche Datenfehler oder unterschiedliche Tabellenschlüssel zu berücksichtigen [Witten et al. 2011, 52], da die Analyseergebnisse letztlich nur so gut sind, wie der eingegebene Dateninput ist [Schön 2018, 290]. Darauf folgt die Bereinigung der Daten. Diese sollte unter der Prämisse, die Daten geringstmöglich zu verändern, erfolgen, sodass deren Objektivität erhalten bleibt. Ausreißer, fehlende (z. B. NaN) und fachlich unplausible Werte sind zu entfernen. Dabei ist es ist wichtig, einen permanenten Austausch mit Prozessexperten aufrecht zu erhalten, um keine für den Prozess charakteristischen Ausprägungen zu beeinflussen und relevante Daten auszuwählen. Prinzipiell besteht die Möglichkeit, dass Anomalien (Ausreißer), welche aus statistischer Sicht vermutlich nicht den Regelbetrieb widerspiegeln, trotzdem in der Analyse zu betrachten sind, da Experten diese als normale Prozesserscheinungen identifizieren [Rodriguez et al. 2009, 107]. Dies können beispielsweise Einflüsse aufgrund von Interdependenzen zu anderen, bedeutsamen Prozessen sein.

Es besteht die Möglichkeit, die Datenbereinigung (teilweise) zu automatisieren. So kann sich zum Beispiel je nach Anwendungsfall das automatische Entfernen von Dubletten anbieten [Schön 2018, 295]. Andere Verfahren berechnen den getrimmten Mittelwert eines Datensatzes, bei welchem vor der Mittelwertberechnung die

fünf kleinsten und fünf größten Werte gelöscht werden [Cleff 2015, 39]. Es gibt Fälle, in denen solche Verfahren durchaus sinnvoll sind, allerdings äußerten Kennzahlenexperten in einem Anwenderworkshop, dass sie die Kontrolle über die Daten behalten wollen und keine automatisierte Datenbereinigung wünschen. Hier zeigte sich wieder deutlich, dass das Vertrauen der Anwender in die angebotenen Lösungen von sehr großer Bedeutung ist.

Auf weitere vorbereitende Tätigkeiten oder Modelle für die Durchführung von Datenanalysen im Allgemeinen (z. B. CRISP-DM, KDD) wird nicht weiter eingegangen, sondern auf Autoren wie [Cios et al. 2007, 17 ff.] verwiesen. Nach Beendigung des Datenimports, der Zusammenführung und Bereinigung der Daten ist die Initialisierungsphase abgeschlossen und die eigentliche Analyse folgt.

4.2.2 Analyse

Während die Initialisierungsphase der Erfassung der notwendigen Datengrundlage dient, deckt die Analysephase mittels quantitativer Verfahren Informationen auf, die in den Daten enthalten sind. Dazu steht eine Vielzahl von Analysemethoden zur Verfügung, aus denen geeignete Algorithmen für die „…sinnvolle Verknüpfung mehrerer Methoden zur Unterstützung einer Klasse von Entscheidungsaufgaben…“ [Kemper et al. 2010, 112] auszuwählen sind. Diese **Techniken** erzeugen Modelle der Beziehungen zwischen den Kennzahlen, welche für den Anwender nutzbar sind. Sie sind je nach Anwendungsfall gemäß der Leitmerkmale aus Kapitel 3.7 wie Nachvollziehbarkeit der Ergebnisentstehung oder Generalisierbarkeit sowie weiterer fallspezifischer Kriterien (Vorhersagegenauigkeit, Robustheit[24], Charakteristika der Daten[25] usw.) auszuwählen.

Je nach Konstellation der Anforderungen sind einzelne Analysemethoden besser oder schlechter geeignet. Die richtigen Algorithmen sowie eine ständige Optimierung sind für die Güte der Ergebnisse entscheidend [Kieninger et al. 2015, 8]. Für einen nachhaltigen Einsatz im Unternehmen ist es dabei hilfreich, zuerst sukzessive das Vertrauen in die neuen Ansätze und die erzeugten Ergebnisse zu entwickeln [Kieninger et al. 2015, 11]. Dazu eignet sich in vielen Fällen in einem ersten Schritt die Deskription/Diagnostik.

---

[24] Statistische Methoden, die das Problem des Umgangs mit Ausreißern adressieren, werden als robust bezeichnet [Witten et al. 2017, 317]. Im Fokus steht dabei unter anderem die Vermeidung von Over- bzw. Underfitting (siehe Kapitel 3.5).

[25] Z. B. numerisch, binär, kategorisch.

4.2.2.1 Deskription/Diagnostik

Die Ermittlung und Visualisierung von Zusammenhängen zwischen mehreren Kennzahlen ermöglicht eine höhere Entscheidungsqualität [Hesse 2015, 192]. Dies fällt in den Bereich der Deskription/Diagnostik, welche alle Verfahren zur Beschreibung von Daten für das Gewinnen von Informationen umfasst [Cleff 2015, 4] und sich somit insbesondere für Einflussfaktorenanalysen eignet. Unter diese Analysen fallen Fragestellungen wie (siehe Abb. 4-8): Wie wirken einflussgebende Kennzahlen auf die Zielgröße? Zu deren Beantwortung ist anhand der Daten zu prüfen, ob zwischen zwei oder mehreren Kennzahlen eine starke, schwache oder keine Beziehung vorliegt. Liegt eine starke Beziehung vor, ist die Kennzahl zukünftig für die Prozesssteuerung zu berücksichtigen, ist die Beziehung schwach ausgeprägt, wird eine geringe prozessuale Auswirkung induziert. Insofern kann beispielsweise die Wirksamkeit von Steuergrößen überprüft werden. Allerdings ist eine starke Beziehung nicht nur ein Indikator für eine mögliche kausale Beziehung, sondern kann auch für Redundanz der Kennzahlen sprechen [Peral et al. 2017, 79]. Je nach abschließender Einschätzung von Prozessexperten sind auf diese Weise redundante Kennzahlen zu identifizieren und zu entfernen, was den unternehmerischen Aufwand, diese Kennzahlen zu erfassen, zu speichern und zu berichten, reduziert. Gleichermaßen ist dies ein Schritt in die Richtung, das Management mit der richtigen Menge relevanter Informationen zu versorgen. Ferner erlauben deskriptive/diagnostische Verfahren, zu untersuchen, ob die Beziehung statistisch positiv oder negativ ist. Liegt eine positive Beziehung vor, steigt oder fällt die eine Größe, wenn die andere steigt oder fällt. Liegt eine negative Beziehung vor, steigt die eine Größe, wenn die andere fällt.

Eine weitere Fragestellung ist, ob die Einflussgrößen so wirken, wie es die Prozessexperten erwarten oder ob die in den Daten enthaltenen Informationen vom impliziten Wissen abweichen. Auf diese Weise lassen sich Kennzahlen identifizieren, die zwar zur Steuerung genutzt werden, aber eigentlich einen geringen Wirkungsgrad aufweisen.

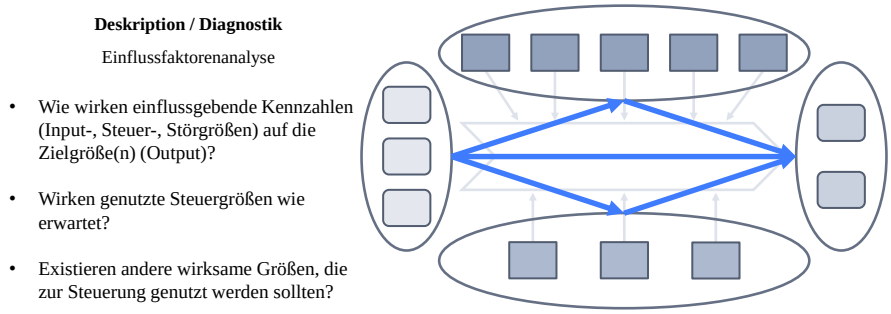

Abb. 4-8: Erkenntnisbeiträge der Deskription/Diagnostik

Mit Hilfe der Deskription/Diagnostik sind also aufgestellte Hypothesen überprüfbar: So ist es möglich, die in Kapitel 4.2 erwähnte Situation, dass ein Meister den Eindruck hat, dass die Hallentemperatur einen Einfluss auf die Anlagenverfügbarkeit hat, auf diese Weise zu untersuchen. Anhand einer diagnostischen Analyse wäre demnach zu prüfen, ob die Kennzahl Anlagenverfügbarkeit schlechtere Werte aufweist, wenn die Werte für die Hallentemperatur steigen oder nicht. Erfolgt diese Analyse unter Einbeziehung weiterer prozessrelevanter Daten, besteht auch die Möglichkeit, bisher unbekannte Beziehungen zu entdecken und zusätzliche wirksame Größen zur Steuerung zu identifizieren. So könnte die Hallentemperatur eventuell auch einen Einfluss auf andere Kennzahlen haben, was die Datenanalyse für den Menschen aufgrund eines geringeren Abstraktionsgrades sichtbar macht.

Umsetzen lassen sich diese Analysen mit verschiedenen Algorithmen, von denen hier nur einige Beispiele aufgeführt werden (siehe Tabelle 4-1): In Kapitel 3.5 wurden wiederholt Korrelationsanalysen genannt. Anhand des Korrelationskoeffizienten nach Bravais-Pearson sind beispielsweise lineare Zusammenhänge zwischen Variablenpaaren bestimmbar [Cleff 2015, 98]. Sind die notwendigen Anforderungen (wie Linearität oder metrische Skalenniveaus) für dessen Anwendung nicht erfüllt, ist unter anderem der Rangkorrelationskoeffizient nach Spearman eine Alternative. Dieser berechnet keine linearen Beziehungen sondern den monotonen Zusammenhang zwischen zwei Rangreihen [Cleff 2015, 102]. Falls nicht nur paarweise Analysen zwischen mehreren Kennzahlen durchgeführt werden sollen, sondern die kombinierte Auswirkung mehrerer Kennzahlen auf eine Zielgröße benötigt wird, eignet sich beispielsweise die in den untersuchten wissenschaftlichen Ansätzen (siehe Kapitel 3.5) wiederholt angewandte multivariate lineare Regression.[26]

Wie in Kapitel 2.4 erwähnt, gibt es komplementäre, konkurrierende oder unabhängige Ursache-Wirkbeziehungen. Eine komplementäre Beziehung zeigt sich durch eine starke, positive Verbindung, eine konkurrierende Beziehung durch eine starke, negative Verbindung und Unabhängigkeit durch keine Verbindung in der Datenanalyse. Diese sind durch die genannten Verfahren ermittelbar. [Kieninger et al. 2016, 242] kritisieren reine Korrelationsmodelle für strategische Entscheidungen und Szenario-Modellierungen als unzureichend, da diese keine Aussagen über kausale Beziehungen zwischen den Kennzahlen liefern. In der Tat impliziert eine betragsmäßig hinreichend große Korrelation nicht automatisch Kausalität [Cleff 2015, 124]. Ebenso ist aus der reinen Datenanalyse nicht erkennbar, ob ein direkter oder indirekter Zusammenhang zwischen zwei Variablen besteht, wie die tatsächliche Wirkrichtung ist (ob A auf B oder B auf A wirkt) oder ob es eine dritte Variable gibt, durch die (fälschlicherweise) eine statistische Beziehung erkennbar ist (Mediation). Korrelationen ergeben sich manchmal rein zufällig, weshalb ein hinreichend großer Koeffizient ohne tatsächliche Ursache-Wirkbeziehung eine so genannte Scheinkorrelation darstellt [Cleff 2015, 124]. Eine fehlende Korrelation schließt überdies eine Kausalbeziehung nicht aus.

---

[26] Weitere Erkenntnisse können darüber hinaus die Granger Kausalität, Moderation und Mediation (siehe [Cleff 2015]) sowie partielle Korrelationen und Kreuzkorrelationen liefern (siehe [Field 2013]).

<table>
<tr><th>Algorithmen</th><th>Charakteristika</th><th>Interpretationshinweise</th></tr>
<tr><td>Korrelations-koeffizient nach Bravais-Pearson</td><td>- Paarweise Analyse von Variablen
- Setzt Linearität der statistischen Beziehung voraus
- Eignet sich für metrisch skalierte Variablen</td><td rowspan="3">- Enthalten keine Aussagen über Kausalität zwischen den Variablen
- Direkte / indirekte Zusammenhänge sind nicht ablesbar
- Aussagen bezüglich der Wirkrichtungen der Variablen sind nicht möglich
- Zufällige statistische Beziehungen sind möglich
- Nicht erkannte Beziehungen können existieren</td></tr>
<tr><td>Korrelations-koeffizient nach Spearman</td><td>- Paarweise Analyse von Variablen
- Für die Analyse monotoner Zusammenhänge geeignet
- Eignet sich für metrisch skalierte sowie kategorische Variablen</td></tr>
<tr><td>Multivariate Regression</td><td>- Analyse des Einflusses mehrerer Prädiktorvariablen auf eine abhängige Variable
- Erzeugt lineare Funktion
- Setzt Linearität der statistischen Beziehung voraus
- Eignet sich für metrisch skalierte Variablen
- Trendbrüche in den Daten können das Ergebnis negativ beeinträchtigen</td></tr>
</table>

Tabelle 4-1: Kurzbeschreibung deskriptiver/diagnostischer Algorithmen

Auch unter Anwendung alternativer Algorithmen stellen sich ähnliche Herausforderungen, weshalb es von besonderer Bedeutung ist, dass Fachexperten relevante Daten auswählen, um die Wahrscheinlichkeit zufälliger Korrelationen zu reduzieren. Außerdem sind die ermittelten Ergebnisse kritisch zu hinterfragen und Entscheidungen nach Abgleich mit Expertenwissen zu treffen (siehe hierzu Kapitel 4.2.3). Da dennoch gemeinsame Trends und ähnliche Verläufe der Daten identifizierbar sind, eignen sich diese Algorithmen zur Entscheidungsunterstützung. [Cokins 2013, 72] konstatiert, dass Scorecards und Dashboards durch den Einsatz von Korrelationsanalysen für Kennzahlen die Optimierung hinsichtlich deren Steuerung und Komplexität ermöglichen. Bei Bedarf existieren zudem weitere prüfende Verfahren wie Signifikanztests oder Kovarianzanalysen (siehe dazu [Field 2013]). Konnte durch die deskriptive/diagnostische Analyse ein tiefergehendes Verständnis für die Ursache-Wirkbeziehungen zwischen Kennzahlen gewonnen werden, bieten prädiktive Analysen weiterführende Funktionen.

4.2.2.2 Prädiktion

Obwohl die Grenzen zwischen Prädiktion und Deskription/Diagnostik angesichts der anwendbaren Algorithmen nicht scharf sind, ist eine Unterscheidung für das Verständnis sinnvoll [Fayyad et al. 1996a, 44]. Dies bezieht sich insbesondere auf die in Kapitel 2.5 genannte Anforderung an die Digitale Unternehmenssteuerung, dass vermehrt eine proaktiv-prognostizierende Prozesssteuerung anstelle reaktiv-analytischer Auswertungen treten soll. Unternehmen besitzen heutzutage bereits Werkzeuge zur zukunftsorientierten Steuerung auf Basis traditioneller Planungen und Prognosen, die auf den Einschätzungen der Führungskräfte basieren und das Fundament ganzheitlicher Steuerung, Gestaltung und Koordination im Unternehmen bilden [Schön 2018, 435]. Folglich ist die Ableitung proaktiver Maßnahmen bezüglich der Kennzahlensteuerung von manuell erstellten und auf Erfahrungswissen basierenden Prognosen abhängig [Cundius 2018, 184]. Die dabei in manchen Fälleb durchgeführten Analysen historischer Daten erfordern umfassende manuelle Analysen mit verschiedenen Algorithmen bis schließlich ein Vorhersagemodell zur Verfügung steht [Castellanos et al. 2005, 2]. [Cokins 2013, 72] nennt drei Strategien, wie Vorhersagen beispielsweise in der Finanzindustrie durchgeführt werden:

> **Single Best Guess**. In der jährlichen Finanzplanung sagen Manager das erwartete Umsatzvolumen für das Sortiment, Arbeitskosten und Einkaufspreise voraus. Diese Einzelschätzungen werden anschließend zu einer Gesamtschätzung aggregiert.
>
> **Worst, Baseline, and Best Likely Outcomes**. Ein fortgeschrittenerer Ansatz berücksichtigt drei Arten von Ergebnissen: Den schlechtesten Fall, ein Grundlagenszenario und das wahrscheinlichste Ergebnis. Für jedes Szenario erfolgt eine Berechnung der Wahrscheinlichkeiten, welche wiederum aggregiert werden und ein Spektrum von Resultaten liefern.
>
> **Multiple Probabilistic Scenarios**. Im komplexesten Fall erfolgt eine Schätzung der Verteilung jeder verfügbaren Variable in Form der Abweichungen von den Ausgangswerten (z. B. -10% oder +20%) und die Ableitung einer Vielzahl von Verteilungskurven. Somit verbessern sich die Zuverlässigkeit der Vorhersagen und das Verständnis der Variablen als Treiber der Ergebnisse, welche proaktiv steuerbar sind.

Wenn sich die Rahmenbedingungen ändern, müssen diese Modelle aktualisiert werden, was, insbesondere bei einer sehr großen Anzahl an zu analysierenden Kennzahlen, zusätzlich zu der initialen Erstellung durch die Abhängigkeit von Erfahrungswissen hohe Aufwände verursacht [Castellanos et al. 2005, 2]. Zudem sind für solche Vorhersagen notwendige Ressourcen in der Regel innerhalb von (Produktions-) Unternehmen nicht flächendeckend verfügbar. Das Verhalten hoch komplexer Systeme ist ferner auf diese Weise nur sehr eingeschränkt vorhersagbar [Rüegg-Stürm 2014, 9]. Daher ist eine Automatisierung der Vorhersagen notwendig [Castellanos et al. 2005, 2].

Einen weiteren zu berücksichtigenden Aspekt bildet die große Nachfrage nach Simulationen, um das Verständnis der Auswirkungen von Maßnahmen auf andere Kennzahlen zu verbessern (Kapitel 2.3.4, [Hesse 2015, 177; van der Aalst 2011, 57]). Für die Durchführung von Simulationen erfolgt die formale Abbildung des zu untersuchenden Systems in einem Modell. Dieses nutzt zur Nachstellung von Einflüssen eingegebene Werte als Input für die Berechnung bestimmter Modellgrößen zur Gewinnung von Erkenntnissen [Wilde/Hess 2007, 282]. Nach der Modellerstellung manipuliert der Mensch das Modell, was zu zusätzlichen Informationen über das Modell selbst, aber auch über das Original, führt und Prognosen hinsichtlich des zukünftigen Verhaltens des geänderten Originals erlaubt [Trier et al. 2013, 59]. Der [Verein Deutscher Ingenieure 2016, 2] definiert daher eine Simulation als das "Nachbilden eines dynamischen Prozesses in einem System mithilfe eines experimentierfähigen Modells, um zu Erkenntnissen zu gelangen, die auf die Wirklichkeit übertragbar sind."

Bestehende Kennzahlensysteme sind als Simulationsmodelle für das Abschätzen der Wirkungen von Handlungsalternativen nutzbar [Gladen 2014, 27]. Die gelernten mentalen Modelle sind dazu für Teile des Prozesssystems häufig zuverlässig und hinreichend genau. In komplexen Systemen stoßen diese aber an ihre Grenzen [Forrester 2009, 10]. Computersimulationen sind hingegen in der Lage, auch das Verhalten komplexer Systeme aufzudecken [Forrester 2009, 10]. Fortgeschrittene Analysemethoden sind eine Möglichkeit, diese zu realisieren. Das zeigt sich in der in Kapitel 3.4 genutzten Definition von Advanced Analytics, in welcher Simulationsfunktionen bereits eingeschlossen werden. Insofern bietet sich die Kombination fortgeschrittener Analysemethoden zusammen mit Kennzahlensystemen für Simulationen an.

Mit Hilfe prädiktiver Algorithmen „…werden aus granularen Daten automatisiert Prognosen generiert, die eine höhere Treffsicherheit als traditionell erstellte Vorhersagen haben. Auf Grundlage dieser mit hoher Wahrscheinlichkeit zutreffenden Prognosen können Unternehmen nach vorne gerichtete Maßnahmen erarbeiten, um die erwartete Entwicklung positiv zu beeinflussen.“ [Mehanna et al. 2015, 29] Sie lernen anhand statistischer und mathematischer Verfahren Modelle über die Abhängigkeiten der zugrunde liegenden Vergangenheitsdaten und stellen Prognosefunktionalitäten zur Verfügung [Chamoni/Gluchowski 2017, 11; Schön 2018, 54]. Dies erlaubt, aus einer Vielzahl von Variablen Verhaltensweisen und Trends zu erkennen und unerwartete Erkenntnisse zu gewinnen [Halper 2014, 3].

[Malina et al. 2006, 939] sprechen von der `black box of predictive ability´, durch welche unternehmerische Vorteile entstehen und erzeugen somit Parallelen zu der Interpretation einer Black Box aus Kapitel 3.6. Mit Hilfe von Vorhersagealgorithmen lässt sich untersuchen, ob und in welcher Form Ursache-Wirkbeziehungen vorliegen und wie sich die betrachteten Outputgrößen sehr wahrscheinlich verhalten werden, ohne im Detail zu untersuchen, warum diese Beziehungen bestehen. Derartige prädiktive Analysen entwickeln sich mehr und mehr zu einem Entscheidungsvorteil für das Erreichen angestrebter Ergebnisse [Halper 2014, 3], weshalb diese auch für die Analyse von Kennzahlenrelationen Anwendung finden sollten.

Indem abhängige Variablen (Zielgrößen bzw. Outputgrößen) auf Basis quantitativ beschriebener Ursache-Wirkbeziehungen mit den relevanten Einflussgrößen geschätzt beziehungsweise prognostiziert werden, ist überprüfbar, ob angestrebte Prozessergebnisse erreicht oder verfehlt werden [Backhaus et al. 2016, 52, 64]. Verzielte Kennzahlen besitzen Grenzwerte, die festlegen, ob eine Zielvorgabe erreicht (Ampelfarbe: grün) ist oder nicht (Ampelfarbe: rot). Mit Hilfe prädiktiver Verfahren ist also frühzeitig erkennbar, ob der Wert zukünftig wahrscheinlich grün oder rot ist, sodass daraufhin eine Abstimmung der nächsten Maßnahmen zur Vermeidung eines unerwünschten Ergebnisses erfolgen kann [Castellanos et al. 2005, 2]. Dabei ist nicht maßgeblich, ob die Vorhersage 100%[27] genau ist [Castellanos et al. 2005, 2], sondern wie sich das Ursache-Wirkgefüge mit hinreichender Wahrscheinlichkeit verhalten wird und durch welche Einflussgrößen dieses Ergebnis zustande kommt. So können kombinierte Einflüsse mehrerer Faktoren betrachtet und nichttriviale Vorhersagen [Witten et al. 2011, 5] gemacht werden.

Wie bereits angedeutet, ermöglicht die Prädiktion zudem ´What-if Analysen´, um im Sinne einer Simulation zu beantworten, wie eine Zielgröße auf die Veränderung eines (oder mehrerer) Einflussfaktors reagiert (siehe Abb. 4-9). Ohne in den realen Prozess eingreifen zu müssen, sind somit die Auswirkungen von Prozessmodifikationen untersuchbar [Tröger 2014, 151]. Ebenfalls von großer Relevanz für das Management ist, welche der Modellgrößen den stärksten (positiven oder negativen) Einfluss auf die Zielgröße(n) hat. Durch die Prädiktion können werttreibende Faktoren hinsichtlich ihrer Ergebniswirkung analysiert werden [Schön 2018, 437]. Basierend darauf leiten sich Empfehlungen für die Prozesssteuerung ab [van der Aalst 2011, 257]. Indem transparent ist, welche Größen stark oder schwach, positiv oder negativ auf eine oder mehrere definierte Zielgrößen wirken, ist es möglich, die effizienteste Maßnahme mit dem besten Verhältnis zwischen Eingriffskosten und Ergebniswirkung auszuwählen. So kann eine Kennzahl zwar besonders stark im Sinne der angestrebten Ergebnisse Einfluss nehmen, deren Manipulation jedoch sehr hohe Kosten verursachen. Möglicherweise ist dann eine Alternative mit einer geringeren Ergebniswirkung aber deutlich geringeren Eingriffskosten für diesen spezifischen Fall besser geeignet. Darüber hinaus liefert dies eine quantitative Grundlage, um zu prüfen, welche Kennzahlen überhaupt für die Steuerung der Zielgröße(n) dienlich oder gegebenenfalls redundant sind [Shin et al. 2015, 982]. Durch die Konzentration auf die wesentlichen Größen kann also die Komplexität der Prozesssteuerung verringert werden. Der hohe Automatisierungsgrad bei der Erstellung und Aktualisierung der Modelle reduziert außerdem den Aufwand für Vorhersagen deutlich, wodurch die Effizienz steigt [Kieninger et al. 2015, 6]. Zudem verbessert sich die Effektivität der Unternehmenssteuerung durch zukunftsgerichtete, proaktive Maßnahmen [Kieninger et al. 2015, 6].

---

[27] Im Gegensatz dazu ist in anderen Anwendungsbereichen prädiktiver Analyseverfahren eine möglichst genaue Vorhersage von enormer Bedeutung. Wird beispielsweise im Rahmen von Predictive Maintenance ein Teil zu früh ausgetauscht, wird dessen Leistungsfähigkeit nicht genutzt. Wird es zu spät ausgetauscht, fällt die Maschine aus und ist nicht einsatzfähig. In beiden Fällen entsteht wirtschaftlicher Schaden.

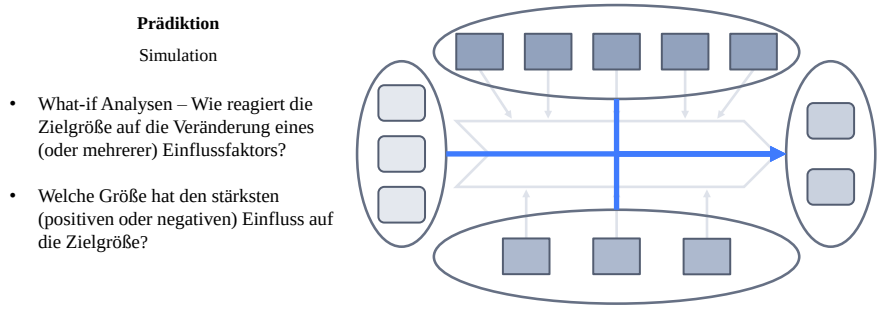

Abb. 4-9: Erkenntnisbeiträge der Prädiktion

In dem in den Kapiteln 1 und 1.3 erläuterten Beispiel, in welchem die verzögerte Anlieferung von Teilen aufgrund blockierter Autobahnen den reibungslosen Produktionsablauf gefährden könnten, könnte sich die Prädiktion produktionsrelevanter Kennzahlen angesichts der Einflussgrößen Wetter und Stau anbieten. Somit ließe sich die zu erwartende Auswirkung vorhersagen. Außerdem hätten Entscheidungsträger mit einem solchen Modell die Möglichkeit, Maßnahmen zu simulieren und wiederum deren Wirkung zur Vermeidung eventueller negativer Effekte zu untersuchen. Somit könnten sie letztlich geeignete Eingriffe für die Prozesse ableiten, noch bevor es zu den prognostizierten Effekten kommt.

Die meisten Anwendungen, die prädiktive Funktionalitäten beinhalten, fordern vom Anwender zu entscheiden, welche Techniken einzusetzen sind, wie die statistischen Ergebnisse zu analysieren sind und wie die Parametrisierungen erfolgen müssen oder es werden einfach in jeder Situation dieselben Algorithmen angewendet [Castellanos et al. 2005, 8]. Im ersten Fall ist umfassendes Know-how vonnöten, während der zweite Fall ineffizient ist [Castellanos et al. 2005, 8]. Daher ist ein Mittelweg zwischen diesen beiden Extremfällen zu finden, der einerseits zuverlässige Informationen sowie andererseits ein hinreichendes Maß an einfacher Interpretier- und Bedienbarkeit aufweist.

Als prädiktive Analysemethoden eignen sich unter anderem lineare Regressionen und Entscheidungsbäume (Kapitel 3.5, [Chamoni/Gluchowski 2017, 11; Rodriguez et al. 2009, 106]), welche auch in der Praxis überwiegend Anwendung finden (siehe Abb. 4-10).

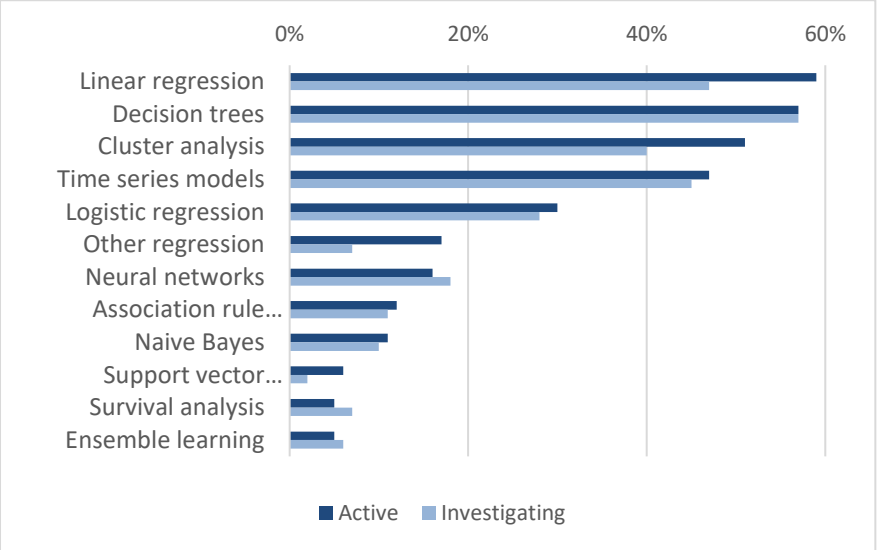

Abb. 4-10: In Unternehmen eingesetzte prädiktive Algorithmen [Halper 2014, 18]

Der primäre Anwendungsbereich von Regressionsverfahren ist die quantitative Beschreibung und Erklärung von Ursache-Wirkbeziehungen [Backhaus et al. 2016, 64]. Wie in Kapitel 3.3 erwähnt, bieten bereits lineare Verfahren interessante Einblicke in die in den Daten enthaltenen Informationen. Die lineare Regression, welche ebenfalls für die Deskription/Diagnostik einsetzbar ist, verdeutlicht, dass eine vollständige methodische Abgrenzung zwischen den Analysegruppen nicht möglich ist. Es handelt sich dabei um eine Schätzgerade, die den Einfluss einer oder mehrerer unabhängiger Variablen auf eine abhängige Variable mittels einer linearen mathematischen Funktion schätzt und in der Automobilindustrie beispielsweise für Absatzprognosen im Einsatz ist [Cleff 2015, 139; Schön 2018, 383]. Eine Möglichkeit die Funktion zu bilden ist, die Summe der quadrierten Abweichungen der tatsächlichen Datenpunkte von den jeweiligen Punkten auf der Geraden zu minimieren (Ordinary Least Squares Regression (OLS)). Entscheidungsbäume nutzen ebenfalls mehrere einflussgebende Variablen für die Vorhersage einer Zielvariablen. Die Verzweigungen des Baumes stellen die Fragestellungen und die Äste die unterschiedlichen Antwortmöglichkeiten dar, sodass Entscheidungswege interpretierbar sind [Schön 2018, 383].

Der Einsatz prädiktiver Verfahren unterliegt je nach eingesetzter Analysemethode zu berücksichtigenden Einschränkungen. So benötigt zum Beispiel die multivariate lineare Regression unter anderem eine linear beschreibbare Datenbasis, welche metrisch skaliert und normalverteilt ist. Trendbrüche in den Daten können das Ergebnis somit verschlechtern. Hinzu kommen im Allgemeinen der Deskription/Diagnostik ähnliche zu beachtende Aspekte: Eine erkannte Beziehung muss nicht existieren

und eine nicht erkannte Beziehung kann trotzdem existieren. Ohne Zutun von Expertenwissen ist das automatische Schließen auf Kausalbeziehungen oder Wirkrichtungen also nicht möglich [Backhaus et al. 2016, 65]. Ein wichtiges Charakteristikum prädiktiver Verfahren ist überdies, dass Vorhersagemodelle komplett verfälscht werden, wenn für den Prozess bedeutsame Einflussgrößen nicht enthalten sind [Shimizu et al. 2006, 3282]. Außerdem sind verschiedene Verfahren unterschiedlich robust und unterscheiden sich in ihrer Empfindlichkeit bezüglich möglicher Ausreißer in den Datensätzen. Auch erlauben sie häufig keine Analyse von Auswirkungen, die ausschließlich eintreten (oder um ein Vielfaches stärker eintreten) wenn zwei oder mehrere bestimmte Ereignisse in Kombination wirken. Eine Zusammenfassung dessen enthält Tabelle 4-2.

<table>
<tr><th>Algorithmen</th><th>Charakteristika</th><th>Interpretationshinweise</th></tr>
<tr><td>Multivariate Regression</td><td>- Analyse des Einflusses mehrerer Prädiktorvariablen auf eine abhängige Variable
- Erzeugt lineare Funktion
- Setzt Linearität der statistischen Beziehung voraus
- Eignet sich für metrisch skalierte Variablen
- Trendbrüche in den Daten können das Ergebnis negativ beeinträchtigen</td><td rowspan="2">- Enthalten keine Aussagen über Kausalität zwischen den Variablen
- Direkte / indirekte Zusammenhänge sind nicht ablesbar
- Aussagen bezüglich der Wirkrichtungen der Variablen sind nicht möglich
- Zufällige statistische Beziehungen sind möglich
- Nicht erkannte Beziehungen können existieren
- Negative Beeinflussung durch Fehlen bedeutsamer Prädiktoren
- Auswirkungen sich verstärkender Effekte kombinierter Ereignisse nur eingeschränkt abbildbar</td></tr>
<tr><td>Entscheidungsbaum</td><td>- Analyse des Einflusses mehrerer Prädiktorvariablen auf eine abhängige Variable
- Erzeugt Baumstruktur
- Knotenpunkte enthalten Entscheidungsregeln, sodass eindeutige Pfade definiert werden
- Eignet sich für metrische und kategorische Variablen</td></tr>
</table>

Tabelle 4-2: Kurzbeschreibung prädiktiver Algorithmen

Nichtsdestotrotz bieten prädiktive Verfahren eine Vielzahl an Vorteilen, die für die Digitale Unternehmenssteuerung überwiegen. Zudem sind viele Auswirkungen der Hürden entweder durch die Auswahl fallspezifisch gut geeigneter Analysemethoden bei der Konzeption sowie Lerneffekte des Anwenders durch den praktischen Einsatz auflösbar. Vor diesem Hintergrund steigt die Bedeutung sukzessive Vertrauen bildender Maßnahmen nochmals, um einen flächendeckenden Einsatz zu erreichen [Mehanna et al. 2015, 32]. Ferner sei noch einmal darauf hingewiesen, dass im Kontext der Digitalen Unternehmenssteuerung für die Bildung des Verständnisses für Ursache-Wirkbeziehungen und für die Vorhersage der möglichen Überschreitung von Grenzwerten kleinere Ungenauigkeiten bei der Prädiktion zu Guns-

ten der ´weichen´ Faktoren wie Nachvollziehbarkeit und Generalisierbarkeit hinnehmbar sind. Für die Entscheidung, welches Verfahren fallspezifisch eingesetzt werden kann, eignen sich Übersichten, wie die von [Casares 2019] (Tabelle 0-1 im Anhang).

[van Helden et al. 2018, 203] nutzen sowohl deskriptive/diagnostische, als auch prädiktive Verfahren zur Quantifizierung von Einflussgrößen für die Konstruktion eines präskriptiven Optimierungsmodells. Diese Analysegruppe wird folgend betrachtet.

4.2.2.3 Präskription

Vielfältige Faktoren können Entscheidungen hinsichtlich der Geschäftsprozesse beeinflussen. Einige Vertreter nennen [van Helden et al. 2018, 202] in Anlehnung an [Di Ciccio et al. 2015]:

- Wissen: Aus informationsgenerierenden Aktivitäten ergeben sich neben bereits gegebenen Informationen neue, aktuelle Kontextinformationen (Evidenzen), die Einfluss auf den Mitarbeiter und somit den Ablauf der Prozesse nehmen.
- Ziele: Die Ausführung von Prozessen verfolgt eines oder mehrere Ziele, welche sich in ihrer Priorität verändern können und Entscheidungen und den Ablauf beeinflussen.
- Einschränkungen: Einige Aktivitäten unterliegen bestimmten Einschränkungen und dürfen nur bei deren Gültigkeit ausgeführt werden, sodass diese zu berücksichtigen sind.
- Ereignisse: Einflüsse auf Entscheidungen und den Prozessablauf entstehen ebenfalls aus dem internen sowie externen Umfeld (siehe auch Kapitel 1.3).

Unter der Berücksichtigung derartiger Faktoren ist die dynamische Optimierung im Sinne der Bestimmung einer Systemkonfiguration, welche hinsichtlich eines oder mehrerer Gütekriterien optimal ist, ein wichtiges Anliegen der mathematischen Systemtheorie [Schwaninger 2004, 18]. Bei präskriptiven Analysen erfolgt die Erweiterung digitaler Prognosen und Simulationen durch digitale Optimierungen um konkrete Vorschläge für Entscheidungen und Maßnahmen und die Auswahl der besten Alternative [Schön 2018, 437].

Im Kontext der Digitalen Unternehmenssteuerung lässt sich auf diese Weise beantworten, wie ein Kennzahlennetzwerk zu steuern ist, um einen definierten Zustand der Zielgrößen zu erreichen (siehe Abb. 4-11). Insofern werden mittels der Analyse von Kennzahlendaten automatisch, basierend auf den gelernten Modellen, optimale Handlungsalternativen für die jeweiligen Input-, Stör- und Steuergrößen ermittelt [Chamoni/Gluchowski 2017, 13].

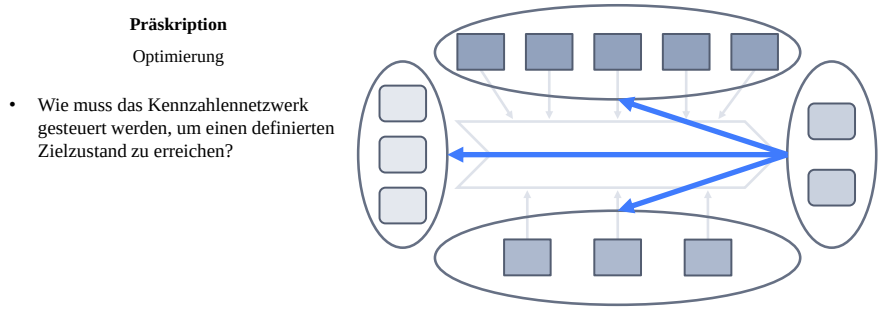

Abb. 4-11: Erkenntnisbeiträge der Präskription

Ein beispielhaftes Anwendungsszenario bildet die Situation, dass aufgrund von Anlagenstörungen in der Logistik Teilelieferungen nicht rechtzeitig erfolgen, sodass ein Ungleichgewicht zwischen Teileversorgung und -bedarf in der Montage entsteht [Interview 22.05.2018]. Das Interesse des Managements ist, Schäden für das Unternehmen zu vermeiden, beziehungsweise geringstmöglich zu halten. Allerdings verlangen dessen Zielvorgaben für die Kennzahlen ebenfalls, dass die avisierte Produktionsmenge für den Zeitraum erreicht wird. Um einen Produktionsstillstand zu vermeiden, besteht somit ein Anreiz, alle verfügbaren Teile aus den Beständen am Produktionsband und in den Lagern zu nutzen oder Fahrzeuge so weit wie möglich fertigzustellen und fehlende Teile in der Nacharbeit zu ergänzen. Daraus ergeben sich jedoch für die Verantwortlichen der Nacharbeit und der Versorgung der Nacharbeit große Herausforderungen. Ebenfalls ist es herausfordernd für die Logistik, die Bestände beim Übergang zurück in den Regelbetrieb wieder zu füllen und gleichzeitig die fortlaufende Montage zu versorgen. Folglich wurde das Problem zwischen den Prozessen verlagert. Fraglich ist demnach, ab welchem Umfang der fortlaufende Abruf der Teile in Summe größere Nachteile für das Unternehmen verursacht, als ein zwischenzeitlicher Produktionsstillstand. Im Idealfall ergibt sich durch präskriptive Analysen für das Management eine sehr gut fundierte, umfassend abgewogene Entscheidung, die alle relevanten Kennzahlen berücksichtigt und eine vergleichsweise hohe Nachvollziehbarkeit aufweist. Ist ein hinreichender Reifegrad der Modelle erreicht, sind Entscheidungen sogar automatisierbar.

Für die Erzeugung derartiger Modelle eignet sich beispielsweise das in Kapitel 3 angesprochene OR. Dieses findet unter anderem bei der jährlichen Produktionsplanung zur Lösung von Optimierungsproblemen unter gegebenen Restriktionen (z. B. Lagerkapazitäten) Anwendung. Die dafür benötigten (Un-) Gleichungen erzeugen Experten in der Regel überwiegend qualitativ, wobei auch die Ergebnisse einiger fortgeschrittener Analyseverfahren eingesetzt werden können. Um bestmögliche Ergebnisse aus einem solchen Modell zu erhalten, sind bei der Konstruktion und Auswertung alle für die Berechnung der Handlungsempfehlungen relevanten Einflussfaktoren zu berücksichtigen [van Helden et al. 2018, 202]. Vorteilhaft daran ist, dass für den Anwender nachvollziehbar ist, wie die errechneten Ergebnsise zu-

stande kommen. Vollständigkeit ist jedoch, wie im Falle der Deskription/Diagnostik sowie Prädiktion aufgrund der Komplexität, Vielzahl und Unterschiedlichkeit der Einflüsse nicht garantierbar.

Angenommen, alle relevanten Größen liegen vor, dann sind für viele Aufgaben mehrere unterschiedlich zu priorisierende Zielstellungen zur Erreichung eines für das Unternehmen bestgeeigneten Ergebnisses in Einklang zu bringen. In dem genannten Logistikbeispiel reicht zum Beispiel eine reine Produktions- und Logistikkostenoptimierung nicht aus, wenn die getroffene Entscheidung negative Auswirkungen auf das Endprodukt haben kann. Die Einbindung qualitativ erzeugter Kosten- und Nutzenfunktionen könnte zu einer Lösung beitragen. Aus dem hohen notwendigen Anteil qualitativer Modellierungen entstehen jedoch weitere Herausforderungen, wie hohe Ressourcenaufwendungen für die Erzeugung und Aktualisierungen. Eine generische Verwendung von Algorithmen im Sinne einer Wiederverwendbarkeit ist derzeit im Kennzahlenkontext kaum umsetzbar. Nichtsdestotrotz bieten präskriptive Analysen vor allem hinsichtlich der Automatisierung von Entscheidungen großes Potential für die Digitale Unternehmenssteuerung.

Nachdem in der Initialisierungsphase die benötigten Daten für die quantitative Analyse von Kennzahlenrelationen ausgewählt und nutzbar gemacht wurden, erfolgt die Analyse anhand der Deskription/Diagnostik, Prädiktion und/oder Präskription zur Extraktion von Informationen aus den Kennzahlendaten. Der nächste Schritt betrifft die Realisierung von Entscheidungen und Maßnahmen.

4.2.3 Realisierung

Die durch die Anwendung der Analysetechniken entdeckten Muster stellen als Ergebnis Informationen, aber noch kein Wissen dar [Knobloch/Weidner 2013, 350]. Ob diese Informationen gültig, neuartig, nützlich und verständlich sind, kann erst durch Interpretations- und Bewertungsmaßnahmen entschieden werden [Knobloch/Weidner 2013, 350]. Dies geschieht in der Realisierungsphase, welche nach der quantitativ geprägten Analysephase überwiegend qualitativer Natur ist. Sie beschreibt, wie ein Anwender die erarbeiteten Informationen als Input verwendet und schrittweise Wissen als **Entwurfsergebnis** generiert. Dazu sind drei Aktivitäten vorgesehen: Die Interpretation der Informationen, die Konklusion hinsichtlich zukünftiger Handlungen und die Applikation der Erkenntnisse.

4.2.3.1 Interpretation der Informationen

Es besteht die Möglichkeit, dass in der Initialisierungsphase nicht optimal ausgewählte und nicht zueinander passende Kennzahlen irreführende Informationen liefern und Mehrdeutigkeiten beinhalten können [Sprotte 2009, 36]. Daher sind die neu gewonnenen Informationen durch den Anwender kritisch zu betrachten und zu bewerten. Dazu sind in der Regel Kreativität und Kontextwissen notwendig, welche derzeit nicht automatisiert abbildbar sind [Knobloch/Weidner 2013, 364]. Außerdem existiert eine statistische Unsicherheit der analytischen Erkenntnisse und Prognosen, sodass sich Unternehmen derzeit nicht ausschließlich auf Datenanalysen für die kennzahlenbasierten Unternehmenssteuerung verlassen [Schön 2018, 433].

Bei der Analyse der physischen Logistik im BMW Group Werk Leipzig zeigte sich beispielsweise, dass die Kennzahl Versorgungsleistung, welche sehr bedeutsam für die Messung des erfolgreichen Leistungsbeitrages der Logistik ist, sehr gute Werte erreichte, wenn ein Feiertag bevorstand. Ohne Einbeziehung von Kontextinformationen wäre also die Schlussfolgerung, dass das Aufkommen von Feiertagen ein positiver Einflussfaktor für die Zielerreichung der Logistik ist. Dies verdeutlicht, wie wichtig die kritische Betrachtung der Ergebnisse durch Prozessexperten ist, um Fehlinterpretationen zu vermeiden. Der Hintergrund dieser Information ist, dass Feiertage frühzeitig in der Versorgungsplanung bekannt sind und Störungen des Regelbetriebes nach Möglichkeit zu vermeiden sind. Daher wird die Logistik vor Feiertagen mit einem größeren Puffer an Teilen versorgt, um mögliche Lieferengpässe abfedern zu können. Ferner liefern die Zulieferer Teile, die auf kurz nach den Feiertagen terminiert waren, vorzeitig, um Ausfälle zu vermeiden. Folglich bleibt die Versorgungsleistung nicht nur, wie beabsichtigt, konstant, sondern verbessert sich sogar. Ursächlich für die gute Leistung ist demnach nicht der Feiertag selbst, sondern die Überversorgung der Logistik wegen des Feiertages. Angesichts dessen, dass die Versorgungsleistung eigentlich nur konstant gehalten werden soll, stellt sich eher die Frage, ob die Menge der Pufferteile zu groß ist und eine zu große Menge an gebundenem Kapital und Lagerkosten verursacht. Diese Abwägungen sind durch den Menschen zu leisten. Folglich kann die Relevanz und eigentliche Bedeutung von Informationen nur durch den Menschen beurteilt werden [Rozinat/van der Aalst 2006, 8]. Insofern bleibt dessen implizites Wissen gerade bei sehr komplexen Sachverhalten ein wesentlicher Bestandteil der Entscheidungsfindung. Im Anschluss an derartige Interpretationen der Informationen, folgt die Verarbeitung der Erkenntnisse durch das Ziehen von Schlussfolgerungen.

4.2.3.2 Konklusion hinsichtlich zukünftiger Handlungen

Das Ableiten von Maßnahmen folgt der Verfügbarkeit von Informationen und deren Interpretation. Die inhärente Unsicherheit, die zukunftsbezogene Entscheidungen beinhalten, benötigt dabei subjektive Annahmen und Intuitionen des Topmanagements, was vor allem die Identifikation und Einschätzung zukünftiger Möglichkeiten und Chancen betrifft [Norreklit 2000, 86]. Dieser ebenfalls kreative Prozess ist systemseitig nur sehr eingeschränkt unterstützbar [Knobloch/Weidner 2013, 358]. Überdies muss der Anwender entscheiden, ob die aus den ausgewählten Daten gewonnenen Erkenntnisse für die Grundgesamtheit verallgemeinerbar sind, was trotz aller Vorhersagealgorithmen einen spekulativen Charakter hat [Cleff 2015, 6]. Dennoch ist die Fehlerwahrscheinlichkeit bei der quantitativen Analyse erheblich besser einschätzbar als bei reinen qualitativen Betrachtungen [Cleff 2015, 6]. Unabhängig davon, ob die Daten qualitativ oder quantitativ erhoben wurden, obliegt es letztlich dem Entscheidungsträger, ob er die Erkenntnisse als hinreichend gesichert und übertragbar ansieht oder nicht. Fällt die Entscheidung zugunsten der Erkenntnisse aus, sind diese in Form von Entscheidungen und Maßnahmen anzuwenden.

4.2.3.3 Applikation der Erkenntnisse

Die Interpretation und das in Kontext setzen der Informationen sowie das Ableiten von Entscheidungen und Maßnahmen führen zu fundiertem Wissen bei dem Anwender. Die Ergebnisse der entscheidungsunterstützenden, quantitativen Analyse können aber auch mit weiteren Experten geteilt und für eine gemeinsame Meinungsbildung genutzt werden. Somit steigt die Qualität des Entscheidungsprozesses ebenso wie die der Entscheidung. Die resultierende positive Beeinflussung der Unternehmensprozesse durch die Anwendung der Erkenntnisse bietet wiederum neue Daten und Erkenntnisgewinn, sodass die in Kapitel 1.3 angesprochene Positivspirale einer verbesserten Entscheidungsqualität heute, die ebenfalls zu einer besseren Entscheidungsqualität in der Zukunft führt, angestoßen wird.

[Knobloch/Weidner 2013, 365] sehen große Herausforderungen für die Zukunft darin, Systemumgebungen zur Entscheidungsvorbereitung zu schaffen, in welchen sämtliche Elemente einer Entscheidungssituation (Entscheidungsproblem, Restriktionen, Zielfunktion; Ergebnisse verschiedener Datenanalysen, externe Informationen, Notizen, Korrespondenzen; Lösung des Entscheidungsproblems und Begründung, etc.) bei Bedarf auch zu späteren Zeitpunkten zur Verfügung stehen. Das Ziel ist, in ähnlichen Situationen auf vergangene Erfahrungen zurückzugreifen [Knobloch/Weidner 2013, 365]. Das beschriebene Vorgehen bildet zwar nicht zwingend alle der genannten Elemente ab, bietet jedoch gegenüber Entscheidungen, welche ausschließlich auf implizitem Wissen basieren, erheblich bessere Möglichkeiten zur Dokumentation und späteren Verwendung.

Nach der Beendigung der Aktivitäten des Vorgehensmodells zur Entscheidungsunterstützung kann der Zyklus bei Bedarf neu gestartet werden. An der Durchführung der Aktivitäten sind in der Regel mehrere Personen beteiligt, die auf unterschiedliche Art und Weise zu dem Ergebnis beitragen.

4.3 Rollenmodell

Die dargestellten Aktivitäten nehmen Menschen wahr, die unterschiedliche Rollen einnehmen. Diese Rollen beziehen sich auf die Sicht des Aufgabenträgers und lassen sich in Form von Rollenmodellen darstellen. Jene Modelle ordnen Einzelpersonen oder Organisationseinheiten die Aktivitäten zu [Alt 2008, 255]. Für Datenanalyseprojekte existieren in der Literatur bereits Rollenmodelle und jeweils zugeteilte Aufgaben (siehe dazu beispielsweise [Felden 2016; Ebers et al. 2018; Heath/Hull 2015]). Die Kombination dieser Erkenntnisse mit den im Rahmen der Dissertation durchgeführten empirischen Analysen führte zu folgender, für die Digitale Unternehmenssteuerung empfohlener Rollenaufteilung:

Rolle	**Aufgabenbeschreibung**
Fachexperte	- Stellt fachliche Anforderungen - Bringt Prozessknow-how ein - Kennt Detaildaten mit Bezug zum Fachprozess - Wählt Datenbasis aus - Interpretiert Analyseergebnisse und prüft diese kritisch - Bewertet Entscheidungsoptionen - Leitet Maßnahmen und Entscheidungen ab - Gibt Handlungsempfehlungen
Key User/Anwender	- Hat fortgeschrittene Kenntnisse in der Anwendung der Analysesoftware - Importiert Daten in Analysesoftware - Führt Datenbereinigung zusammen mit Fachexperten durch - Führt Analysen durch - Hat ein fortgeschrittenes Verständnis für IT-Lösungen
Data Engineer	- Verwaltet und stellt benötigte Daten zur Verfügung (ggf. aus verschiedenen Quellen – Extract, Transform, Load) - Verwaltet Datenschnittstellen
Data Scientist	- Wählt geeignete Analysemethoden bei der Erstellung der Analysesoftware aus - Ergänzt geeignete Analysemethoden für die Analysesoftware - Steht beratend zur Verfügung

Tabelle 4-3: Rollenmodell für die Digitale Unternehmenssteuerung

Die Rollen sind entsprechend des jeweiligen Anwendungsfalls zu betrachten und zu besetzen. Auch können mehrere Personen eine Rolle oder eine Person mehrere Rollen einnehmen. Sind beispielsweise ein Entscheidungsträger mit breit angelegtem Wissen und ein beratender Prozessexperte mit Detailwissen beteiligt, teilen sie sich die Aufgaben des Fachexperten. Ist die Analysesoftware so anwenderfreundlich programmiert, dass ein Fachexperte sie mit seinem aktuellen Kenntnisstand selbständig bedienen kann, vereint er in sich die Rollen des Fachexperten und des Key Users und liefert somit gleichermaßen den fachlichen Input und führt die Analyse aus. Data Engineers können insbesondere in der Initialisierungsphase sehr hilfreich sein, da sie die Quellsysteme und verfügbaren Daten häufig sehr gut kennen. Data Scientists wählen bei der Softwareentwicklung gemäß der Fachanforderungen geeignete Analysealgorithmen aus und beraten Fachexperten bei deren Anwendung und Interpretation. Besonders für Nachfragen, die das Vertrauen in die Ergebnisse steigern, ist deren Beitrag von sehr großer Bedeutung. Die Besetzung aller Rollen ist nicht immer notwendig und es können je nach Anwendungsfall Rollen hinzukommen oder wegfallen. Wie angedeutet, hat die technische Umsetzung der Software einen großen Einfluss auf die benötigten Rollen und die tatsächliche Anwendung der Methode durch die Mitarbeiter von Unternehmen.

4.4 Tool und Leitmerkmale

Kapitel 3.5 untersucht Ansätze zur Entscheidungsunterstützung mittels der quantitativen Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen für die Unternehmenssteuerung und stellt Gründe für die geringe Verbreitung dieser in der Praxis heraus. Die somit erarbeiteten **Leitmerkmale** dienen der Orientierung für die technische Umsetzung von Analysesoftware (**Tool**). Sie umfassen

- Prozess- und hierarchieübergreifende Analysen,
- Komplementär sowie komparativ eingesetzte Analysemethoden,
- Objektivität der Analyseergebnisse,
- Anwenderfreundlichkeit bei der Durchführung und Interpretation,
- Schaffen von Vertrauen in die Ergebnisse,
- Nachvollziehbarkeit der Ergebnisentstehung ohne automatisierte Entscheidungen,
- Wirtschaftlichkeit durch generisch einsetzbare und skalierbare Lösungen.

Um die Aktivitäten des Vorgehensmodells durchlaufen und die verschiedenen Analysetechniken anwenden zu können, ist die Verfügbarkeit eines (oder mehrerer) (Software-) Tools notwendig. Die vorliegenden Leitmerkmale und die aufgezeigte Vision schaffen eine Sollvorstellung eines Informationssystems für die Digitale Unternehmenssteuerung, deren Berücksichtigung bei der Konstruktion von Informationssystemen unter gegebenen Restriktionen (siehe Kapitel 1.4) einen unterneh-

mensweiten Einsatz fördern. Das Tool trägt wesentlich dazu bei, die für Fachanwender ohne fortgeschrittene Analytics-Kenntnisse schwer nutz- und interpretierbaren Algorithmen leicht anwendbar zu machen und die Ergebnisse verständlich zu visualisieren. Es stellt zusammen mit den Leitmerkmalen die letzten Elemente der Methode für die Digitale Unternehmenssteuerung dar.

4.5 Methode für die Digitale Unternehmenssteuerung

Die Vielzahl an Interdependenzen zwischen Prozessen innerhalb großer Produktionsunternehmen bedingt ein hohes Maß an Komplexität. In diesem Umfeld hat das Management der Unternehmen die Aufgabe, die Prozesse im Sinne der übergeordneten Ziele zu steuern und zu führen. Dazu werden schnelle, fundierte und nachvollziehbare Entscheidungen sowie die Ableitung effizienter und effektiver Maßnahmen nach der Abwägung von Alternativen erwartet. Eine isolierte Betrachtung der Prozesse oder der Kennzahlen aufgrund von Zeitdruck und wegen der Komplexität der Aufgabenstellung kann die Betrachtung von Produktionssystemen in ihrer Gesamtheit verhindern. Um dies zu vermeiden, müssen prozessübergreifende Daten verfügbar und für den Entscheidungsträger analysierbar sein.

Ein Lösungsansatz liegt in der quantitativen Analyse der Ursache-Wirkbeziehungen zwischen Prozessen anhand relevanter Vergangenheitsdaten. Während also bisher Interdependenzen mit sehr hohem Aufwand fast ausschließlich qualitativ auf Grundlage des impliziten Wissens der Verantwortlichen erfasst werden, dienen dazu zukünftig digitale Werkzeuge wie Advanced Analytics Algorithmen. Unter Nutzung bestehender Strukturen wie Kennzahlensystemen und weiterer interner sowie externer Datenquellen werden mit Hilfe der digitalen Werkzeuge in einem unternehmensweiten Ansatz bestehende sowie aus Daten abgeleitete Informationen in Beziehung gesetzt, um Wissen zu generieren. Demnach überträgt der Mensch gemäß der sinnhaften Vollautomation (siehe [Mertens 1995]) die Aufgabe der Analyse von Ursache-Wirkbeziehungen auf Maschinen. Dies ist gerechtfertigt aufgrund der höheren Leistungsfähigkeit von Maschinen im Umgang mit Komplexität im Sinne der Verarbeitung mehrerer Variablen sowie unter der Berücksichtigung von deren höheren Wirtschaftlichkeit durch den erheblich geringeren Analyseaufwand (vgl. [Mertens et al. 2017, 4]). In Kapitel 2.5 zeigte sich jedoch, dass entsprechende Methoden für das Treffen fundierter empirischer Aussagen hinsichtlich des Nachweises von Ursache-Wirkbeziehungen fehlen.

Das Methoden Engineering nach [Gutzwiller 1994, 13] ergänzt durch [Alt 2008, 128] bietet eine geeignete Ausgangsbasis für die Zusammenstellung der für die Digitale Unternehmenssteuerung benötigten Elemente. Diese Elemente und die Zusammenhänge, die zwischen diesen bestehen, sind zusammenfassend in dem Metamodell in Abb. 4-12 dargestellt.

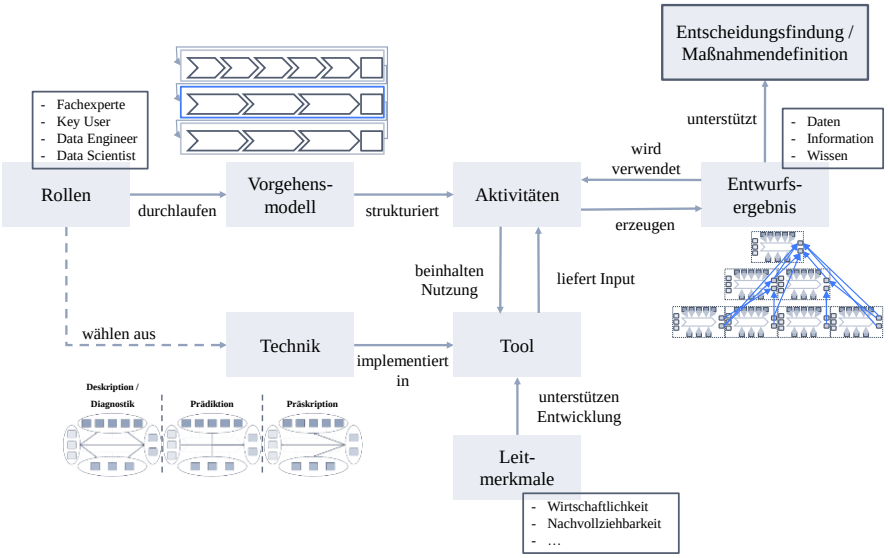

Abb. 4-12: Metamodell der Methode für die Digitale Unternehmenssteuerung

Das Vorgehensmodell (Kapitel 4.2) legt die zur Ergebniserzeugung auszuführenden Entwurfsaktivitäten mit den zu erarbeitenden Inhalten fest und bringt sie in eine Ablauffolge. Dabei ist es deutlich spezifischer als beispielsweise das CRISP-DM, aber dennoch im Bereich der quantitativen Analyse von Kennzahlenrelationen allgemeingültig definiert. Da, sofern ein Tool mit geeigneten Techniken zur Verfügung steht, die eigentliche Datenanalyse den geringsten Aufwand in einem Analyseprojekt darstellt, liegt das Hauptaugenmerk des Vorgehensmodells auf den bedarfsgerecht und iterativ zu durchlaufenden Aktivitäten der Initialisierungs- und Realisierungsphasen. Es dokumentiert bewährte Schritte und leitet den Anwender durch die Aktivitäten zur Anwendung der Algorithmen. Somit verringert es die Komplexität der Analyseprojekte, hilft bei der Einarbeitung in die Methode und in der Konsequenz bei der Vermeidung von Fehlern und Unsicherheiten. Als Ergebnis steigen die Effizienz der Projektabwicklung und die Transparenz.

Ebenfalls der Vereinfachung und Schaffung von Transparenz für die Durchführung eines solchen Analyseprojektes dient das Rollenmodell. Die an der Ausführung beteiligten Personen erfüllen unterschiedliche Funktionen gemäß ihres Fachwissens und nehmen daher unterschiedliche Rollen ein (Kapitel 4.3). Ist frühzeitig bekannt, welches Know-how benötigt wird, sind die verfügbaren Ressourcen besser planbar.

Einen sehr starken Einfluss auf das während der Analyse benötigte Know-how bei den Anwendern haben die Techniken zur Erzeugung der Entwurfsergebnisse (Kapitel 4.2.2). Je nach zu beantwortender Fragestellung und Verfügbarkeit geeigneter Software sind Algorithmen unter der Berücksichtigung technischer Rahmenbedingungen wie Robustheit, angestrebter Vorhersagegenauigkeit oder Charakteristika

der Daten auszuwählen oder bestehende Lösungen anzuwenden. Sie ermöglichen deskriptive/diagnostische, prädiktive und präskriptive Analysen. Die Deskription/Diagnostik (Kapitel 4.2.2.1) dient der Einflussfaktorenanalyse und unterstützt bei der Ermittlung komplementärer, konkurrierender oder unabhängiger Ursache-Wirkbeziehungen in Form von quantitativ erzeugten, komplexen Abhängigkeitsnetzen. Die Prädiktion (Kapitel 4.2.2.2) ermöglicht Vorhersagen und Simulationen und untersucht, ob und inwiefern mehrere einflussgebende Kennzahlen mit den betrachteten Outputgrößen in Beziehung stehen. Bei der Anwendung präskriptiver Analysen (Kapitel 4.2.2.3) werden optimale Systemzustände hinsichtlich eines definierten Outputs bei gegebenen betrieblichen Restriktionen berechnet. Sie stellen einen wesentlichen Beitrag zur Entscheidungsautomatisierung dar.

Auf unterschiedliche Arten fördern diese Techniken die proaktive Steuerung von Prozessen in Produktionsunternehmen. Sie schaffen Transparenz über die Ursache-Wirkbeziehungen zwischen Kennzahlen, ohne mit hohem Aufwand die exakten prozessualen Kausalketten untersuchen zu müssen. Darüber hinaus sind sie im Vergleich mit vielen qualitativen Methoden deutlich wirtschaftlicher erzeugbar, aktualisierbar und von dem Know-how einzelner Personen unabhängiger, da sie automatisiert gelernt werden.

Ob und wie gut die Techniken für Fachanwender einsetzbar sind, hängt maßgeblich von deren Kombination sowie dem eingesetzten Tool ab (Kapitel 4.4). Es gilt einerseits, die technischen Anforderungen hinreichend zu erfüllen und andererseits die Leitmerkmale (Wirtschaftlichkeit, Nachvollziehbarkeit usw.) im Sinne eines angestrebten flächendeckenden Einsatzes des Tools zu berücksichtigen. Die Priorisierung der Umsetzung dieser Aspekte obliegt dem Unternehmen.

Das angewandte Prozessmodell (Kapitel 4.2.1.1) mit seinen Input-, Output-, Stör- und Steuergrößen bietet die Möglichkeit, Prozesse von operativen bis hin zu strategischen Ebenen auf die gleiche Art und Weise zu modellieren, um die Ursache-Wirkbeziehungen zwischen den Größen zu untersuchen. Es kann Super- wie auch Subprozesse repräsentieren, ist somit je nach Perspektive des Anwenders auf vielfältige Problemstellungen anwendbar und hilft, die verfügbaren Größen zu strukturieren. Die eigentliche Analyse der Ursache-Wirkbeziehungen erfolgt mittels der ausgewählten Technik auf Grundlage der Kennzahlendaten.

Im Sinne eines unternehmensweiten Steuerungsansatzes und der Analyse von Prozessinterdependenzen im Kennzahlengefüge sind die Vernetztheit und Komplexität des realen Betriebes zu erfassen. Dazu sind prozess- und hierarchieübergreifende Analysen durchzuführen. Das Ebenenmodell (Kapitel 4.2.1.2) repräsentiert die einzelnen Bestandteile des betrachteten Prozesssystems und beschreibt auf Grundlage der Ergebnisse der Analysemodelle die Beziehungen zwischen den Prozessen. Somit ist die Wirksamkeit des bestehenden Kennzahlensystems und der Prozessstrukturen überprüfbar und ermöglicht im Bedarfsfall Optimierungen.

Letztlich entstehen die Ergebnisse der Methode in der Realisierungsphase des Vorgehensmodells unter Anwendung der Ergebnisse der einzelnen Elemente als Input. Das Management kann somit in einem interdisziplinären Zusammenspiel von Expertenwissen und Methodenkompetenz besser fundierte und nachvollziehbarere Entscheidungen auf Basis der mit Hilfe der digitalen Werkzeuge empirisch beschriebenen Ursache-Wirkbeziehungen treffen und Maßnahmen definieren.

Durch die Entwicklung dieser Methode zur Informationssystemgestaltung ist der erste Teil des Gestaltungszieles erreicht. Dies stellt einen großen Schritt in Richtung der Umsetzung der in Kapitel 1.3 aufgestellten Vision und folglich einer zukünftig (teil-) automatisierten Prozesssteuerung dar. Zu welchem Ausmaß deren Realisierung erfolgen wird, hängt davon ab, ob die erzeugten Artefakte Anwendung finden, denn in der Wirtschaftsinformatik sind Artefakte selten formal beweisbar [Österle et al. 2010, 670]. Stattdessen basieren sie darauf, dass Experten, die den Stand der Wissenschaft und die Praxis kennen, sie aufgrund der vorgelegten Begründung und der Implementierung akzeptieren [Österle et al. 2010, 670]. Daher ist zu untersuchen, ob die vorliegenden Ergebnisse bei der Bewältigung der im zweiten Kapitel erarbeiteten Herausforderungen für das Management helfen und die Erfüllung der Anforderungen an die kennzahlenbasierte Unternehmenssteuerung unterstützen. Unter Verwendung der im dritten Kapitel hergeleiteten Leitmerkmale und der im vierten Kapitel entwickelten Elemente der Methode für die Digitale Unternehmenssteuerung erfolgt im nächsten Kapitel die Prüfung der Akzeptanz von Experten im betrieblichen Einsatz zur vollständigen Erreichung des Gestaltungsziels.

5 Umsetzung der Digitalen Unternehmenssteuerung

Gemäß des in Kapitel 1.4 dargestellten Forschungsvorgehens ist durch den Entwurf der Methode für die Digitale Unternehmenssteuerung die Entwurfsphase beendet. Infolgedessen ist das entwickelte Artefakt einer Evaluation zu unterziehen. [Venable et al. 2016, 80] schlagen dazu verschiedene Evaluationsstrategien vor.

5.1 Evaluationsstrategien im Design Science Research

Die Strategien für die Evaluation von Artefakten gemäß des Design Science Research sind anhand von zwei Dimensionen beschreibbar. Das Spektrum der einen Dimension reicht von künstlich bis naturalistisch und der anderen von formativ bis summativ (siehe Abb. 5-1).

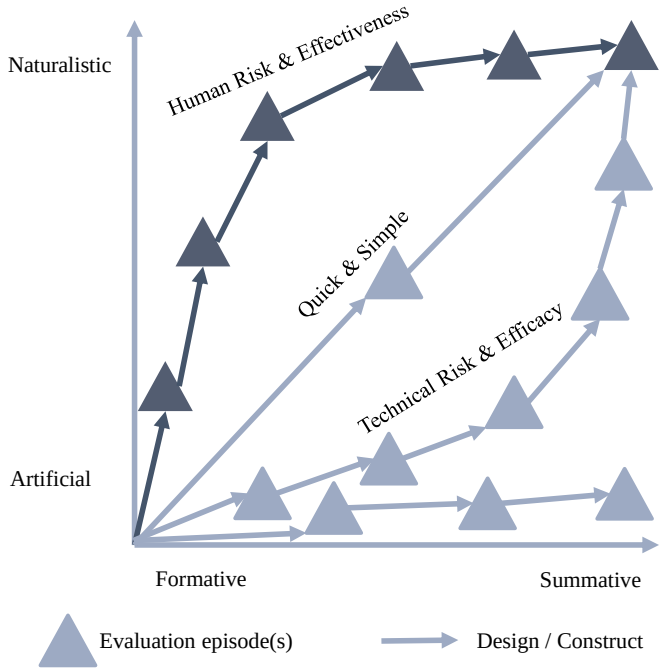

Abb. 5-1: Framework for Evaluation in Design Science [Venable et al. 2016, 80]

Eine summative Evaluation nach [Venable et al. 2016] beabsichtigt die Beurteilung des Ausmaßes, zu welchem das fertiggestellte Ergebnis die Erwartungen erfüllt. Bis das finale Ergebnis erreicht ist, können Zwischenstände evaluiert werden, um diese fortlaufend zu verbessern; dies entspricht einer formativen Evaluation. Die künstliche Evaluation umfasst Laborexperimente, Simulationen, kriterienbasierte Analysen, theoretische Argumente und mathematische Beweise. Demgegenüber basiert die naturalistische Evaluation auf der Untersuchung der Leistung einer Lösung in ihrer tatsächlichen Umgebung, was üblicherweise Unternehmen sind. Dies beinhaltet die reale Unternehmenskomplexität sowie praktisches menschliches Handeln.

Wird eine relativ kleine formative Evaluation und eine zügige summative und eher naturalistische Evaluation durchgeführt, entspricht dies einer ´Quick & Simple´-Strategie. Erfolgt zunächst eine künstliche, formative Evaluation mit schnellem Fortschreiten zu naturalistischen, formativen Evaluationen, liegt eine ´Human Risk & Effectiveness´-Strategie vor. Die ´Technical Risk & Efficacy´-Strategie ist hingegen durch einen frühzeitigen Übergang von einer künstlichen, formativen hin zu einer künstlichen, summativen Evaluation geprägt. [Venable et al. 2016, 80 ff.]

Wie in Kapitel 4.5 erläutert, sind formale (künstliche) Beweise in der Wirtschaftsinformatik nur selten geeignet. In dem vorliegenden Fall war außerdem der langfristige Einsatz des Artefaktes in der Praxis angestrebt, weshalb eine starke Anwenderorientierung sehr wichtig war. Ferner ermöglichte die enge Verzahnung mit der Praxis die schnelle Realisierung der praktischen Erprobung von Zwischenständen [Venable et al. 2016, 82]. Somit fiel die Wahl auf die ´Human Risk & Effectiveness´-Strategie (in Abb. 5-1 dunkelblau hervorgehoben) und die einhergehende kontinuierliche Prüfung der Akzeptanz von Experten hinsichtlich der entwickelten Elemente. Dementsprechend erfolgte die Sicherstellung der Effektivität des Artefaktes durch eine überwiegend naturalistische Evaluation. Maßgeblich dafür war, ob es weiterhin Nutzen stiftet, wenn es im realen unternehmerischen Betrieb im Einsatz ist und sich langfristig trotz der Schwierigkeiten des Übergangs in das Tagesgeschäft eignet [Venable et al. 2016, 81 f.].

Für die Erfassung der Reaktionen der Anwender auf die Methode sowie die entsprechenden Softwarelösungen eigneten sich sowohl Einzel- wie auch Gruppeninterviews, bei welchen sich die Teilnehmer gegenseitig zu weiteren Interpretationen animierten [Benyon et al. 2006, 281]. So wurde auf effektive Weise ermittelt, was die Anwender möchten und auf welche Probleme sie stoßen [Benyon et al. 2006, 216]. Dazu standen drei Typen von Interviews zur Auswahl: Strukturierte Interviews befolgen strikt im Vorhinein vorbereitete Fragen, wodurch sie leicht durchführbar sind, jedoch durch die engen Vorgaben keine Erfassung unerwarteter Antworten zulassen (z. B. Meinungsumfragen) [Benyon et al. 2006, 216]. Halbstrukturierte Interviews folgen vorbereiteten Fragen, welche der Interviewer situationsbedingt stellen und somit flexibel auf sich ergebende Themen eingehen kann [Benyon et al. 2006, 216]. Der dritte Typ, welcher für die folgende Evaluation angewandt wurde, sind unstrukturierte Interviews mit explorativem Charakter zur Minimierung

des Einflusses des Fragestellers und zur Schaffung von Freiräumen für die Interviewpartner [Benyon et al. 2006, 216]. Sie eigneten sich insbesondere für den Einsatz in regulär stattfindenden Meetings im Alltagsgeschehen.

So wurden zunächst die Problemstellung und Forschungslücke theoretisch erarbeitet und frühzeitig Feedback von Experten aus der Praxis eingeholt. Die gewonnenen Erkenntnisse flossen direkt in erste Methodenentwürfe mit entsprechenden Umsetzungen ein und wurden praktisch erprobt. Daraus entstandene Lerneffekte ermöglichten schrittweise Verbesserungen der Software und der Elemente der Methode für die Digitale Unternehmenssteuerung. Insofern fand ein stark formativ, naturalistisch geprägter Prozess statt, welcher mit einer summativen, naturalistischen Evaluation endete. Allerdings sind sowohl die Methode als auch die Software zukünftig weiterzuentwickeln und zu aktualisieren, sodass eine Fertigstellung nur aus Sicht des Dissertationsprojektes anzunehmen ist. Bezüglich der Software als ein zentrales Element der Methode war zu Beginn der Entwicklung zunächst zu entscheiden, welche Form der Umsetzung geeignet ist.

5.2 Individual- und Standardsoftwarelösungen

Für die Realisierung einer Softwarelösung zur quantitativen Analyse von Kennzahlenrelationen bestand einerseits die Möglichkeit des Einsatzes einer Standardsoftware oder der Entwicklung einer Individualsoftware. Standardsoftware entspricht einer Anwendung, welche Softwarehersteller einem anonymen Markt anbieten, während sich Individualsoftware durch eine individuelle (eigene oder fremde) Programmierung auszeichnet und Spezialanforderungen des Unternehmens beinhaltet [Schön 2018, 305]. Eine Gegenüberstellung der Vor- und Nachteile dieser beiden Implementierungsmöglichkeiten ist Tabelle 5-1 zu entnehmen.

	Vorteile	Nachteile
Standard-software	- Jahrelange Erfahrungen verschiedenster Branchenanforderungen können genutzt werden - Bestimmte Unternehmensanforderungen können durch das Customizing für den vorgedachten Standard abgedeckt werden - Integrationsflexibilität zu anderen Systemen - Weniger personal- und kapitalaufwendig - Standardisierung von Prozessen möglich - Weiterentwicklung zumeist durch den Softwarehersteller gewährleistet	- Abhängigkeit vom Softwarehersteller - Funktionale Beschränkungen durch definierten Produktumfang - Individuelle Spezialanforderungen, die über das Customizing hinaus gehen, können nur bei offenen Systemen berücksichtigt werden - Customizing verursacht zusätzliche Kosten - Aufwände entstehen für die detaillierte Analyse und den Vergleich konkurrierender Angebote
Individual-software	- Flexible Weiterentwicklung möglich - Unabhängigkeit vom Softwarehersteller - Individuelle Spezialanforderungen können berücksichtigt werden - Urheberrechte der Lösung gehören dem eigenen Unternehmen	- Personal- und kapitalintensiv - Keine erfolgsversprechende Entwicklungsgarantie - Integrationsfähigkeit zu nach- und vorgelagerten Systemen muss selbst gewährleistet werden - Komplexität der Anforderungen zumeist alleine nicht mehr umsetz- und pflegbar - Abhängigkeit von einzelnen Programmierern bzw. vom Programmierwissen - Aufwände für Weiterentwicklung, Wartung etc. entstehen im eigenen Unternehmen

Tabelle 5-1: Vor- und Nachteile der Softwarelösungen (in Anl. an [Schön 2018, 307])

Wie in Kapitel 3 dargestellt, liegt keine Standardsoftware vor, die die Anforderungen für die Digitale Unternehmenssteuerung erfüllt. Einige Anbieter von BI-Lösungen liefern zwar Schnittstellen zu R oder Python (siehe Kapitel 3.3), welche das Erzeugen von Programmen für den Einsatz von Advanced Analytics-Methoden ermöglichen. Dies entspricht jedoch einem sehr hohen Individualisierungsaufwand der Standardlösung. Insbesondere die Ungewissheit der Akzeptanz der Ergebnisse bei den Anwendern und die Notwendigkeit iterativer Anpassungen auf Grundlage des Anwenderfeedbacks schlossen die Anwendung einer Standardsoftware, welche mit großer Abhängigkeit vom Hersteller und hohen zusätzlichen Kosten einhergegangen wäre, aus. Die unabhängige, flexible Weiterentwicklung und Umsetzung von Spezialanforderungen waren im Bewusstsein der gegebenen Nachteile demnach ausschlaggebend für die Entscheidung, Individuallösungen zu entwickeln. Gemäß der formativ-naturalistischen Evaluation werden nachstehend die Evolutionsstufen der Softwareversionen als Zwischenstände (siehe Kapitel 5.1) sowie das Endergebnis jeweils unter Einsatz der Methode für die Digitale Unternehmenssteuerung vorgestellt.

5.3 KPI Intelligence Tool v1: Analyse von Werkskennzahlen

In den ersten Anwendungsfällen der Methode für die Digitale Unternehmenssteuerung lag der Fokus auf der Untersuchung der technischen Realisierbarkeit der quantitativen Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen für die Entscheidungsunterstützung des Managements großer Produktionsunternehmen. Mit dem Ziel zu prüfen, ob fortgeschrittene Analysemethoden dabei helfen, quantitativ Erkenntnisse für die Prozesssteuerung zu erhalten, wurden für die erste Version komplementäre **Techniken** ausgewählt und implementiert. Dies erfolgte für die Deskription/Diagnostik und die Prädiktion. Eine Umsetzung präskriptiver Analysen fand aufgrund des enorm hohen Implementierungsaufwandes zur Erfassung von Kosten-/Nutzenfunktionen (siehe Kapitel 4.2.2.3) nicht statt.

5.3.1 Initialisierung

In der ersten durchlaufenen Initialisierungsphase fanden zahlreiche Interviews mit Experten aus diversen Bereichen des BMW Group Werks Leipzig (z. B. Logistik, Controlling, Reporting, Qualitätsmanagement) für die Erfassung relevanter Kennzahlen zur Analyse von Ursache-Wirkbeziehungen statt. Somit fungierten diese als Fachexperten und brachten ihr Prozess-Knowhow ein. Dabei zeigte sich sehr deutlich, dass zur Orientierung und Strukturierung der komplexen Fragestellung Hilfsmittel in Form von Modellen vonnöten sind. Um ein gemeinsames Verständnis der Prozesslogik und der sequentiellen, parallelen und hierarchischen Verknüpfungen zu erzeugen, wurden daher das **Prozess- und das Ebenenmodell** entwickelt (Kapitel 4.2.1.1 und 4.2.1.2). Zur Schaffung von Transparenz und Nachvollziehbarkeit hinsichtlich der auszuführenden Tätigkeiten wurden durchgeführte und noch durchzuführende **Aktivitäten** notiert und in eine Ablauffolge gebracht. Dies führte letztlich zur Entwicklung des **Vorgehensmodells** (Kapitel 4.2), anhand dessen dieses sowie die Kapitel 5.4 und 5.5 strukturiert sind.

In enger Abstimmung mit Prozessexperten erfolgte mit Hilfe der Modelle die Auswahl zu analysierender Prozesse und relevanter Kennzahlen. Unter anderem wurde eine Untersuchung der strategisch bedeutsamen Kennzahl Termintreue (TT) im Finish-Bereich der Montage durchgeführt (siehe Kapitel 2.4.2). Sie repräsentiert einen kritischen Erfolgsfaktor für die Werkleitung. In der Konsequenz ist die Kenntnis, welche Größen sowohl positiven als auch negativen Einfluss auf diese Ergebnisgröße haben und wie sie sich unter gegebenen Bedingungen zukünftig entwickeln wird, von großer Bedeutung für das Management. Folglich wurde sie als Outputgröße modelliert. Für die Auswahl einer geeigneten Anzahl einflussgebender Größen für diese Kennzahl war es hilfreich, einen Teilprozess des gesamten Montageprozesses (gemäß Ebene 1 in Abb. 4-4) auszuwählen. Der so genannte F1-Punkt, an welchem der eigentliche Zusammenbau der Fahrzeuge weitgehend beendet ist und die Qualitätsprüfung der Fahrzeuge erfolgt, eignete sich als Start dessen. Aus den in diesem Teilprozess erhobenen Kennzahlen waren diejenigen mit der höchsten

Relevanz gemäß der Prozessexperten als Input-, Stör- und Steuergrößen zu bestimmen. Dazu wurden weitere Kennzahlen aus dem Finish-Bereich ausgewählt und um operative Größen ergänzt, sodass die Analyse der Ursache-Wirkbeziehungen mit insgesamt neun Kennzahlen erfolgte (Fehler pro Einheit (FpE), Ausschleuser, Direktläuferquote (DLQ), Durchlaufzeit (DLZ), Systemfüllung, Nacharbeitsminuten (NAF1), Soll-Ist-Vergleich am F1-Punkt (SIV F1), Soll-Ist-Vergleich am F2-Punkt (SIV F2)). Gleichzeitig wurde geprüft, ob die Kennzahlen definitorisch unabhängig sind, sodass Beziehungen aufgrund formeller Abhängigkeiten ausgeschlossen sind und sichergestellt, dass sie logisch und prozessual in Zusammenhang stehen, sodass Kausalbeziehungen möglich sind. Abb. 5-2 zeigt das erzeugte **Prozessmodell**.

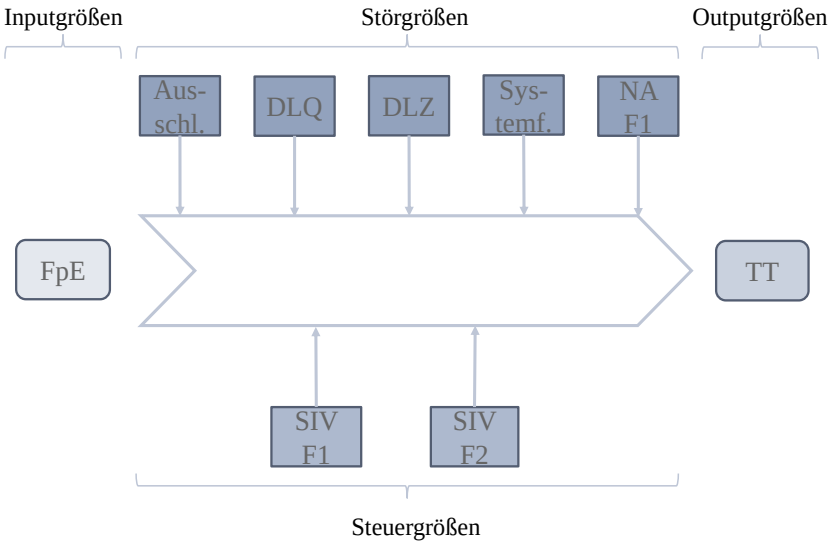

Abb. 5-2: Prozessmodell KPI Intelligence Tool v1

Der Kennzahlenauswahl schlossen sich die Datenbeschaffung und zielgerichtete, aufgabenadäquate Aufbereitung des Rohdatenmaterials an [Chamoni/Gluchowski 2017, 9]. Die Kennzahlendaten stammen üblicherweise aus unterschiedlichen Quellsystemen, sodass eine aufwendige Zusammenführung von Tabellen notwendig ist. Hinzu kommt, dass Excel als Reporting-Tool trotz häufig unzureichender Funktionalitäten immer noch vielfach angewendet wird. Daher fiel die Entscheidung darauf, die Daten aus den Quellsystemen zu exportieren und die Datengrundlage mit der Hilfe von Data Engineers in Form von flachen Tabellen (siehe dazu [Schön 2018, 73]) auf Excel- und csv-Basis bereitzustellen. Ein Vorteil dieser Lösung ist, dass dies vielen Fachanwendern vertraute Formate sind.

Die verwendeten Daten waren die Kennzahlenwerte für die Serienproduktion von Fahrzeugen mit Verbrennungsmotor auf Tagesbasis von Oktober 2012 bis Januar 2018. Der Herausforderung von zeitlicher Latenz wurde dadurch begegnet, dass die genutzten Kennzahlen entsprechend des jeweils zugehörigen Datums im Sinne eines gemeinsamen Tabellenschlüssels zusammengeführt wurden. Zwar können die Ursache-Wirkbeziehungen für Fahrzeuge, die den Prozessdurchlauf an einem Tag begonnen und am nächsten beendet haben, somit nicht klar identifiziert werden. Diese stellen jedoch nur einen sehr geringen Anteil dar und verursachen daher nur ein geringes Rauschen in den Daten. Für andere Datensätze, deren Kennzahlen über mehrere Tage oder Wochen entstanden sind, konnten in anderen Anwendungsfällen beispielsweise eineindeutige Nummern wie Teilenummern, welche im Prozess erfasst werden, oder Fahrgestellnummern genutzt werden, sodass keine Zuordnungsprobleme durch zeitliche Latenz entstanden. Zudem wurden Tage, an welchen ein Wert mindestens einer Kennzahl fehlte, gelöscht, sodass für jeden Tabellenschlüssel und jede Kennzahl ein gültiger Wert vorhanden war [Berger 2008, 10]. Der für die Analyse genutzte Datensatz beinhaltete schließlich mehr als 840 Beobachtungen je Kennzahl, sodass die Ursache-Wirkbeziehungen über einen repräsentativen Zeitraum abbildbar waren.

Bei den beschriebenen Aktivitäten in diesem und anderen Anwendungsfällen kristallisierten sich die unterschiedlichen aufgabenbezogenen **Rollen**, die die Beteiligten einnahmen, (Kapitel 4.3) stark heraus. Für die anstehende Analysephase, in welcher initial geeignete **Techniken** zu bestimmen waren, bestand beispielsweise stets ein intensiver Austausch mit Data Scientists.

5.3.2 Analyse

Nachdem die Datenbasis vorlag, waren geeignete deskriptive/diagnostische und prädiktive **Techniken** in einem **Tool** umzusetzen. Besonders im Fokus standen dabei die **Leitmerkmale** des Schaffens von Vertrauen in die Lösung durch bestmöglich interpretierbare **Techniken**, die Nachvollziehbarkeit für den Anwender durch die Vermeidung automatisierter Entscheidungen und die Erzeugung objektiver Resultate mit Hilfe der Datenanalyse.

Lineare Korrelations- und Regressionsverfahren fanden in den in Kapitel 3.5 untersuchten Ansätzen breite Anwendung, besitzen, wie in Kapitel 3.3 erläutert, eine hohe Leistungsfähigkeit und erfüllen die ausgewählten **Leitmerkmale** zu einem hohen Maß. Aus diesen Gründen wurden sie mit dem Package Statsmodels in Python implementiert. Die Visualisierung des resultierenden Abhängigkeitsgraphen erfolgte in der Deskription/Diagnostik mittels Neo4J und die Vorhersagen und Simulationen erfolgten in Excel.

5.3.2.1 Deskription/Diagnostik

Die Wahl der **Technik** für die Deskription/Diagnostik fiel auf eine paarweise Korrelationsanalyse nach Bravais-Pearson. Sie ermöglicht die Bestimmung der Stärke des linearen Zusammenhangs zweier Variablen und wird anhand folgender Formel berechnet [Cleff 2015, 101]:

$$r = \frac{\frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x}) * (y_i - \bar{y})}{\sqrt{(\frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})^2) * (\frac{1}{n}\sum_{i=1}^{n}(y_i - \bar{y})^2)}}$$

mit r = Korrelationskoeffizient nach Bravais-Pearson und $-1 \leq r \leq +1$,
n = Anzahl der Datensätze,
x und y = Attribute,
$\bar{x}$ und $\bar{y}$ = arithmetische Mittelwerte.

Liegt ein positiver linearer Zusammenhang vor, ist der Korrelationskoeffizient positiv (perfekt positiver Zusammenhang: r=1). Im Falle eines negativen linearen Zusammenhangs ist dieser negativ (perfekt negativer Zusammenhang: r= -1). Je stärker sich der Koeffizient aus dem positiven oder negativen Bereich kommend der Null nähert, desto stärker weichen die Daten von einem perfekten linearen Zusammenhang ab. Bei einem Koeffizienten (nahe) bei null geht man von einem Fehlen eines linearen Zusammenhangs zwischen den beiden betrachteten Größen aus. Häufig orientiert man sich in der Wissenschaft bei der Interpretation an folgenden Grenzwerten:

$\lvert r\rvert < 0{,}5$	schwacher linearer Zusammenhang
$0{,}5 \leq \lvert r\rvert < 0{,}8$	mittlerer linearer Zusammenhang
$r \geq 0{,}8$	starker linearer Zusammenhang.

Da jedoch für die quantitative Analyse von Kennzahlenrelationen die Differenzierung der Einflussstärken von zentraler Bedeutung ist, fiel die Wahl für die erste Version auf engmaschigere Kategorisierungen:

$\lvert r\rvert < 0{,}1$	kein linearer Zusammenhang
$0{,}1 \leq \lvert r\rvert < 0{,}4$	schwacher linearer Zusammenhang
$0{,}4 \leq \lvert r\rvert < 0{,}7$	mittlerer linearer Zusammenhang
$0{,}7 \leq \lvert r\rvert < 0{,}9$	starker linearer Zusammenhang
$r \geq 0{,}9$	sehr starker linearer Zusammenhang.

Eine wesentliche Voraussetzung für den Einsatz dieses Korrelationskoeffizienten ist, dass die Rohdaten der Kennzahlen metrisch skaliert sind. Dies war für den vorliegenden Datensatz zutreffend. Anhand der Sichtung der Streudiagramme aller möglichen Kennzahlenpaare wurde überdies sichergestellt, dass die Daten linear beschreibbar waren. Dies verdeutlicht das in Abb. 5-3 dargestellte Diagramm beispielhaft anhand der Kennzahlen Termintreue (x-Achse) und Durchlaufzeit (y-Achse).

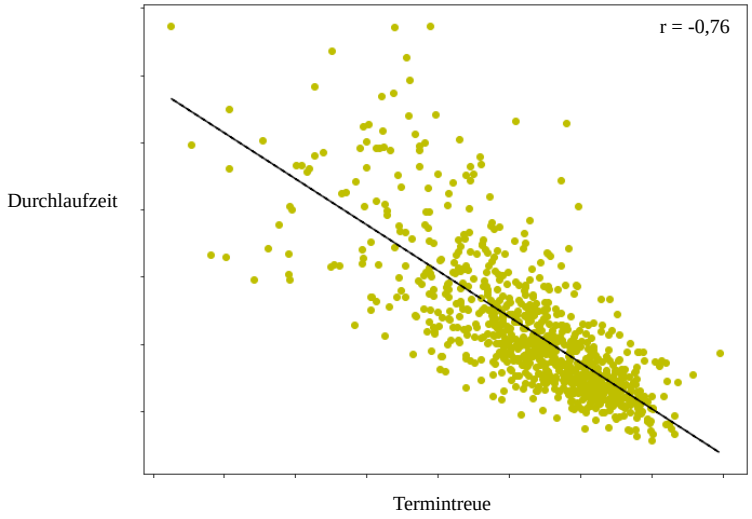

Abb. 5-3: Streudiagramm zwischen der Termintreue und der Durchlaufzeit

Diese beiden Kennzahlen, die annähernd normalverteilt sind, weisen einen Korrelationskoeffizienten von -0,76 auf. Das bedeutet, dass sie stark antikorreliert sind, die eine Kennzahl also fällt, wenn die andere steigt. Dieser Einblick wurde durch Experten bestätigt, da es prozessual schlüssig ist, dass wenn die Durchlaufzeit je Fahrzeug sinkt, eine Verbesserung der Termintreue sehr wahrscheinlich ist. So konnten anhand der vorselektierten Größen plausible Beziehungen erkannt und deren Charakteristik in Form der Stärke der Beziehung und eines positiven oder negativen Zusammenhangs untersucht werden.

Zusätzlich erfolgte mittels der Berechnung des P-Wertes eine Prüfung der Signifikanz der erkannten statistischen Beziehungen. Dieser Wert gibt an, mit welcher Wahrscheinlichkeit ein Korrelationskoeffizient gleicher Größe entstehen könnte, wenn die Nullhypothese (es existiert keine Beziehung zwischen den Variablen) wahr wäre. Autoren wissenschaftlicher Literatur nutzen häufig eine Signifikanzgrenze von 0,05, welche in dem Beispiel sehr deutlich unterschritten wird (P-Wert: 7,38E-160 < 0,05). Die Anwendung dieses Wertes ist für die Korrelationsanalyse nach Bravais-Pearson optional, da auch diese keine Kausalität beweist.

An die Berechnung der Korrelationskoeffizienten schloss sich die übersichtliche Visualisierung der Ergebnisse in einem Abhängigkeitsgraphen an (siehe Abb. 5-4). In jenem repräsentieren die Knoten die jeweiligen Kennzahlen und die Kanten die bestehenden Korrelationsbeziehungen zwischen diesen. Die Stärke der Korrelationen ist anhand der Farbe und der Breite der Kanten sowie der dargestellten Werte ablesbar. Die Pfeile an den Kanten sind mangels Aussagekraft bezüglich der Wirkrichtung zu ignorieren und sind auf die nicht anpassbare Darstellungsform von Neo4J zurückzuführen. Davon abgesehen eignet sich Neo4J jedoch, um solche komplexen Graphen zu erzeugen.

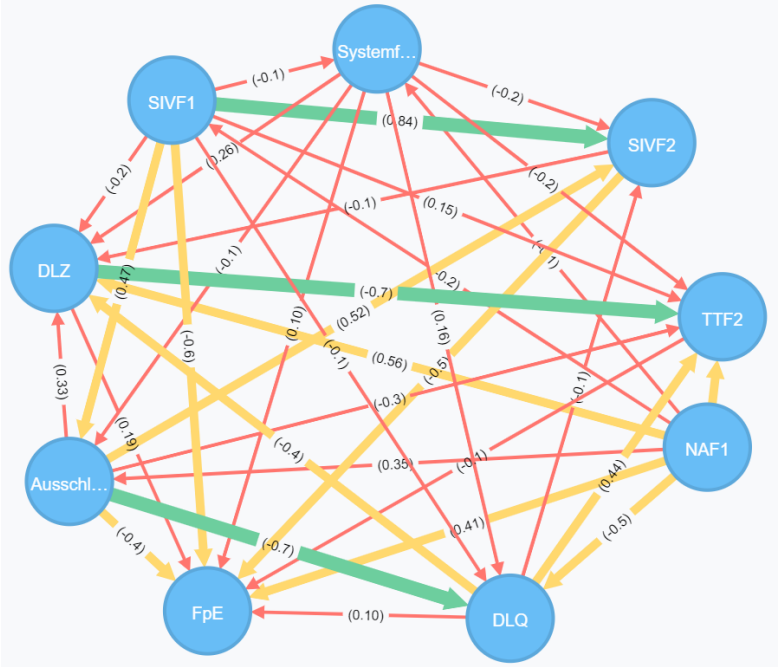

Abb. 5-4: Abhängigkeitsgraph KPI Intelligence Tool v1

Eine solche Darstellung ermöglicht die quantitative Analyse einer Vielzahl von Kennzahlen hinsichtlich ihrer statistischen Beziehungen: Es zeigte sich in der Praxis, dass diese Visualisierung für Fachanwender in wenigen Augenblicken interpretierbar und die Interdependenzen der Kennzahlen und die Komplexität, der sich das Management gegenübersieht, durch die Korrelationen zwischen den Kennzahlen nachvollziehbar waren. Anhand der Korrelationskoeffizienten besteht die Möglichkeit zu untersuchen, ob es sich um komplementäre (positive Korrelation), konkurrierende (negative Korrelation) oder unabhängige (Korrelation nahe Null) Ursache-Wirkbeziehungen handelt. Zahlreiche alternative Visualisierungen in Form von Graphen diskutiert [Hesse 2015].

Zu berücksichtigen ist, dass das dargestellte Kennzahlennetzwerk auf paarweisen Korrelationen basiert, weshalb kombinierte Ursache-Wirkbeziehungen nicht abbildbar und „What-if"-Analysen nicht möglich sind. Eine Lösung dafür beinhaltet Kapitel 5.3.2.2.

5.3.2.2 Prädiktion

Die multivariate lineare Regression ist ein sehr attraktiver Modellierungsalgorithmus aufgrund der guten Interpretierbarkeit der Koeffizienten [Kuhn/Johnson 2013, 108]. Des Weiteren besitzt diese keine Tuningparameter, die es zu optimieren gilt [Kuhn/Johnson 2013, 109] und sie ist sowohl für die Analyse kleiner als auch großer Datensätze geeignet [Finch/Hernández Finch 2017, 21]. Daher wurde in der ersten Softwareversion die in Kapitel 4.2.2.2 erläuterte lineare Ordinary Least Squares Regression implementiert. Die erzeugte Regressionsgerade ist umso besser, je näher sich die einzelnen Beobachtungspunkte an dieser befinden [Cleff 2015, 141]. Ein perfekter linearer Zusammenhang besteht also, wenn wie bei dem Korrelationskoeffizienten nach Bravais-Pearson die Beobachtungspunkte alle auf der Regressionsgeraden liegen [Cleff 2015, 141]. Gleichermaßen sinkt die Vorhersagegenauigkeit umso mehr, je stärker die Punkte verstreut sind.

Für die Anwendung der multivariaten linearen Regression muss der Datensatz einige Anforderungen erfüllen: So müssen unter anderem die metrisch skalierten Daten linear beschreibbar sein. Zudem sollten die Daten normalverteilt sein. Kommt mehr als eine unabhängige Variable in dem Modell zum Einsatz, darf keine Multikollinearität vorliegen, was bedeutet, dass diese keinen starken statistischen Zusammenhang untereinander aufweisen [Cleff 2015, 160]. Als Orientierung nennt [Field 2013, 325] Korrelationen von über 0,8 oder 0,9 als Grenzwerte für das Vorhandensein von Multikollinearität. Das Problem der Multikollinearität liegt darin, dass wenn zwei stark korrelierte Variablen in das Modell aufgenommen werden, die zweite Variable möglicherweise denselben Anteil der Varianz der abhängigen Variablen erklärt, wie die erste [Field 2013, 325]. Somit hat jede der Variablen einen Einfluss auf die abhängige Variable, wenn sie als erste zu dem Modell hinzugefügt wird, nicht jedoch bei Hinzufügen als zweite [Berger 2008, 13]. Im Umkehrschluss ist es wahrscheinlich, dass zwei unkorrelierte Variablen unterschiedliche Teile der Varianz erklären. Ist dieses Kriterium verletzt, sind Konfidenzintervalle und Signifikanztests nicht aussagekräftig [Field 2013, 311]. Außerdem sind die Regressionskoeffizienten im Fall von Multikollinearität nicht mehr sinnvoll interpretierbar [Kuhn/Johnson 2013, 108]. In der Praxis ist Multikollinearität allerdings nahezu unvermeidbar [Field 2013, 324]. Weiterhin sollte für eine gültige Anwendung linearer Regressionen die Anzahl an Datensätzen die Anzahl an Prädiktoren übersteigen [Kuhn/Johnson 2013, 108].

Für den vorliegenden Datensatz wurde die Termintreue, welche den Prozessoutput darstellt, als abhängige Variable und die übrigen acht Kennzahlen des **Prozessmodells** in Abb. 5-2 als Prädiktoren definiert. Zwar könnte der Anwender an dieser

Stelle geneigt sein, möglichst viele erklärende Variablen zu nutzen, um die Vorhersagegenauigkeit zu steigern, allerdings sollte gemäß des Konstruktionsziels von Modellen der zu untersuchende Sachverhalt mit möglichst wenigen Einflussvariablen erklärt werden [Cleff 2015, 149 f.]. Die Einbeziehung von Variablen mit keiner oder nur sehr geringer Einflusskraft auf die abhängige Variable ist eine so genannte Überparametrisierung [Cleff 2015, 150]. Das Ergebnis der multivariaten linearen Regression ist in Tabelle 5-2[28] dargestellt.

	Konst.	**Ausschleuser**	**DLQ**	**DLZ**	**NAF1**	**FpE**	**SIV F1**	**SIV F2**	**Systemfüllung**
Koeff.	92,75	0,008	0,151	-0,82	-0,001	1,17E-06	0,01	-0,009	-0,10
Normiert	0,79	0,085	0,142	-0,52	-0,164	0,456	0,24	-0,332	-0,16
P>|t|	0	0,033	0,001	0	0	0,023	0	0	0

Tabelle 5-2: Auswertung der multivariaten linearen Regression

Die Zeile unterhalb der Kopfzeile stellt die Regressionskoeffizienten der einflussgebenden Kennzahlen (unabhängigen Variablen) dar. Sie repräsentieren den mathematischen Einfluss der jeweiligen Kennzahl auf die Termintreue in Form des eingebrachten Mehrwerts [Ng/Soo 2018, 81] (siehe auch [Mertens et al. 2012, 630]). Durch die Nutzung der Koeffizienten als Gleichung ist es relativ einfach, Vorhersagen und Simulationen mit vertrauten Anwendungen wie Excel durchzuführen und die Entstehung der Ergebnisse nachzuvollziehen. So hat eine Kennzahl mit positivem Vorzeichen in der Gleichung einen positiven und mit negativem Vorzeichen einen negativen Einfluss auf die Ergebnisgröße. Eine Kennzahl mit größerem Regressionskoeffizienten hat einen stärkeren Anteil am vorhergesagten Ergebnis als eine Kennzahl mit einem kleineren Koeffizienten. Allerdings ist aus der Anwenderperspektive eine sinnvolle Interpretierbarkeit nicht gegeben, sofern die untersuchten Kennzahlen unterschiedliche Einheiten aufweisen [Ng/Soo 2018, 81]. Daher stehen in der zweiten Zeile die Regressionskoeffizienten für dieselben Kennzahlendaten, die allerdings vor der Berechnung der multivariaten Regression normiert wurden.

[28] "If your model has several predictors then you can't really beat a summary table as a concise way to report your model. As a bare minimum, report the betas, their confidence interval, significance value and some general statistics about the model (such as the R2). The standardized beta values and the standard errors are also very useful." [Field 2013, 352]

Ziel dessen ist die Analyse der relativen Einflussstärken der unabhängigen Variablen im Hinblick auf die abhängige Variable [Peral et al. 2017, 79]. Die Normierung erfolgte anhand folgender Gleichung, wobei j für die Kennzahl und i für den jeweiligen Zeitpunkt der Erfassung des Wertes stehen, sodass die Kennzahlen Werte zwischen 0 und 1 annehmen.

$$\tilde{v}_{ij} = \frac{v_{ij} - v_{jmin}}{v_{jmax} - v_{jmin}}$$

Die statistischen Anforderungen an die Daten für die Anwendung einer multivariaten linearen Regression sind sehr hoch und in der Praxis kaum zu erfüllen. Für die Analyse von Ursache-Wirkbeziehungen hinsichtlich der Termintreue konnte beispielsweise Multikollinearität nicht ausgeschlossen werden. Dadurch ist das erzeugte Modell zwar nicht optimal, aber dennoch gültig [Field 2013, 311]. Durch die vorliegende Multikollinearität liefern die Regressionskoeffizienten sowie Signifikanzwerte keine bestmögliche Informationsgrundlage. Um dennoch allgemein den Nutzen der Analyse der Regressionskoeffizienten für Datensätze, welche die Anforderungen erfüllen, zu demonstrieren, steht der folgende Absatz unter der Annahme, dass die Konformität mit den Anforderungen gewährleistet ist und die Merkmale entsprechend interpretierbar sind[29]:

Der T-Test in der untersten Zeile von Tabelle 5-2 dient der Prüfung der Signifikanz der Regressionskoeffizienten, wofür sich auch hier eine Grenze von 0,05 eignet. Demzufolge ist der Einfluss aller berechneten Regressionskoeffizienten signifikant. Allerdings erlauben diese keinen Vergleich von deren relativer Einflussstärke. Daher erfolgte die Berechnung der Regressionskoeffizienten der normierten Daten anhand derer sich ableiten lässt, wie stark jede einflussgebende Kennzahl in Relation zu den anderen auf das Ergebnis der Termintreue einwirkt. So haben die DLZ den stärksten und die Ausschleuser den schwächsten betragsweisen Einfluss dieser Auswahl an unabhängigen Variablen. Aufbauend auf diesen Werten kann das Management prüfen, ob sich eine Kennzahl besonders gut zur Steuerung der Termintreue eignet oder ob diese aufgrund mangelnder Wirksamkeit zur Reduktion der Vielzahl an Kennzahlen nicht mehr zur Steuerung dessen genutzt werden sollte. Die Tabelle 5-3 enthält die zu diesem Modell gehörigen Gütekriterien.

R^2	**F**	**P(F)**	**DW**	**Durchschnitt Termintreue**
0,628	172,5	1,08E-169	1,08	[redacted][30]

Tabelle 5-3: Gütekriterien Multivariate Lineare Regression

[29] "However, the environments in which IT artifacts must perform and the artifacts themselves may defy excessive formalism. Or, in an attempt to be mathematically rigorous, important parts of the problem may be abstracted or assumed away." [Hevner et al. 2004, 88]

[30] Aus Datenschutzgründen unkenntlich gemacht.

Zur Prüfung der Vorhersagegüte des gelernten Modells zeigt das R^2 an, wieviel Prozent der Varianz der Ergebnisgröße durch das erlernte Modell erklärbar sind, wobei ein Wert von null eine ungenügende und ein Wert von Eins eine perfekte Anpassungsgüte anzeigen [Cleff 2015, 144]. Dieses Kriterium ermöglicht zudem die Untersuchung des Erkenntnisgewinns des Hinzufügens oder Entfernens einer oder mehrerer einflussgebender Kennzahlen [Field 2013, 324]. Die ermittelten 62,8% der erklärten Varianz der Termintreue, die dieses Fallbeispiel erreicht, bilden einen stabilen Wert, lassen jedoch 37,2% unerklärt. Dies ist ein realistisches Ergebnis, da die ausgewählten einflussgebenden Kennzahlen aufgrund der Komplexität der der Termintreue vorgelagerten Prozesse und der Vielzahl an Einflüssen nur einen Teil dessen erklären können.

Der F-Test gibt Aufschluss darüber, ob das Modell eine höhere Vorhersagegenauigkeit, hat als eine Steuerung nach dem Durchschnitt der Ergebnisgröße hätte, wobei ein gutes Modell einen F-Wert größer als Eins aufweisen sollte [Field 2013, 302 f.]. Der Wert von F = 172,5 zeigt also, dass das Modell zur prädiktiven Steuerung besser geeignet ist, als eine Steuerung nach dem Durchschnittswert und ist signifikant, da P(F)=1,08E-169<0,001.

Eine weitere Anforderung an die Durchführung einer multivariaten linearen Regression ist, dass keine Autokorrelation vorliegen darf. Das bedeutet, dass die Fehlerterme untereinander nicht korrelieren dürfen [Cleff 2015, 159]. Der Durbin-Watson Test (DW) dient der Überprüfung dieses Kriteriums und nimmt Werte zwischen null und vier an [Field 2013, 311]. Der Wert zwei bedeutet, dass keine Autokorrelation vorliegt, Werte unter zwei induzieren positive und Werte größer als zwei negative Korrelationen zwischen den Fehlertermen [Field 2013, 311]. Als kritisch betrachtet [Field 2013, 311] Werte kleiner als eins oder größer als drei. Im vorliegenden Fall liegt der Wert knapp über der angegebenen Kritikalitätsgrenze und ist somit bestanden.

Zu dem Hindernis der hohen statistischen Anforderungen der linearen multivariaten Regression an die Datengrundlage kommt hinzu, dass die Interpretation der genannten Gütekriterien und statistischen Kennwerte Know-how der Anwender erfordert, welches üblicherweise in Fachbereichen nicht vorausgesetzt werden kann. Berücksichtigt man deren eigentliche Intention, die Erreichung der vorgegebenen Kennzahlenzielwerte zu prüfen, ist ein einfacher interpretierbares Kriterium vonnöten. Daher wurde zur zusätzlichen Prüfung der Vorhersagegenauigkeit des Modells eine Accuracy-Berechnung mit Hilfe einer Cross-Validation durchgeführt. Ihr Ziel ist, möglichst intuitiv darzulegen, wie hoch der Anteil korrekter Vorhersagen ist [Ng/Soo 2018, 14]. Dafür wurde das statistische Modell mit einem Teil des Datensatzes trainiert und mit den verbleibenden Daten getestet [Rao et al. 2008, 588]. Somit ist prüfbar, wie häufig das gelernte Modell eine richtige oder falsche Vorhersage bezüglich der Zielerreichung macht.

Wie in Kapitel 3.2 dargelegt, nutzen Fachanwender häufig Ampelfarben (A) zur Präsentation von Kennzahlenwerten. Diese ergeben sich für die Termintreue (TT) danach, ob sie ihre(n) definierten Grenzwert(e) (G) über- oder unterschreitet.

1. Fall: $TT \geq G, dann\ A = gr\ddot{u}n$
2. Fall: $TT \geq G_O, dann\ A = gr\ddot{u}n; G_O \geq TT \leq G_U,\ dann\ A = gelb;\ sonst\ A = rot$

Anhand dieser Ampelfarben war also zu prüfen, in wie viel Prozent der Fälle das gelernte lineare Regressionsmodell die richtige Farbe vorhersagt. Zu diesem Zweck wurden in mehreren Durchläufen die acht Quartale der Jahre 2016 und 2017 nacheinander aus dem Datensatz entfernt und als Testdatensätze definiert. Die nach der Entfernung der Testdatensätze verbliebenen Daten stellten die Lerndatensätze dar, sodass acht unterschiedliche Validierungsdatensätze jeweils bestehend aus einem Test- und einem Lerndatensatz entstanden. Darauf folgte für die Testdatensätze die Übersetzung der nummerischen Tageswerte in die Ampelfarben durch die Überprüfung der Erreichung der Zielvorgaben des jeweiligen Tages. Sodann wurden anhand der Lerndatensätze acht Regressionsmodelle erzeugt. Somit flossen keine Informationen der Testdatensätze in die zugehörigen gelernten Modelle ein, sodass diese unabhängig waren. Im nächsten Schritt wurden die erzeugten Modelle auf die Testdatensätze angewendet, indem die Tageswerte der unabhängigen Variablen in die Regressionsgleichung eingesetzt wurden und eine Vorhersage der Termintreue erfolgte. Auch hier fand ein Abgleich mit den Grenzwerten und eine Präsentation in Ampelfarben statt. Durch den Vergleich der vorhergesagten Ampelfarben mit den tatsächlichen Ampelfarben der jeweiligen Tage der Testdatensätze konnte für jede der acht Betrachtungen der prozentuale Anteil korrekt bestimmter Ampelfarben ermittelt werden. Für diese acht Anteile war anschließend der Durchschnitt ermittelbar, um die Vorhersagegenauigkeit des gesamten Modells bezüglich der Zielerreichung abschätzen zu können.

Ausgehend von dem ersten Fall, in welchem nur zwischen den Ampelfarben grün und rot der Termintreue unterschieden wurde, konnte anhand der von den Lerndatensätzen unabhängigen Testdatensätze in durchschnittlich 81,23% der Fälle die Farbe der Ampel und somit die Erreichung der Zielwerte anhand der ausgewählten einflussgebenden Kennzahlen korrekt vorhergesagt werden. Wird nun berücksichtigt, dass die Ampelfarben, wie im zweiten Fall dargestellt, auch einen gelben Status einnehmen können, liegt bei demselben Vorgehen die durchschnittliche Vorhersagegenauigkeit bei 74,48%.

Um zu prüfen, ob diese Werte gut oder schlecht sind, eignet sich ein Vergleich mit der Steuerung gemäß des Durchschnittswertes der Termintreue[31]. Übersetzt man diesen wiederum anhand des Zielwertes in eine Ampelfarbe und nutzt diese durchgehend zur Steuerung, läge man im ersten Fall in 70,1% (mit Hilfe des Modells 81,23%) und im zweiten Fall in 56,8% (mit Hilfe des Modells 74,48%) der Tage richtig. Daraus lässt sich schließen, dass, obwohl die strengen statistischen Anforderungen nicht erfüllt sind, die Vorhersage mit Hilfe eines multivariaten linearen

[31] Der Realwert darf aus Datenschutzgründen nicht genannt werden.

Regressionsmodells eine deutlich höhere Vorhersagegenauigkeit zulässt als die Steuerung gemäß des Durchschnitts der abhängigen Variablen. Somit stellt sie ein geeignetes Werkzeug zur prädiktiven Analyse von Kennzahlenrelationen dar. Weiterhin ergänzt die Anwendung dieses Algorithmus die Deskription/Diagnostik dahingehend, dass nicht nur paarweise Analysen zwischen mehreren Kennzahlen durchführbar sind, sondern die kombinierte Auswirkung mehrerer Kennzahlen auf eine Zielgröße analysierbar ist. Zudem ermöglicht er die Durchführung der durch die Anwender geforderten „What-if"-Analysen. In der anschließenden Analysephase wurden die gewonnenen Erkenntnisse durch Fachanwender interpretiert.

5.3.3 Realisierung

In diesem frühen Stadium der Software lag der Fokus der Realisierungsphase auf der Erfassung des Anwenderfeedbacks und der Potentiale, die der Einsatz von Advanced Analytics für die Analyse von Kennzahlenrelationen mit sich bringt. Eine umfassende qualitative Analyse der im vorliegenden Anwendungsfall genutzten Kennzahlen bildete eine geeignete Basis, um zu prüfen, ob die den Prozessexperten bekannten Ursache-Wirkbeziehungen belegbar waren. Dies diente der Verifizierung oder Falsifizierung der Ergebnisse der Algorithmen. Das Ergebnis des Experteninterviews ist in folgender Abbildung zusammengefasst:

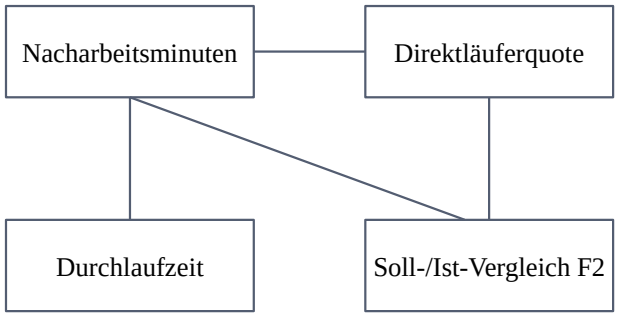

Abb. 5-5: Qualitativ erfasste Ursache-Wirkbeziehungen (in Anl. an [Wolle 2016, 65])

Demnach stehen die Nacharbeitsminuten mit der Direktläuferquote, der Anzahl der vollständig geprüften Fahrzeuge (Soll-Ist-Vergleich F2) und der Durchlaufzeit sowie die Direktläuferquote mit dem Soll-Ist-Vergleich F2 in Beziehung. Die Stärke und Charakteristik (positive/negative Beziehung) werden daraus nicht ersichtlich. Auch sind die Hintergründe der Entstehung dieses (mentalen) Modells nicht transparent, sodass für Dritte eine Einschätzung der Güte und Aktualität dessen nicht möglich ist. Betrachtet man diese Darstellung im Vergleich mit Abb. 5-4 zeigt die Kennzahl Nacharbeitsminuten (NAF1) dort eine negative mittlere Korrelation mit der Direktläuferquote, eine positive mittle Korrelation mit der Durchlaufzeit (DLZ)

und entgegen der Erwartung nach Abb. 5-5 keine Korrelation mit dem Soll-/Ist-Vergleich F2 (SIVF2). Die Beziehung zwischen der Direktläuferquote und dem Soll-Ist-Vergleich F2 ist sehr schwach und wäre aus statistischer Sicht vernachlässigbar. Allerdings liegt eine mittlere positive Korrelation zwischen der Direktläuferquote und der Durchlaufzeit vor. Diese Beziehung wurde in dem Interview nicht erfasst. Somit konnten einige bekannte Beziehungen bestätigt und zusätzliche Informationen über diese gewonnen werden (Stärke und Charakteristik der Beziehung). Weiterhin sind aufgrund abweichender Ergebnisse zwischen qualitativer und quantitativer Untersuchung einige ermittelten Beziehungen kritisch zu hinterfragen sowie unerwartet erkannte Beziehungen weitergehend zu betrachten. Also ist fachlich zu bewerten, welche Rückschlüsse diese Gegenüberstellung von implizitem Wissen und den Ergebnissen der quantitativen Analyse bezüglich der Prozesssteuerung ermöglichen. Vorhersagen oder Simulationen wären anhand der qualitativ ermittelten Ursache-Wirkbeziehungen nicht möglich.

Durch die prototypische Implementierung zeigte sich also in erster Linie, dass quantitative Analysen von operativen und gering aggregierten Kennzahlen in Kombination mit strategischen sowie hochaggregierten Kennzahlen relevante Erkenntnisse über deren Ursache-Wirkbeziehungen liefern können. Während bisher eher singuläre oder ausschließlich paarweise Betrachtungen von Kennzahlen durchgeführt werden, bieten quantitative Analysen die Möglichkeit, eine Vielzahl[32] von Kennzahlen in Beziehung zueinander zu setzen und das Ursache-Wirkgefüge umfassend zu betrachten. Ferner ist es möglich, auf Basis der Vergangenheitsdaten einer Vielzahl von Kennzahlen mit unterschiedlichen Einheiten die Zielerreichung der Ergebnisgröße mit einer deutlich erhöhten Wahrscheinlichkeit als bisher korrekt vorherzusagen, wodurch die Transformation von einer reaktiven Unternehmenssteuerung hin zu einem proaktiven Vorgehen gefördert wird. Auch erlaubt diese Art der quantitativen Analyse die Simulation geplanter Maßnahmen oder möglicher Einflüsse in Kombination miteinander, ohne in den realen Prozess eingreifen zu müssen.

Ein weiterer Aspekt ist die Unterstützung bei der Auswahl wirksamer Größen für die Prozesssteuerung anhand der Einflussstärken der Kennzahlen sowie der Analyse der statistisch positiven sowie negativen Beeinflussung [Interview 01.02.2018]. Dies ist einerseits anhand der Korrelationen im Kontext der paarweisen Betrachtungen und andererseits anhand der normierten Regressionskoeffizienten hinsichtlich einer definierten abhängigen Variablen möglich. So steigt die Effektivität der Unternehmenssteuerung, indem wirksame Maßnahmen ergriffen werden, ebenso wie die Effizienz, in dem die Maßnahme mit dem besten Kosten-/Nutzenverhältnis gewählt wird. Darüber hinaus bietet dies eine quantitative Grundlage, um zu prüfen,

[32] Ohne Hilfsmittel kann der Mensch bis zu vier Variablen kognitiv verarbeiten (siehe Kapitel 1.1). In dem in Kapitel 2.4.1 erwähnten Projekt erfolgte mittels der Sensitivitätsanalyse nach Vester die qualitative Untersuchung von 25 Variablen. Wie bei jenen paarweisen Analysen ermöglicht auch die Anwendung der statistischen Methoden theoretisch eine Verwendung beliebig vieler Variablen. Wie in Kapitel 5.3.2.2 erläutert, ist deren Anzahl jedoch aus Gründen der Praktikabilität und Aussagekraft auf ein notwendiges Minimum zu reduzieren. Dies umfasste in dem zurückliegenden Beispiel für die quantitative Analyse neun Variablen.

welche Kennzahlen überhaupt zur Steuerung sinnvoll oder ggf. redundant sind [Interview 01.02.2018]. Auf diese Weise ist die Komplexität der Kennzahlenlandschaft reduzierbar [Interview 01.02.2018]. Außerdem ist es möglich, unbekannte Beziehungen zwischen Kennzahlen, die bisher nicht bei der Steuerung des Prozesses berücksichtigt wurden, zu identifizieren und durch das versuchsweise Hinzufügen und Entfernen weiterer Kennzahlen neue Erkenntnisse bezüglich der Ursache-Wirkbeziehungen zu gewinnen. Auf Grundlage dessen kann implizites Wissen von Verantwortlichen datenbasiert fundiert und anderen zugänglich gemacht, kritisch hinterfragt oder ergänzt werden. Die somit steigende Transparenz verringert nicht nur die Komplexität für die Steuerung der Prozesse, sondern steigert gleichermaßen die Nachvollziehbarkeit von Entscheidungen.

Zu berücksichtigen ist, dass sowohl der Korrelationskoeffizient nach Bravais-Pearson, als auch die multivariate lineare Regression ausreißerempfindlich sind. Daher ist bei deren Anwendung großer Wert auf die Datenbereinigung zu legen. Weiterhin haben die Beobachtungspunkte an den äußeren Rändern von Regressionsgeraden einen stärkeren Einfluss auf deren Steigung als diejenigen in der Mitte [Cleff 2015, 153]. Die äußersten Punkte definieren überdies den so genannten Stützbereich, in welchem Beobachtungen vorliegen [Cleff 2015, 139]. Für Prognosen außerhalb dieses Bereiches muss dies unter der Annahme erfolgen, dass sich die Zusammenhänge genauso verhalten, wie innerhalb des Stützbereiches [Cleff 2015, 139].

Die erste Version des KPI Intelligence Tools erfüllte die **Leitmerkmale** aus Kapitel 3.7 wie in Tabelle 5-4 dargestellt. Positiv zu bewertende Eigenschaften sind durch eines oder mehrere „+“, neutral zu bewertende durch eine 0 und ein geringer Erfüllungsgrad der **Leitmerkmale** durch eines oder mehrere „-" repräsentiert.

Leitmerkmale	**Erfüllungsgrad**
Prozess- und hierarchieübergreifende Analysen	0
Komplementär eingesetzte Analysemethoden	+
Komparativ eingesetzte Analysemethoden	-
Objektivität der Analyseergebnisse	+
Anwenderfreundlichkeit bei der Durchführung und Interpretation	- -
Schaffen von Vertrauen in die Ergebnisse	+
Nachvollziehbarkeit der Ergebnisentstehung ohne automatisierte Entscheidungen	+ +
Wirtschaftlichkeit durch generisch einsetzbare und skalierbare Lösungen	+

Tabelle 5-4: Erfüllung der Leitmerkmale durch das KPI Intelligence Tool v1

Die Entstehung der Ergebnisse durch die Korrelationsanalyse und die lineare Regression war bei Bedarf durch die Fachanwender während der Interpretation in den Realisierungsphasen gut interpretierbar, was Vertrauen schaffte. Insbesondere die Verfügbarkeit von Streudiagrammen und die Auswertung der Regressionskoeffizienten förderten dies. Durch die logische Ähnlichkeit der beiden Algorithmen[33] waren sie für den komplementären Einsatz in der Praxis sehr gut geeignet. Darüber hinaus entschieden die Fachexperten gemäß ihrer in Tabelle 4-3 beschriebenen **Rolle**, welche Daten zu verwenden waren, begleiteten deren Bereinigung und führten die Interpretation der Informationen durch, sodass keinerlei automatisierte Entscheidungen in die Ergebnisse einflossen. Dennoch erfolgte die Bestimmung der Beziehungen ausschließlich auf Grundlage der quantitativen Daten, sodass ein hohes Maß an Objektivität und Reproduzierbarkeit der Informationen vorlag. Da außer der Auswahl der Größen und deren prozessualer Modellierung keine qualitativen Informationen in die Analyse einflossen, war die Komplexität gegenüber anderen quantitativen Ansätzen geringer. Auch reduzierte sich durch den geringeren notwendigen Personaleinsatz der Aufwand gegenüber einer qualitativen Analyse deutlich, sodass die Wirtschaftlichkeit der Analyse von Ursache-Wirkbeziehungen stieg. Dazu trug auch die generische Einsetzbarkeit der Algorithmen wesentlich bei, da diese, sofern die statistischen Anforderungen hinreichend erfüllt waren, mit geringem Aufwand für die Analyse anderer Anwendungsfälle und Datensätze einsetzbar waren, ohne die Nachvollziehbarkeit einzuschränken. Ein Vorteil insbesondere der linearen Regression ist, dass sie anders als beispielsweise Neuronale Netze oder Entscheidungsbäume keine Parametrisierungen (z. B. Anzahl Layer) benötigt.

Die generische Einsetzbarkeit erfolgte unter Hinnahme einer reduzierten Vorhersagegenauigkeit, die aber trotzdem hinreichend genau war. Der Einsatz nur eines Algorithmus für die Prädiktion entsprach außerdem nicht dem komparativen Einsatz alternativer **Techniken**. Auch wenn sich die Darstellung des Abhängigkeitsgraphen sehr bewährte, wies die erste Umsetzung insgesamt eine geringe Anwenderfreundlichkeit auf, da für den Datenimport, die Datenbereinigung und die Interpretation der Prädiktion fortgeschrittenes Know-how des Anwenders notwendig war. Somit war diese Lösung schwierig im betrieblichen Alltag einsetzbar. Prozess- und hierarchieübergreifende Analysen waren zudem zwar technisch möglich, jedoch war auch diesbezüglich die Anwenderfreundlichkeit zu steigern. Daher stand bei der Entwicklung der zweiten Version des KPI Intelligence Tools die Steigerung dessen im Fokus.

[33] „Zu beachten ist, dass Regressionsanalysen immer nur Korrelationen belegen können.“ [Gluchowski 2016, 282]

5.4 KPI Intelligence Tool v2: Analyse von Logistikkennzahlen

Die Analyse der Werkskennzahlen mit der ersten Softwareversion zeigte bereits Beiträge, die der Einsatz der Methode für die Digitale Unternehmenssteuerung leisten kann. Sie lieferte geeignete Lösungsansätze hinsichtlich der **Leitmerkmale** Vertrauen, Wirtschaftlichkeit, Objektivität, Nachvollziehbarkeit und komplementärer Methoden. Bei der Weiterentwicklung galt es, insbesondere die Anwenderfreundlichkeit hinsichtlich der Analyse und der Ergebnisinterpretation zu steigern und mehrere Algorithmen komparativ einzusetzen. Den Rahmen dafür bildete das Forschungsprojekt „Untertätige Steuerung für Prozesse“: In einer Forschungskooperation förderte die Sächsische Aufbaubank die 4K Analytics GmbH und die Professur für Anwendungssysteme des Instituts für Wirtschaftsinformatik der Universität Leipzig. Das BMW Group Werk Leipzig fungierte als assoziierter Partner. Das Projektteam beschloss neben anderen von der vorliegenden Fragestellung unabhängigen Implementierungen die Ergänzung von leicht verständlichen Visualisierungen und eines Neuronalen Netzes für die zweite Version. Die technische Umsetzung erfolgte durch die 4K Analytics GmbH, begleitet durch Data Scientists. Der Analyse ging wiederum eine Initialisierungsphase voran.

5.4.1 Initialisierung

Für die zweite Umsetzung fiel die Wahl auf die physische Logistik des Automobilwerkes, welche als Einzelprozess gemäß Ebene 1 aus Abb. 4-4 zu analysieren war. Dazu wurden auf Basis von Interviews mit zahlreichen Fachexperten, welche unterschiedliche Aufgaben in der Logistik erfüllen, die Teilprozesse der Logistik erfasst. Daraus resultierte das in Abb. 5-6 dargestellte, abstrahierte Prozessmodell. Es unterteilt den gesamten Logistikprozess in fünf Teilprozesse, anhand derer zunächst die Kennzahlenerfassung erfolgte. Die bedeutsamste Zielgröße in diesem Bereich ist die Versorgungsleistung. Sie misst, wie viele Teile zum richtigen Zeitpunkt in geeigneter Qualität am richtigen Verbauort der Montage zur Verfügung stehen im Verhältnis zu der Anzahl der Teile, die für die Produktion der geplanten Fahrzeuge benötigt waren. Folglich ist eine effiziente und effektive Steuerung dieser Kennzahl von großer Relevanz für die Verantwortlichen des physischen Logistikprozesses. Weitere gemessene Outputgrößen sind die Bereitstell- und Abrufqualität und die Kommissionierqualität.

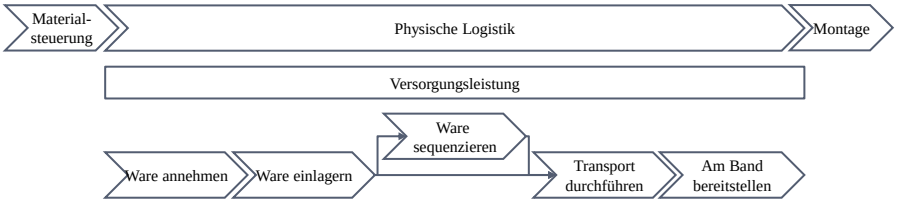

Abb. 5-6: Logistikprozessmodell

Die anhand der Teilprozesse ermittelten einflussgebenden Größen, waren teilweise zu feingranular, sodass deren Einfluss auf die Versorgungsleistung zu gering ausfiel, um aussagekräftig zu sein und die Menge an Kennzahlen zu groß für eine sinnvolle Interpretation war. Daher fiel die Wahl auf eine abstraktere Modellierung unter Einsatz des **Prozessmodells** aus Abb. 4-3. Das resultierende Modell der physischen Logistik zeigt die Startseite der zweiten Softwareversion (siehe Abb. 5-7[34]). Die gelben Felder repräsentieren die Input-, die grünen Felder die Output-, die braunen Felder die Stör- und die grauen Felder die Steuergrößen des Prozesses[35].

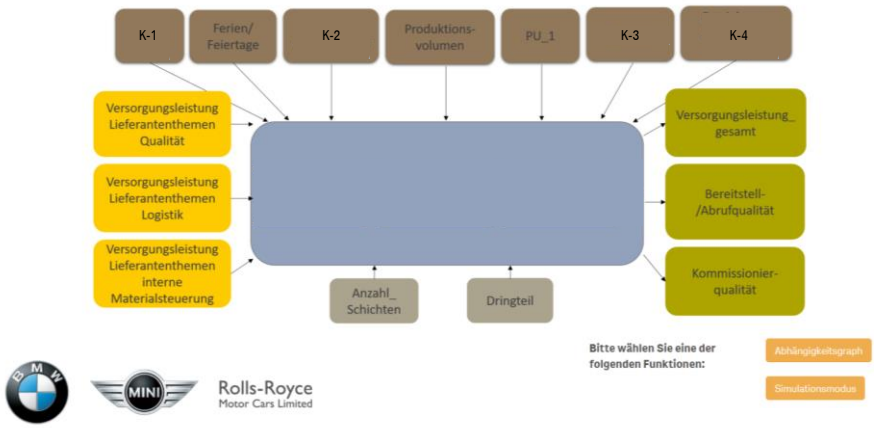

Abb. 5-7: Startseite KPI Intelligence Tool v2

[34] Aus Datenschutzgründen wurden die Kennzahlen teilweise unkenntlich gemacht.

[35] PU_1 ist ein Kürzel für die planmäßig durchgeführten Produktionsunterbrechungen des Werkes, bei welchen unter anderem Effizienzmaßnahmen zur weiteren Leistungssteigerung der Montagelinie vorgenommen werden. Dringteile sind außerplanmäßige Versorgungsaufwendungen zur Gewährleistung eines störungsfreien Montagebetriebes.

Das Modell enthält sowohl aggregierte Kennzahlen, wie auch operatives Datenmaterial und externe Daten, wie Feiertage und Ferien. Wiederum folgte die Beschaffung der Kennzahlendaten mit der Unterstützung von Data Engineers (für diesen Anwendungsfall wurden die Tageswerte des Jahres 2016 ausgewählt) sowie deren Bereinigung. Die Datengrundlage belief sich letztlich auf 284 Datensätze, die in das **Tool** importiert wurden. Da in diesem Anwendungsfall die mathematischen Algorithmen überwiegend zuvor durch die erste Version definiert worden waren, waren besonders die **Rollen** der Fachexperten und Key User sehr wichtig. Dies galt sowohl in der Initialisierungs- als auch in der Analysephase.

5.4.2 Analyse

Für die Steigerung der Anwenderfreundlichkeit lag bei der Auswahl der Software für die Implementierung das Hauptaugenmerk auf der Visualisierung der deskriptiven/diagnostischen und prädiktiven **Techniken**. Dazu kam QlikSense Desktop zum Einsatz. Die Berechnungen erfolgten mit der Statistiksoftware R als OpenCPU-R-Server auf einer virtuellen Hyper-V-Maschine.

5.4.2.1 Deskription/Diagnostik

Für die Deskription/Diagnostik erfolgte ebenfalls die Bestimmung des Korrelationskoeffizienten nach Bravais-Pearson bestimmt und die Visualisierung der Ergebnisse in einem Abhängigkeitsgraphen. Dieser ist in Abb. 5-8[36] dargestellt.

[36] Aus Datenschutzgründen wurden die Kennzahlen teilweise unkenntlich (K-1 bis K-4) gemacht. Zu Testzwecken wurden zudem weitere Variablen erzeugt, sodass die Anzahl der Knoten von der Anzahl der modellierten Kennzahlen in Abb. 5-7 abweicht (K-5 bis K-15).

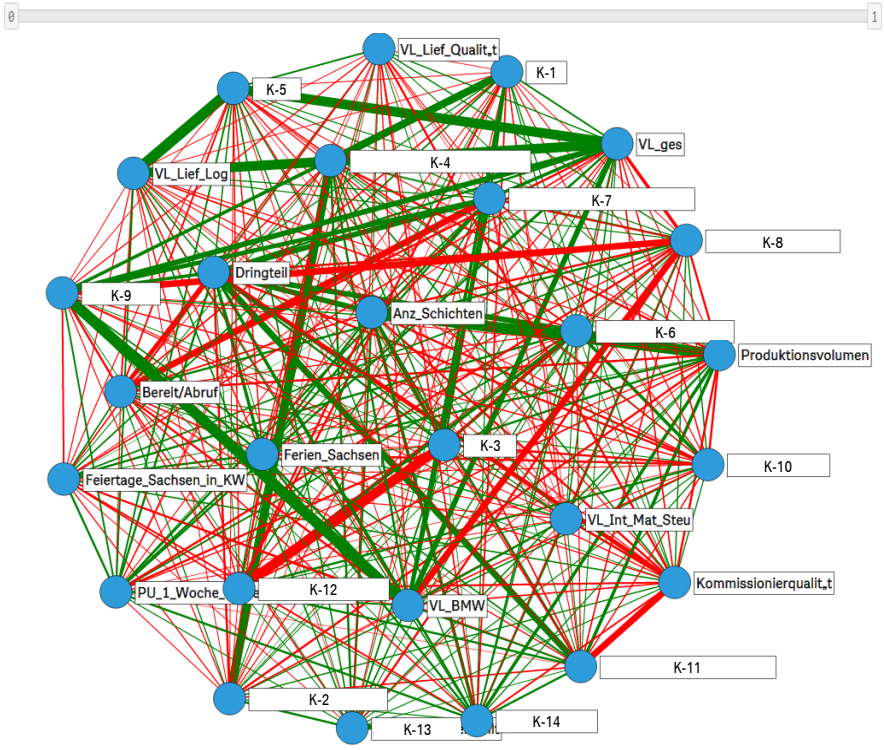

Abb. 5-8: Abhängigkeitsgraph KPI Intelligence Tool v2

Wiederum repräsentieren die Knoten die modellierten Kennzahlen und die Kanten zwischen diesen die statistischen Beziehungen. Die Stärke der Kanten richtet sich ebenfalls nach der Stärke der Relation mit dem Unterschied, dass diese nicht wie in Kapitel 5.3.2.1 kategorisiert sind (je stärker die Beziehung ist, desto breiter ist die Kante). Farblich erfolgt eine Unterscheidung nur zwischen zwei Varianten: Grüne Kanten stehen für statistisch positive und rote Kanten für statistisch negative Beziehungen. Durch ein Mouseover über den Kanten kann der nummerische Korrelationswert angezeigt werden. Darüber hinaus kann sich der Anwender durch das Klicken auf eine der Kanten das zu dem jeweiligen Kennzahlenpaar gehörende Streudiagramm anzeigen lassen.

Um die Übersichtlichkeit des Abhängigkeitsgraphen zu steigern, erlauben zwei Schieberegler, zum einen bei null, zum anderen bei eins beginnend, das Filtern der betragsmäßigen Korrelationsstärken. Abb. 5-9 zeigt beispielhaft den gefilterten Abhängigkeitsgraphen mit den Korrelationen, deren absoluter Wert sich im Wertebereich von 0,3 bis 0,95 befindet.

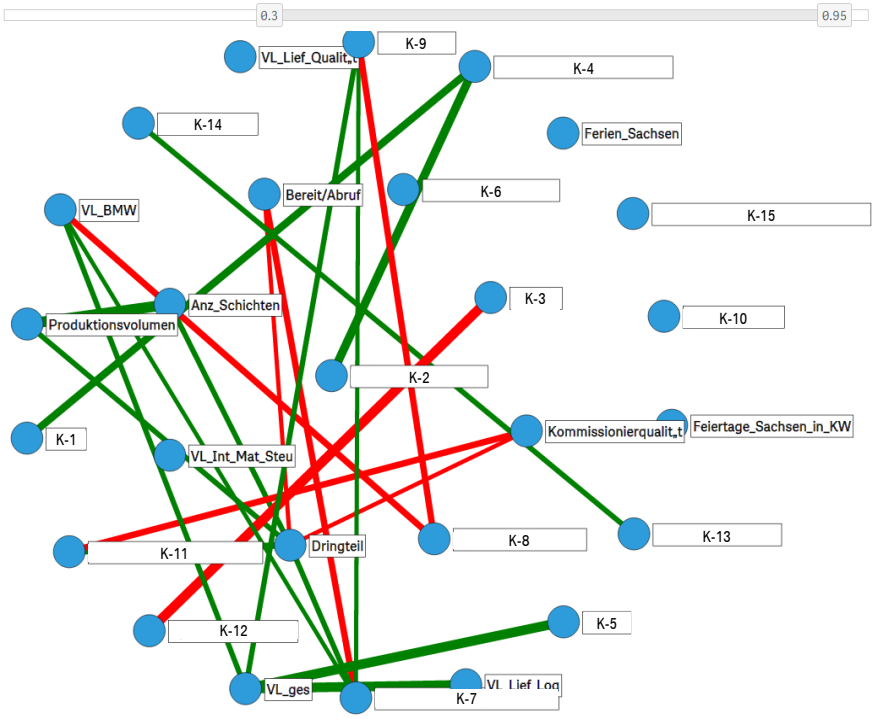

Abb. 5-9: Abhängigkeitsgraph gefiltert KPI Intelligence Tool v2

Weiterhin hat der Anwender die Möglichkeit, auf einen der Knoten zu klicken. Dadurch werden nur die Kennzahlen angezeigt, die mit der ausgewählten Kennzahl eine statistische Beziehung in dem durch den Filter definierten Wertebereich aufweisen. Da in diesem Anwendungsfall vor allem die Versorgungsleistung (VL_ges) zu untersuchen war, zeigt die Abb. 5-10 die Kennzahlen, die innerhalb der gefilterten Korrelationsgrenzen mit dieser in Beziehung stehen.

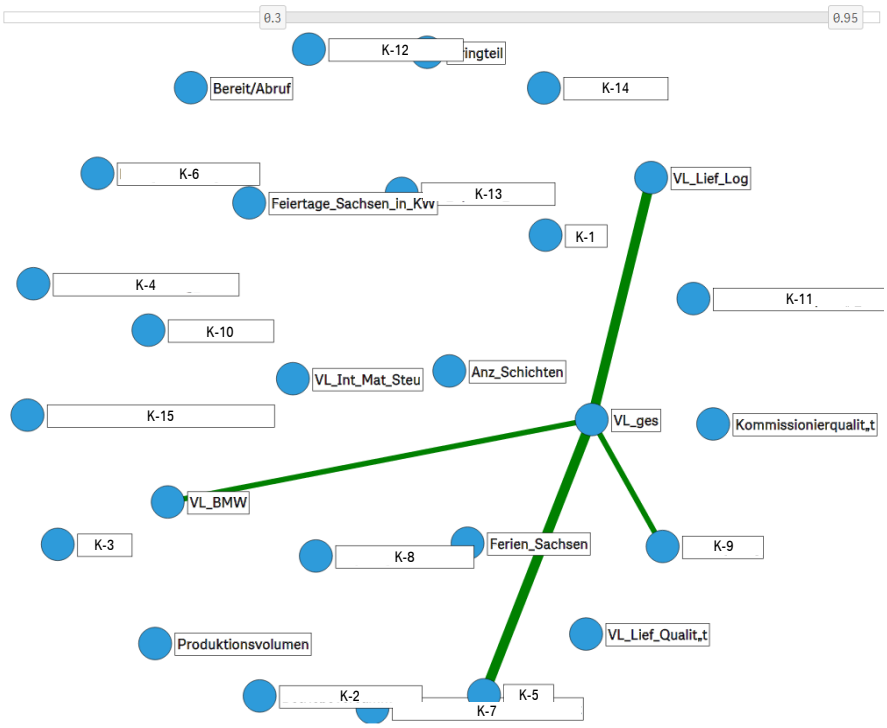

Abb. 5-10: Abhängigkeitsgraph Versorgungsleistung KPI Intelligence Tool v2

Diese verbleibenden Beziehungen sind statistisch positiv und wurden mit Prozessexperten analysiert. Ein besonderes Augenmerk lag dabei auf den Beziehungen mit der Versorgungsleistung der Logistikdienstleister (VL_Lief_Log) und mit der BMW-internen Versorgungsleistung (VL_BMW). Die Korrelation der internen Versorgungsleistung mit der gesamten Versorgungsleistung ist mit einem Wert von 0,476 deutlich geringer als die mit der Versorgungsleistung der Lieferanten mit 0,87. Erklärt wurde dies so, dass letztere einen sehr großen Anteil der Teilelieferungen Just-in-Time oder Just-in-Sequence leisten. Traten also Schwierigkeiten wie schlechte Verkehrsbedingungen auf, sodass die geplante Anlieferung behindert wurde, trat eine direkte negative Wirkung in der Montage und folglich in der Kennzahl Versorgungsleistung gesamt ein. Gab es hingegen Probleme bei der internen Versorgung, konnten benötigte Teile üblicherweise trotzdem ohne größere Verzögerungen bereitgestellt werden, da sich diese im Lager des Werkes befanden und notfalls über Sonderprozesse angeliefert wurden. Die stärkere Einflussgröße auf die Performance der gesamten Versorgungsleistung ist demnach die Versorgungsleistung der Logistikdienstleister. Anhand dieser Informationen wäre beispielsweise zukünftig zu überlegen, begrenzte Ressourcen verstärkt auf eine Verbesserung der

Kommunikation mit Logistikdienstleistern zu fokussieren, um Lieferprobleme frühzeitig zu identifizieren sowie deren Auswirkungen zu reduzieren. Dies bietet Potentiale, die Effizienz und Effektivität der Prozesssteuerung zu steigern. Dabei unterstützt ebenfalls die prädiktive Analyse des Logistik-Fallbeispiels.

5.4.2.2 Prädiktion

Auch bei der zweiten Version erfolgte die Implementierung der Prädiktion mittels einer multivariaten linearen (OLS-) Regression und zusätzlich mittels eines künstlichen Neuronalen Netzes für den komparativen Einsatz. Letzteres bildet die Funktionsweise des menschlichen Gehirns nach, um Muster zu erkennen [Chamoni/Gluchowski 2017, 12]. Ähnlich wie ein Gehirn, welches aus vernetzten Neuronen besteht, die durch den Austausch von Signalen und Reizen miteinander interagieren, werden für künstliche Neuronale Netze gewichtete Verbindungen zwischen Verarbeitungselementen ermittelt. Diese Verarbeitungselemente sind üblicherweise in verschiedenen Schichten angeordnet, sodass deren Verknüpfungen ein Netzwerk erzeugen. Die Verknüpfungen entstehen, indem eine Input-Schicht Signale der Umwelt entgegennimmt (im vorliegenden Fall Input in Form von Kennzahlendaten), diese verarbeitet und als Ausgabe an eine versteckte Schicht (hidden layer) weiterleitet. Die Verarbeitungselemente der nächsten Schicht nehmen die Ausgabe-Signale der Input-Schicht entgegen und erzeugen ihrerseits ebenfalls ein Ausgabesignal, das an die nächste Schicht weitergereicht wird [Gluchowski 2016, 281]. Insofern ist jede der versteckten Schichten eine lineare Kombination aller oder auch nur einer Auswahl der Prädiktorvariablen, wobei die lineare Kombination häufig durch nichtlineare Funktionen transformiert wird [Kuhn/Johnson 2013, 141]. Die entstehenden Koeffizienten der Gleichungen sind dabei mit klassischen Regressionskoeffizienten vergleichbar [Kuhn/Johnson 2013, 142]. Eine weitere Parallele zur linearen Regression ist, dass häufig ebenfalls die Summe der quadrierten Abweichungen minimiert wird [Kuhn/Johnson 2013, 143]. Das für das Logistikbeispiel erzeugte künstliche Neuronale Netz ist in Abb. 5-11 schematisch dargestellt. Es beinhaltet die Input-Schicht mit den Kennzahlennamen, zwei versteckte Schichten sowie die Output-Schicht mit der vorherzusagenden Kennzahl (hier: Versorgungsleistung). An den Kanten sind die jeweiligen Gewichtungen eingetragen.

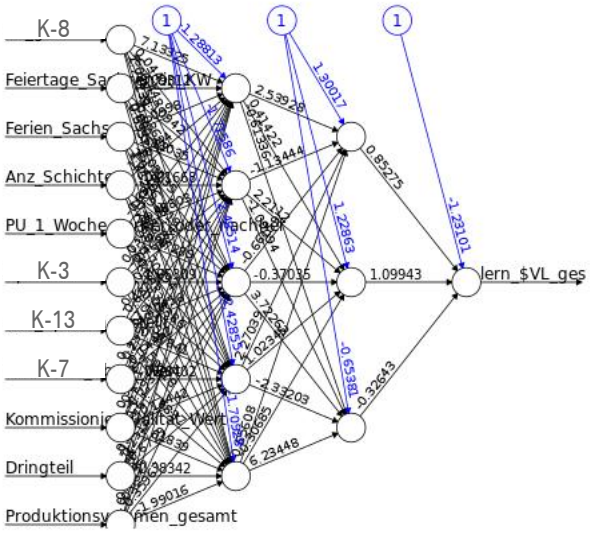

Abb. 5-11: Visualisierung Neuronales Netz KPI Intelligence Tool v2

Dass das künstliche Neuronale Netz in der Abbildung nur eine Kennzahl in der Output-Schicht enthält, verdeutlicht, dass in der zweiten Version des KPI Intelligence **Tools** für jede der drei Outputgrößen Versorgungsleistung, Bereitstell-/Abrufqualität und Kommissionierleistung je ein Modell gelernt und für jedes Modell die zwölf Input-, Stör- und Steuergrößen als Prädiktoren genutzt wurden. Das gleiche gilt für die multivariate lineare Regression. Abb. 5-12 zeigt, wie die Ergebnisse beider Algorithmen analog visualisiert und nutzbar gemacht wurden.

Abb. 5-12: Visualisierung Prädiktion KPI Intelligence Tool v2

Zunächst sind wiederum alle berücksichtigten Kennzahlen gemäß der Prozessmodelllogik dargestellt. Unter den Input-, Stör- und Steuergrößen befindet sich jeweils ein Eingabefeld. In dieses kann der Anwender Kennzahlenwerte eintragen, um anhand derer mittels der gelernten Vorhersagemodelle die Werte für die Outputgrößen zu prognostizieren. Die Messzeiger neben den Outputgrößen sowie die darin befindlichen Zahlenwerte[37] stellen die Ergebnisse dar. Der Anwender wählt dabei aus, welchen Algorithmus er verwenden möchte. Als Hilfsmittel für den Vergleich der Vorhersagegüte beider Verfahren dienen die Streudiagramme in Abb. 5-13. Sie stellen die vorhergesagten und tatsächlichen Werte in Abhängigkeit des genutzten Algorithmus für eine ausgewählte Kennzahl gegenüber. Je näher die Punkte an oder auf der Linie liegen, desto besser ist die Vorhersagegenauigkeit. Somit sind die in Kapitel 5.3 f. genannten Potentiale der Prädiktion in der Realisierungsphase bestmöglich nutzbar.

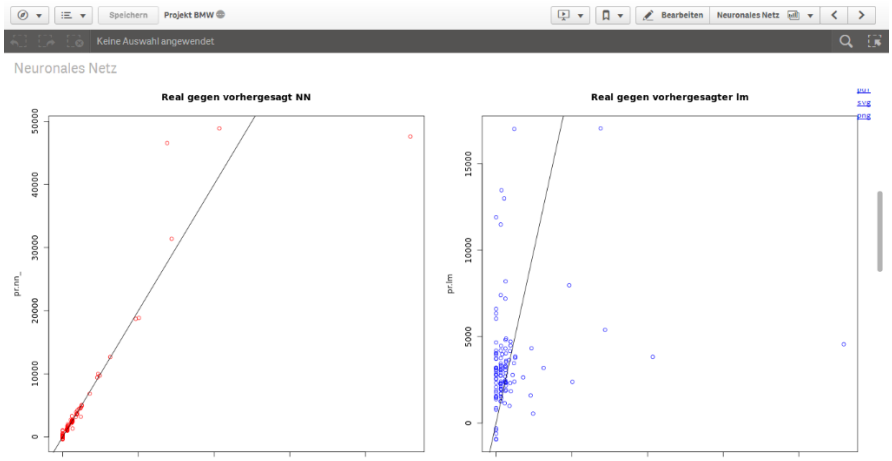

Abb. 5-13: Vorhersagegüte Neuronales Netz (links) und multivariate lineare Regression (rechts)

[37] Aus Datenschutzgründen wurden Zufallswerte genutzt.

5.4.3 Realisierung

In der Realisierungsphase der Analyse der Logistikkennzahlen untersuchte eine Vielzahl von Anwendern die erzeugten Ergebnisse und Visualisierungen. Besonders interessant war, dass sowohl Logistikspezialisten, als auch Spezialisten anderer Bereiche als der Logistik die Ergebnisse interpretieren und Schlussfolgerungen aus den statistischen Beziehungen ziehen konnten, obwohl einem Teil der Probanden das aufgabenspezifische Hintergrundwissen fehlte. Die Analyse führte zu folgender Beurteilung der Erfüllung der **Leitmerkmale**:

Leitmerkmale	**Erfüllungsgrad**
Prozess- und hierarchieübergreifende Analysen	0
Komplementär eingesetzte Analysemethoden	+
Komparativ eingesetzte Analysemethoden	0
Objektivität der Analyseergebnisse	+
Anwenderfreundlichkeit bei der Durchführung und Interpretation	0
Schaffen von Vertrauen in die Ergebnisse	-
Nachvollziehbarkeit der Ergebnisentstehung ohne automatisierte Entscheidungen	+ +
Wirtschaftlichkeit durch generisch einsetzbare und skalierbare Lösungen	+

Tabelle 5-5: Erfüllung der Leitmerkmale durch das KPI Intelligence Tool v2

Maßgeblich für die gute Interpretierbarkeit war die Verwendung des **Prozessmodells**, ebenso wie der Korrelationsgraph in der neuen Darstellungsform. Allerdings sorgte bei letzterem die Farbwahl der Kanten (grün - positive Korrelation; rot - negative Korrelation) für Missverständnisse bei einigen Fachanwendern: Da die Visualisierung mit Ampelfarben in der Kennzahlensteuerung ein geläufiges Mittel ist, wurden entsprechend rote Kanten, welche lediglich auf eine statistisch negative Beziehung hinweisen, fälschlicherweise als Einflussfaktoren, welche sich negativ auf die Zielerreichung auswirken, interpretiert. Dabei kann eine statistisch negative Beziehung durchaus gewollt und sehr gut zur Prozesssteuerung geeignet sein. Folglich war dies irreführend für Anwender, denen statistische Analysen weniger geläufig sind. Weiterhin war die zufällige Anordnung der Knoten in dem Korrelationsgraph, die von der Prozessmodellstruktur der Startseite abweicht, ein Grund für Irritationen.

Das Beibehalten der Visualisierung gemäß des **Prozessmodells** für die Prädiktion führte zu einem zügigen Verständnis der Anwender. Auch die verwendeten Messzeiger für die Darstellung der Vorhersagewerte erlangten positive Resonanz und eigneten sich insofern sehr gut, da weniger hochpräzise Vorhersagen, sondern eher Indikationen der zukünftigen Zielerreichung beabsichtigt waren.

Das Fehlen der Regressionskoeffizienten nahmen auch Anwender, denen die erste Version nicht bekannt war, (indirekt) wahr: Häufig stellten sie Fragen nach zusätzlichen Informationen bezüglich der gelernten Modelle. Auch war daher eine weiterführende Interpretation der normierten Regressionskoeffizienten nicht möglich. Obwohl die Abb. 5-13 der Abschätzung der Vorhersagegüte der beiden **Techniken** diente, kritisierten Anwender außerdem das Fehlen statistischer Gütekriterien (siehe Kapitel 5.3.2.2). Es fiel Fachanwendern daher schwer, Schlüsse aus dieser Darstellung zu ziehen und folglich Vertrauen in die Ergebnisse aufzubauen.

Bei der Analyse der Daten dieses Fallbeispiels zeigte sich außerdem, wie wichtig die kritische Betrachtung der Ergebnisse durch Fachexperten (siehe Tabelle 4-3) sein kann. Die in Kapitel 4.2.3.1 erläuterte Fehlinterpretation des Bevorstehens von Feiertagen mit einer besonders positiven Auswirkung auf die Erreichung der Zielvorgaben der Versorgungsleistung entstand in diesem Szenario.

Das Logistik-Fallbeispiel machte dennoch deutlich, dass die Zusammenführung externer Daten (z. B. Feiertage), aggregierter (z. B. Versorgungsleistung) und nichtaggregierter Daten (z. B. Produktionsvolumen) möglich ist. Wie auch in der ersten Version waren die **Leitmerkmale** der Objektivität, des Einsatzes komplementärer Methoden und der Nachvollziehbarkeit gegeben. Deutlich verbessert hat sich demgegenüber die Anwenderfreundlichkeit durch die Visualisierung mit Hilfe des **Prozessmodells**.

Hinzu kam der komparative Einsatz der multivariaten linearen Regression sowie Neuronaler Netze. Den Ergebnissen der Neuronalen Netze begegneten die Fachanwender auf unterschiedliche Weise. Bei einigen Anwendern bestand Vertrauen in diese Technologie während andere sehr skeptisch reagierten. Eine Führungskraft konstatierte, dass die Ergebnisse, mögen sie auch richtig sein, durch ihn nicht zur Entscheidungsunterstützung angewendet werden, wenn er nicht besser nachempfinden kann, wie diese zustande gekommen sind. Da Neuronale Netze aber aus vielen Schichten und „Neuronen“ sowie individuellen Aktivierungsregeln bestehen [Ng/Soo 2018, 143], ist die Entstehung von deren Ergebnissen für Fachanwender nicht interpretierbar. Somit ist deren Einsatz kritisch zu hinterfragen (siehe auch Kapitel 3.5). Die Verwendung eines Neuronalen Netzes benötigt zudem die Definition verschiedener Tuningparameter, wie beispielsweise die Anzahl der Neuronen pro Schicht sowie die Anzahl der Schichten der Verarbeitungselemente [Ng/Soo 2018, 140]. Häufig kommen drei Schichten zum Einsatz [Gluchowski 2016, 281]. Dies ist jedoch nicht als Standardeinstellung zu betrachten. Für die zweite Version wurden beispielsweise vier Schichten genutzt (siehe Abb. 5-11). Dennoch kann bei dem Einsatz von Neuronalen Netzen nicht garantiert werden, dass das optimierte Parameterset besser ist, als andere mögliche Kombinationen [Kuhn/Johnson 2013, 143]. Häufig ist zu beobachten, dass eher Overfitting vorliegt [Kuhn/Johnson 2013,

143]. Folglich ist die generische Einsetzbarkeit Neuronaler Netze schwierig zu erreichen. Ferner zeigte sich bei den Gesprächen mit Fachanwendern, dass das Konzept des Parametertuning unbekannt war [Casares 2019, 114].

Außerdem entstanden wiederum Herausforderungen dadurch, dass die erneut genutzten Korrelationskoeffizienten nach Bravais-Pearson und die multivariate lineare Regression hohe statistische Ansprüche an die Datenbasis stellen (siehe Kapitel 5.3.2.1 und 5.3.2.2). Insofern hat die generische Einsetzbarkeit nicht wesentlich verbessert. Auch die Tatsache, dass die Datengrundlage für die zweite Version weiterhin nur durch IT-Spezialisten austauschbar ist, spricht dagegen. Der zweite für die Wirtschaftlichkeit der Lösung ausschlaggebende Faktor, die Skalierbarkeit, hat sich allerdings durch den Einsatz des **Prozessmodells** und die erhöhte Anwenderfreundlichkeit verbessert. Wie in der ersten Version sind parallele, sequentielle und hierarchische Analysen zwar mathematisch möglich, allerdings ist diesbezüglich die Anwenderfreundlichkeit noch mit Hilfe einer geeigneten Visualisierung zu steigern. Das gleiche betrifft die Unterstützung beim Datenimport sowie der -bereinigung. Nichtsdestotrotz tragen die Ergebnisse zu einer verbesserten betrieblichen Anwendbarkeit der Lösung für die Digitale Unternehmenssteuerung maßgeblich bei. Ein nächster Schritt zur Beseitigung der Defizite hinsichtlich der **Leitmerkmale** erfolgte als Version Nummer drei.

5.5 KPI Intelligence Tool v3: Analyse von Kennzahlenhierarchien

Die erläuterten Anwendungsfälle, bei denen die Methode für die Digitale Unternehmenssteuerung zum Einsatz kam, machten unter anderem deutlich, welche große Bedeutung die Erfüllung der **Leitmerkmale** durch die Analysesoftware für den flächendeckenden Einsatz in Unternehmen hat. Die Version eins lieferte geeignete Lösungsansätze hinsichtlich der **Leitmerkmale** Vertrauen, Wirtschaftlichkeit, Objektivität, Nachvollziehbarkeit und komplementärer Methoden. Dessen Weiterentwicklung, die zweite Version, besaß verbesserte Eigenschaften bezüglich der Anwenderfreundlichkeit und des komparativen Einsatzes von Analysealgorithmen. Weitere Potentiale bestanden insbesondere hinsichtlich der **Leitmerkmale** Vertrauen in die Ergebnisse der verwendeten **Techniken**, der Wirtschaftlichkeit im Bereich der generischen Einsatzmöglichkeiten, prozess- sowie hierarchieübergreifender Analysen und des Datenimports und der -bereinigung, um die betriebliche Anwendbarkeit zur Unterstützung der Digitalen Unternehmenssteuerung zu fördern. Bei der Entwicklung der dritten Evolutionsstufe der Software standen demnach diese im Fokus der Aktivitäten. Die realisierte Softwarelösung stand allen Mitarbeitern der BMW Group zur Verfügung und wurde im Kontext des Einsatzes der Methode für die Digitale Unternehmenssteuerung für zahlreiche Anwendungsfälle genutzt. Diese stammten unter anderem aus den Bereichen Qualitätsmanagement in der Produktion auf strategischen sowie operativen Ebenen, der Logistik, der Pro-

duktionsstrategie und -steuerung, der Produktionsprogrammplanung, der Lackiererei und dem Kleinserien- und Prototypenbau. Bereits wenige Monate nach der Fertigstellung des **Tools** waren im Dezember 2019 über 55 Anwender sowohl aus deutschen wie auch internationalen Unternehmensstandorten registriert. Im ersten Quartal 2021 nutzten es bereits deutlich mehr als 100 Personen. Insofern liegt eine breite Basis an diversen Erfahrungswerten vor.

Die Version drei entstand wiederum als Individualsoftware im Rahmen der vorliegenden Dissertation auf Basis der Erkenntnisse der ersten beiden Versionen. Die Programmierung erfolgte gemäß den Vorgaben durch eine Entwicklungsdienstleistung eines Zulieferers im Auftrag der BMW Group. Das aus beiden Unternehmen zusammengesetzte Projektteam beinhaltete sowohl mehrere Data Scientists, Data Engineers sowie Fachexperten und Anwender (siehe Tabelle 4-3).

Klassischerweise installieren und betreiben Unternehmen ihre Hard- und Softwarelösungen in den eigenen Räumen und haben diesbezüglich mit den Herstellern über entsprechende Nutzungs- und Lizenzmodelle die Zahlung von Gebühren beispielsweise für eine gewisse definierte Anzahl von Nutzern vereinbart [Schön 2018, 444]. Dieser so genannten `On-Premises´-Nutzung steht das Cloud-Computing gegenüber, bei welchem ebenfalls gegen Nutzungsgebühren Hard- oder Softwaresysteme in einem oder mehreren fremden Rechenzentren zur Verfügung stehen, wodurch sich viele Kunden oder Unternehmen diese Infrastruktur und Services teilen können [Schön 2018, 444]. Derartige offene und skalierbare Lösungen bieten gemäß [Diekmann/Sümmchen 2016, 32] den besten Investitionsschutz. Schließlich ermöglicht das zentrale Management der IT-Leistungen ein kostengünstigeres Angebot aufgrund der Skaleneffekte [Schön 2018, 444]. Für das Reporting und die Planung von Unternehmen kommt ein reines Public-Cloud-Modell wegen der hohen Sensibilität der Daten und den folglich strengen Datenschutzanforderungen jedoch nicht in Frage [Schön 2018, 447]. Als hybride Variante bieten sich daher Private Clouds an, bei welchen der Kunde Transparenz hinsichtlich der physikalischen Ansiedlung und Verteilung der zur Verfügung gestellten IT-Ressourcen (wie Standort des Servers in einem fremden Rechenzentrum oder dem eigenen Unternehmen) erhält [Schön 2018, 446]. Um zukünftig einen flächendeckenden Einsatz der Software im Unternehmen zu erreichen und die Eintrittsbarriere für dessen Nutzung möglichst gering zu halten, wurde vorliegend ein solcher Private Cloud-Ansatz gewählt. Als Analytics-Komponente dienten verschiedene Bibliotheken aus Python (u.a. Pandas, Numpy, Scikitlearn) und für die Visualisierungen die JavaScript library D3.js. Die implementierten Funktionen zeigt folgender Anwendungsfall.

5.5.1 Initialisierung

Die mit der Softwareversion 1 untersuchten Kennzahlen sind sehr wichtig für die Steuerung der Fahrzeugwerke der BMW Group (siehe Kapitel 5.3). Zu diesen gehören unter anderem die Nacharbeitsminuten (NAF1), die Direktläuferquote (DLQ) und die Fehler pro Einheit (FpE), auf welche die Montageverantwortlichen ihr Hauptaugenmerk legen. Daher prüfen sie ihren eigenen Beitrag zur Zielerreichung dieser Kennzahlen, aber auch die Beiträge interdependenter Prozesse [Interview 25.04.2019b]. Kennzahlen der anderen Prozesse berücksichtigen sie in dieser Betrachtung nicht [Interview 25.04.2019b], sondern ausschließlich die Auswirkungen der Prozessoutputs auf die Montagekennzahlen. In einer so genannten Zielwerttabelle werden mit den für die Erreichung der Werksziele besonders bedeutsamen Aufgabenbereichen (exemplarisch A1 - A6), wie beispielsweise der Entwicklung, Lackiererei, Einkauf und Lieferanten, Vorgaben für diese Produktionskennzahlen in Form von Verteilungsschlüsseln auf Basis impliziten Wissens jeweils für das gesamte Jahr vereinbart. Bei Ereignissen, die die Kennzahlen negativ beeinflussen, erfolgt eine Prüfung durch Experten, welcher Prozess ursächlich dafür war und eine entsprechende Dokumentation. Insofern setzt sich jede der drei Größen auf Werksebene aus deren Pendants auf der nächsten Hierarchieebene zusammen (z. B. FpE_Werk besteht aus FpE_A1 bis FpE_A6[38]) [Interview 17.04.2019].

Die unterschiedlichen Kennzahlen sind untereinander definitorisch unabhängig, stehen jedoch prozessual in Zusammenhang. Seitens der Entscheidungsträger besteht großes Interesse in der Analyse der Ursache-Wirkbeziehungen der Kennzahlen. So kann zum Beispiel ein Fehler in der Entwicklung deutlich schwieriger zu beheben sein, als die Berichtigung eines Lackfehlers und damit Fehler in verschiedenen Prozessabschnitten sehr unterschiedliche Nacharbeitsaufwände verursachen und sich unterschiedlich in den Kennzahlen niederschlagen [Interview 17.04.2019]. Daher dient im Folgenden das Werk auf Werkleiterebene, anhand der drei Kennzahlen NAF1, DLQ und FpE als Outputgrößen modelliert, als Anwendungsfall (Abb. 5-14). Diese Definition erfolgte durch einen Fachexperten, welcher gleichzeitig auch die **Rolle** eines Data Engineers erfüllte (siehe Kapitel 4.3).

[38] Analog für die übrigen Kennzahlen.

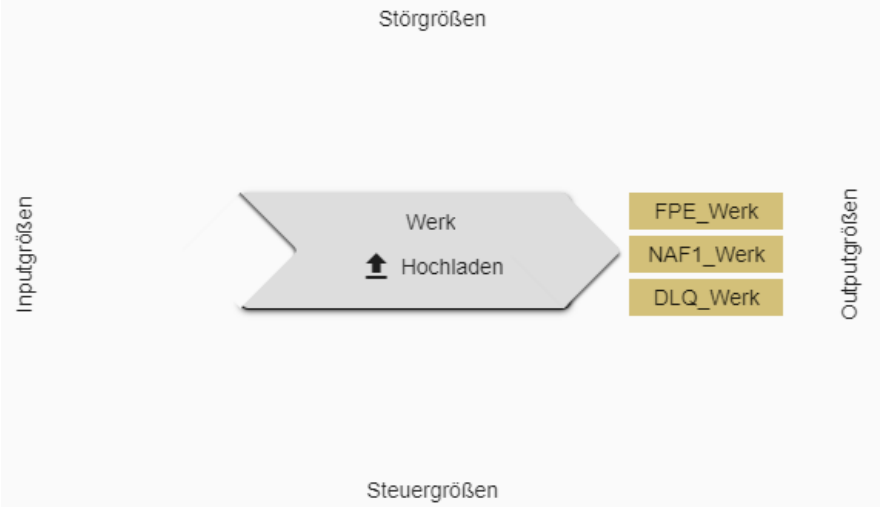

Abb. 5-14: Prozessmodell Werk

Anschließend waren die Subprozesse für die Analyse der hierarchischen Ursache-Wirkbeziehungen zwischen den Kennzahlen der Aufgabenbereiche und des Gesamtwerks gemäß der Ebene 4 (siehe Abb. 4-7) zu modellieren. Die Ergänzung der teilprozessspezifischen NAF1, DLQ und FpE als Outputgrößen ergab folgendes **Ebenenmodell** (siehe

Abb. 5-15). Das verwendete Datenset beinhaltete die Kennzahlenwerte für die Serienproduktion von Fahrzeugen mit Verbrennungsmotor auf Tagesbasis für den Zeitraum von Januar 2018 bis Mitte April 2019 und umfasste 374 Werte je Kennzahl und Prozess.

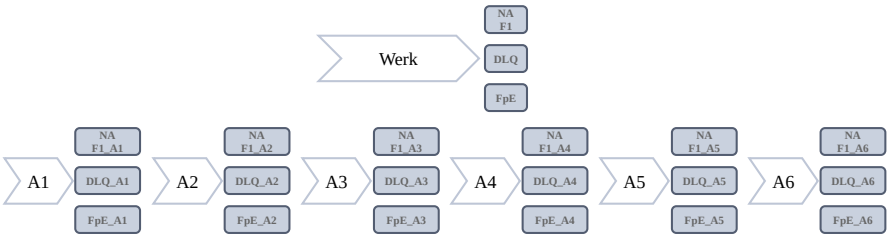

Abb. 5-15: Hierarchisches Prozessmodell gemäß Zielwerttabelle

Der Datenimport erfolgt bei der dritten Version per Excel, csv-Datei oder per API-Schnittstelle als JSON-Datei. Dazu zeigt es die ausgewählte Datei im **Tool** an und fordert den Anwender auf, eine Spalte als Tabellenschlüssel zu definieren, welche für den Join[39] mehrerer Tabellen heranzuziehen ist. Der Tabellenschlüssel kann verschieden beschaffen sein (z. B. Datum, Fahrgestellnummer), muss die Kennzahlen jedoch eineindeutig einander zuteilen können. Im vorliegenden Anwendungsfall diente dazu das Tagesdatum. Anschließend sind, wie in Abb. 5-16 dargestellt, die Tabellenspalten mit relevanten Kennzahlendaten durch den Nutzer auszuwählen, indem er durch ein Dropdown-Menü die jeweilige Kennzahl nach den Größenarten (Input-, Output-, Stör-, Steuergröße) klassifiziert. Enthält die Spalte kategorische Werte, ist dies durch das Setzen eines Häkchens deutlich zu machen. Kategorische Variablen sind vorliegend sowohl binäre Variablen, die nur zwei mögliche Werte annehmen können (z.B. Feiertag: ja oder nein) als auch Variablen mit mehr als zwei Optionen, die ordinal skaliert sind (z.B. rote/gelbe/grüne Ampelfarbe einer Kennzahl).

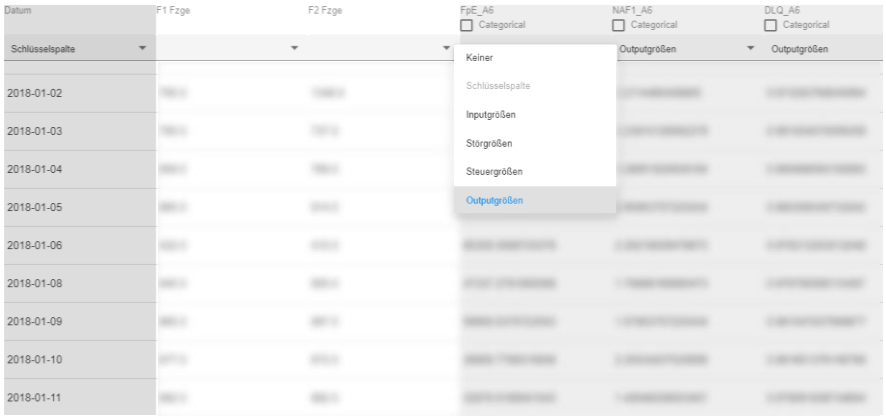

Abb. 5-16: Tabellenansicht KPI Intelligence Tool v3

Für jeden modellierten Prozess ist in dem **Tool** ein Prozess mit den zugehörigen Kennzahlen anzulegen. Das Anwählen der verfügbaren Schaltflächen definiert, ob die Prozesse in sequentieller, paralleler oder hierarchischer Beziehung zueinander stehen (siehe Abb. 0-3 im Anhang). Ein vorgelagerter Prozess wird durch Auswahl der linken, ein nachgelagerter Prozess durch die Auswahl der rechten Schaltfläche mit dem „Plus“ hinzugefügt. Ergänzt der Anwender einen zweiten Prozess mit der Schaltfläche über oder unter dem bestehenden Prozess, erfolgt die Interpretation als

[39] Um ein hohes Maß an Konsistenz zu erreichen, wird ein Inner-Join durchgeführt.

Parallelprozess. Beim Einfügen von mindestens drei Prozessen, von denen mindestens ein Prozess über eine der Schaltflächen über oder unter den Prozessen ergänzt wurde, liegt ein hierarchisches **Prozessmodell** vor.

Die Datenbereinigung erfolgt für alle importierten Kennzahlen anwenderfreundlich innerhalb der Anwendung. Dies ist unabhängig von der Festlegung der zu untersuchenden Ebenen und geschieht durch die paarweise Selektion der Kennzahlen, die sodann als Streudiagramme angezeigt werden. Durch anhaltendes Drücken der Maustaste und Ziehen über die entsprechenden Punkte kann der Anwender Ausreißer markieren und löschen. Dies ist in Abb. 5-17 beispielhaft zu sehen. Somit ist die Prozessmodellierung beendet und ein bereinigter Datensatz liegt vor, sodass die Analysephase folgen kann.

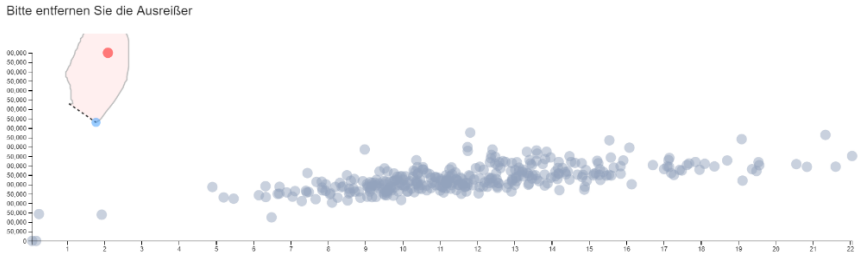

Abb. 5-17: Ausreißerbereinigung KPI Intelligence Tool v3

5.5.2 Analyse

Das KPI Intelligence Tool Version 3 beinhaltet ein breites Spektrum an Analysefähigkeiten, die dem Anwender zur Verfügung stehen. Es bietet wiederum deskriptive/diagnostische sowie prädiktive Funktionalitäten, welche zusätzlich gemäß der in Kapitel 4.2.1.2 dargelegten **Prozessebenen** analysierbar sind (siehe Tabelle 5-6). Anhand der möglichen Kombinationen (A-J) verläuft die Untersuchung der Kennzahlen aus der Zielwerttabelle. So repräsentiert eine Analyse gemäß der Kombination A die Anwendung einer deskriptiven/diagnostischen Methode anhand der **Prozessmodellierung** nach Ebene 1.

	Deskription/Diagnostik	Prädiktion	
		Ridge Regression	Random Forrest
Ebene 1	A	E	F
Ebene 2	B	G	H
Ebene 3	C		
Ebene 4	D	I	J

Tabelle 5-6: Analysefähigkeiten des KPI Intelligence Tools v3

5.5.2.1 Deskription/Diagnostik

Für die Erzeugung der Abhängigkeitsgraphen diente in den beiden ersten Softwareversionen der Korrelationskoeffizient nach Bravais-Pearson. Auch wenn auf diese Weise relevante Erkenntnisse gewonnen wurden, ist dessen generische Einsetzbarkeit aufgrund der hohen Anforderungen an die Datensätze für die Erzeugung aussagekräftiger Ergebnisse (z. B. Linearität des Zusammenhangs) eingeschränkt. Wie in Kapitel 4.2.2.1 angesprochen, ist der Rangkorrelationskoeffizient nach Spearman eine Alternative. Dieser bestimmt ebenfalls den paarweisen Zusammenhang zwischen Variablen. Allerdings ist dafür nicht entscheidend, ob die Daten einen linearen, sondern ob sie einen monotonen Zusammenhang aufweisen [Cleff 2015, 102]. Dies bedeutet, dass die Beobachtungswerte auf in der Steigung variierenden doch stets ansteigenden beziehungsweise stets fallenden Kurven liegen [Cleff 2015, 102]. Daher sind sowohl lineare als auch nicht-lineare Beziehungen analysierbar. Ähnlich verhält es sich bezüglich der notwendigen Skalierungen: Während der Korrelationskoeffizient nach Bravais-Pearson metrische Daten benötigt, ermöglicht Spearman den Umgang mit metrischen, aber auch ordinal skalierten Daten. Darüber hinaus ist der Rangkorrelationskoeffizient robuster, also weniger ausreißerempfindlich. Insofern ist dieser für die Steigerung der generischen Einsetzbarkeit der Lösung besser geeignet als der Korrelationskoeffizient nach Bravais-Pearson.

Die Formel von Spearmans ρ (Rho) weist Ähnlichkeiten zu der des Korrelationskoeffizienten nach Bravais-Pearson auf. Der zentrale Unterschied ist, dass anstelle der Originalwerte für x beziehungsweise y deren kalkulierte[40] Rangwerte R(x) beziehungsweise R(y) sowie die durchschnittlichen Ränge $\overline{R(x)}$ beziehungsweise $\overline{R(y)}$ genutzt werden [Cleff 2015, 106 f.]:

[40] Für eine detailliertere Herleitung siehe [Cleff 2015, 102 ff.]

$$\rho = \frac{\frac{1}{n}\sum_{i=1}^{n}\left(R(x_i) - \overline{R(x)}\right) * \left(R(y_i) - \overline{R(y)}\right)}{\sqrt{\left(\frac{1}{n}\sum_{i=1}^{n}\left(R(x_i) - \overline{R(x)}\right)^2\right) * \left(\frac{1}{n}\sum_{i=1}^{n}\left(R(y_i) - \overline{R(y)}\right)^2\right)}}$$

mit ρ = Rangkorrelationskoeffizient nach Spearman und $-1 \leq \rho \leq +1$,

n = Anzahl der Datensätze,

R(x) und R(y) = Rangwerte,

$\overline{R(x)}$ und $\overline{R(y)}$ = arithmetische Rangwerte.

Auch das ρ nimmt Werte zwischen -1 (perfekter negativer Zusammenhang) und 1 (perfekter positiver Zusammenhang) an. Je stärker es sich einem Wert von null nähert, desto stärker ist die Abweichung von den perfekten Zusammenhängen. Somit erlaubt es ebenfalls die Analyse von Daten hinsichtlich komplementärer, konkurrierender oder unabhängiger statistischer Zusammenhänge. Die Bestimmung der Signifikanz der Ergebnisse des Rangkorrelationskoeffizienten folgt derselben Logik wie die des Koeffizienten von Bravais-Pearson. Die dritte Version des KPI Intelligence **Tools** zeigt nicht-signifikante Werte in Klammern an (siehe hierzu Kapitel 5.3.2.1). Eine Klassifizierung der Korrelationsstärken erfolgt auch in dieser nicht. Abb. 5-18 zeigt beispielhaft den Abhängigkeitsgraphen der modellierten Outputgrößen für die Werksebene in Form eines Einzelprozesses gemäß Feld A der Tabelle 5-6.[41]

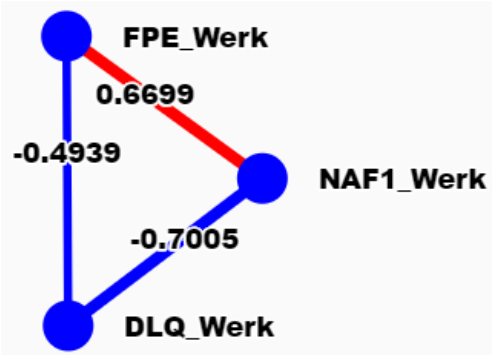

Abb. 5-18: Korrelationsgraph Zielwerttabelle Werksebene

[41] Eine Darstellung eines Abhängigkeitsgraphen mit Input- Output-, Stör- und Steuergrößen befindet sich im Anhang in Abb. 0-4.

Die Art der Darstellung in der dritten Implementierung hat sich bezüglich der beiden vorangegangenen Implementierungen wenig verändert, da sie sich bewährt hat. Wiederum visualisieren die Knoten die einzelnen Kennzahlen, allerdings mit dem Unterschied, dass die Knoten gemäß der **Prozessmodellierung** angeordnet sind, um die Einordnungen als Input-, Output-, Stör- und Steuergrößen beizubehalten (sofern diese modelliert wurden[42]) und die Interpretation zu vereinfachen. Ferner repräsentieren die Kanten die errechneten paarweisen statistischen Beziehungen zwischen den Größen. Ebenso ist die Stärke der Korrelationen anhand der Breite der Kanten sowie der ρ-Werte ablesbar. Die neue Farbgebung repräsentiert Kanten mit einer positiven Korrelation in rot und mit einer negativen Korrelation in blau. Dies vermeidet den direkten Bezug zur Ampelfarbenlogik und die unterbewusste Kategorisierung in „gute“ und „schlechte“ Beziehungen bei der Interpretation, wie sie teilweise bei der zweiten Version stattfand. In der Darstellung zeigt sich, dass die Kennzahlen DLQ, FpE und NAF1 auf Werksebene mittlere bis starke Korrelationen aufweisen. Dies ist prozessual schlüssig, da Fehler Nacharbeiten verursachen und Fahrzeuge, bei denen Nacharbeiten durchgeführt wurden, keine Direktläufer sind.

Ein Mouseover über den Kanten bewirkt, dass diese optisch hervorragen, um zu symbolisieren, dass eine Interaktion möglich ist. Klickt der Anwender auf eine der Kanten, öffnet sich ein Streudiagramm (siehe Abb. 5-19) der beiden miteinander korrelierten Kennzahlen und grundlegende statistische Angaben (Minima, Maxima, Abweichung, Durchschnittswerte) stehen zur Verfügung.

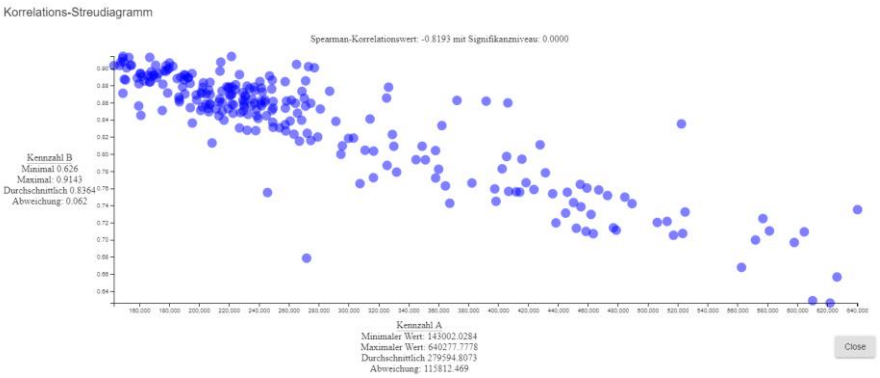

Abb. 5-19: Streudiagramm von Kennzahlen KPI Intelligence Tool v3

Dies fördert die Transparenz für den Nutzer, der somit besser einschätzen kann, wie die Korrelationswerte zustande gekommen sind und hilft bei der Interpretation von deren Güte. Auch die Möglichkeit, die absoluten Werte der Korrelationen bei null und eins beginnend zu filtern oder auf einen der Knoten zu klicken, sodass nur die

[42] Siehe als Beispiel Abb. 0-4.

Kanten angezeigt werden, die mit dieser Kennzahl statistische Beziehungen aufweisen, ist zur Steigerung der Übersichtlichkeit der Darstellung wie in der zweiten Umsetzung weiterhin gegeben.

Beabsichtigt ein Anwender die Analyse sequentiell verknüpfter Prozesse gemäß Feld B der Tabelle 5-6, kann er durch Klick auf einen der kleinen Pfeile mit einem Plus vor oder hinter dem modellierten Prozess einen oder mehrere vor- oder nachgelagerte(n) Prozess(e) ergänzen. Dafür ist es möglich, entweder einen in einem anderen Projekt bestehenden Prozess zu importieren oder einen zusätzlichen Prozess, wie in Kapitel 5.5.1 erläutert, zu modellieren. Abb. 5-20 zeigt dies beispielhaft für zwei Prozesse, die wiederum ausschließlich durch ihre Outputgrößen repräsentiert werden.

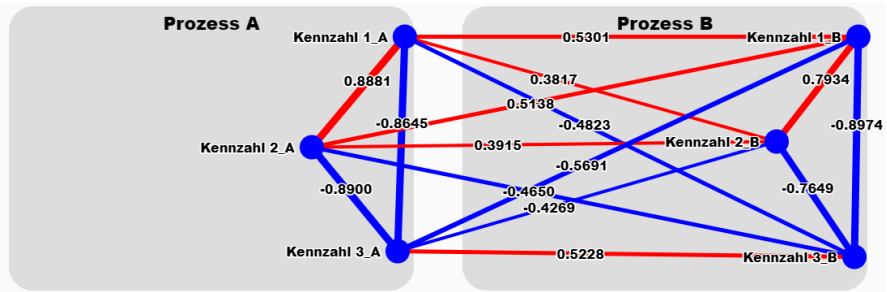

Abb. 5-20: Sequentielle Prozesse KPI Intelligence Tool v3

In dem sequentiellen Abhängigkeitsgraph erfolgt die Berechnung der paarweisen Korrelationen zwischen allen modellierten Input- und Outputgrößen; sowohl innerhalb der einzelnen Prozesse als auch prozessübergreifend. Auf diese Weise zeigen sich interprozessuale Abhängigkeiten sequenziell verschalteter Aufgabenbereiche. Fachlich bestätigten Prozessexperten, dass der Output von Prozess A Einfluss auf die Leistungserbringung von Prozess B hat.

Statistische Abhängigkeiten können auch zwischen parallel stattfindenden Prozessen bestehen. Für eine Analyse gemäß Feld C der Tabelle 5-6, wird ein paralleler Prozess durch Anklicken der kleinen Pfeile über oder unter dem modellierten Prozess zu einem einzelnen Prozess ergänzt. In diesem Fall berechnet die Anwendung alle paarweisen Korrelationen zwischen den Input-, Output-, Stör- und Steuergrößen beider Prozesse sowie prozessübergreifend und stellt diese im Abhängigkeitsgraphen dar.

Die vierte Ebene kombiniert und ergänzt die Analyse sequentieller sowie paralleler Prozesse (Ebenen 2 und 3). Damit zielt sie auf die Analyse hierarchischer Ursache-Wirkbeziehungen ab und beabsichtigt die Untersuchung der Wirksamkeit des Kennzahlensystems. Dabei liegt die Hypothese zugrunde, dass der Verantwortliche des Superprozesses die Zielvorgaben mit den Verantwortlichen der Subprozesse

derart vereinbart, dass deren Zielerreichung die Zielerreichung des Superprozesses sicherstellt. Daher berechnet die Anwendung die Korrelationen für die Outputgrößen der modellierten Prozesse. Auf den Anwendungsfall der Zielwerttabelle übertragen, ist folglich durch eine Betrachtung gemäß Feld D der Tabelle 5-6 zu prüfen, inwiefern die ausgewählten Prozesse die Montage und die Werkskennzahlen beeinflussen. Zur Steigerung der Übersichtlichkeit sind in Abb. 5-21 nur die Prozesse A3 und A4 sowie die Werksebene dargestellt, da nur deren Outputgrößen Korrelationen mit absoluten Werten in dem durch den Fachanwender fokussierten Wertebereich zwischen 0,5 und 1 vorweisen.

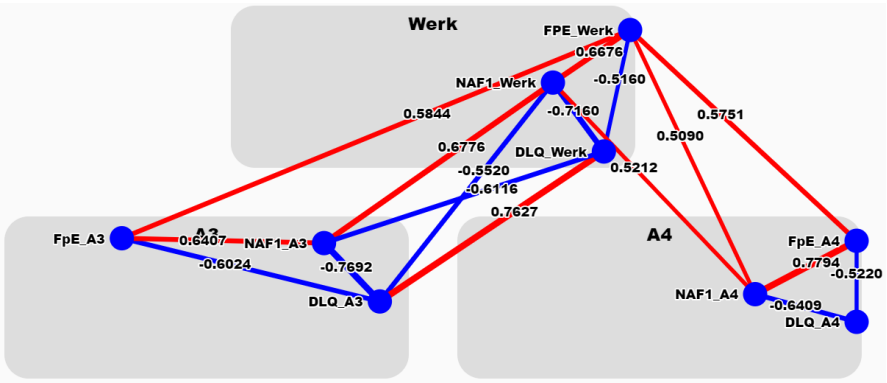

Abb. 5-21: Hierarchischer Abhängigkeitsgraph KPI Intelligence Tool v3

Hinsichtlich des Prozesses A3 war dieses Ergebnis dem Verantwortlichen für die Zielwerttabelle zufolge zu erwarten. Gemäß des qualitativ definierten Verteilungsschlüssels wäre hingegen von einer stärkeren Korrelation zwischen den Kennzahlen der Prozesse A2 und A6 mit den Werkswerten auszugehen gewesen. Stattdessen weist A4 unerwartet starke Korrelationen mit diesen auf. Eine detailliertere Analyse folgt in der Realisierungsphase in Kapitel 5.5.3.

Der Fachanwender äußerte, dass die Korrelationsanalyse wertvolle Erkenntnisse für die zukünftige Gestaltung des Verteilungsschlüssels liefert, diese jedoch durch weitere analytische Verfahren, wie beispielsweise einer Regressionsrechnung zu ergänzen ist [Interview 17.04.2019]. Diese schließt sich im nächsten Kapitel an.

5.5.2.2 Prädiktion

Der Einsatz der multivariaten linearen Regression hat sich in der Praxis, in den in Kapitel 3.5 diskutierten wissenschaftlichen Ansätzen sowie in den beiden ersten Versionen bewährt. Dennoch weist diese Methode auch Schwächen für den Einsatz in der kennzahlenbasierten Unternehmenssteuerung auf. Darunter fallen die hohe Ausreißerempfindlichkeit, die Einschränkung auf metrisch skalierte Variablen und das Problem der Modellgüte bei vorhandener Multikollinearität. Eine Möglichkeit, das Ausmaß der Multikollinearität zwischen Prädiktorvariablen in einem Datensatz zu bestimmen, ist der Variance Inflation Factor (VIF). Dieser prüft für jeden einzelnen Prädiktor die Korrelationsfunktion mit den übrigen gewählten Prädiktoren [Kuhn/Johnson 2013, 108]. Liegt Multikollinearität in einem Datensatz vor, ist eine Lösung zur Vermeidung, die Menge der Prädiktoren um betroffene korrelierende Größen zu reduzieren [Rao et al. 2008, 593]. Für eine solche Reduktion eignen sich diverse Methoden, wie zum Beispiel die ´stepwise multiple linear Regression´. Einige Vorteile, die sich daraus ergeben, sind, dass sich die normierten Koeffizienten, wie in Kapitel 5.3.2.2 erläutert, interpretieren lassen und die Komplexität der Regressionsgleichung reduziert wird. Zudem beschleunigt die geringere Datenmenge die Berechnung des Modells, reduziert Overfitting und verbessert die Modellgüte.

Nachteilig für die kennzahlenbasierte Unternehmenssteuerung hingegen kann eben dieses Entfernen modellierter Größen aus der Betrachtung sein. Da die Bestimmung der statistisch besten Prädiktoren durch den Algorithmus erfolgt [Berger 2008, 7], ist für den Fachanwender nicht nachvollziehbar, wie das Ergebnis zustande kommt. Die reine Fokussierung der statistischen Aussagekraft könnte zudem zu einer Auswahl an Größen führen, welche aus unternehmerischer Sicht nicht die erste Wahl für die Prozesssteuerung wären.

Alternativ sind also Verfahren zu nutzen, für die Multikollinearität ein weniger großes Hindernis darstellt. Eine Möglichkeit ist die in der dritten Version anstelle der multivariaten linearen Regression implementierte Ridge Regression, die sich für Datensätze mit vorliegender Multikollinearität eignet [NCSS Statistical Software; Ng/Soo 2018, 84]. Sie benötigt zudem keine Normalverteilung der Daten, setzt aber wie die multivariate lineare Regression lineare Beziehungen zwischen den Variablen und deren Unabhängigkeit untereinander voraus [NCSS Statistical Software]. Ebenfalls ähnlich ist, dass die Ridge Regression eine Funktion erzeugt, die die Summe der quadrierten Abweichungen der Punkte auf der Geraden zu den tatsächlichen Datenpunkten reduziert [Vlaming/Groenen 2015, 2]. Allerdings ergänzt die Ridge Regression die Minimierungsfunktion um einen durch ein λ gewichteten Term, welcher die Gültigkeit der Lösung trotz möglicher Multikollinearität sicherstellt, das Modell aber noch vergleichsweise einfach hält [Vlaming/Groenen 2015, 2]. Beabsichtigt wird, auch das λ zu minimieren [NCSS Statistical Software]. Hat es den Wert null, entspricht die Gleichung der Ridge Regression der Gleichung der multivariaten linearen Regression [Vlaming/Groenen 2015, 3].

Die Ridge Regression hat also den Vorteil, dass sie trotz Multikollinearität gültige Ergebnisse erzeugt und dabei ohne Variablenselektion alle Inputgrößen berücksichtigt. Darüber hinaus ist sie weniger anfällig bezüglich Ausreißern und ermöglicht die Analyse von metrisch skalierten wie auch kategorischen Variablen. Trotzdem sind auch bei der Ridge Regression die normierten Regressionskoeffizienten nicht direkt interpretierbar, wenn Multikollinearität vorliegt. Sie weist also gegenüber der multivariaten linearen Regression als vergleichsweise einfach interpretierbarem Analysealgorithmus deutliche Vorteile auf, stellt allerdings ebenfalls statistische Anforderungen bezüglich des Dateninputs.

Wie in der zweiten Version gibt es in der dritten Umsetzungsvariante des KPI Intelligence Tools ein weiteres prädiktives Verfahren für den komparativen Einsatz. Da Neuronale Netze nach deren Erprobung als weniger geeignet zu beurteilen waren, wurde die Einbindung anderer Algorithmen erwogen. Die in den in Kapitel 3.5 untersuchten Ansätzen mehrfach eingesetzten Entscheidungsbäume stellen eine interessante Alternative dar. Sie eignen sich für den Einsatz in vielen Domänen zur Lösung von Regressions- wie auch Klassifikationsproblemen. Entscheidungsbäume unterteilen Datensätze in kleinere, homogenere Gruppen. Dazu legen sie die Prädiktoren und zugehörige Werte, anhand derer eine Unterteilung erfolgt, fest und definieren auf diese Weise ihre Tiefe und Komplexität sowie die jeweiligen Vorhersagegleichungen [Kuhn/Johnson 2013, 175]. Die Zielstellung sieht dabei vor, die Summe der quadrierten Fehler bei der Vorhersage zu minimieren [Kuhn/Johnson 2013, 175].

Dies geschieht, indem der Algorithmus für jede Vorhersage eine eineindeutige Route durch den Entscheidungsbaum anhand von if-then-Statements für die Prädiktoren erzeugt, sodass für eine Vorhersage den Statements zu folgen ist [Kuhn/Johnson 2013, 173]. Diese Statements sind vergleichsweise einfach zu visualisieren (siehe Abb. 5-22) und daher einfach zu verstehen und intuitiv interpretierbar [Gröger et al. 2014, 28]. Dies ist ein Grund für ihren umfassenden Einsatz in der Wissenschaft und Praxis [Ng/Soo 2018, 110] und macht sie attraktiv für den Einsatz im Kontext der Digitalen Unternehmenssteuerung, da dies die Nachvollziehbarkeit für den Anwender erhöht. Ferner ermöglicht die Struktur von Entscheidungsbäumen ebenfalls die Analyse kategorialer wie auch stetiger Variablen, kleiner sowie großer Datensätze und macht sie unempfindlich gegenüber Ausreißern [Kuhn/Johnson 2013, 174; Ng/Soo 2018, 110]. Somit sind die Anforderungen an den Dateninput weniger streng als bei den linearen Regressionsverfahren.

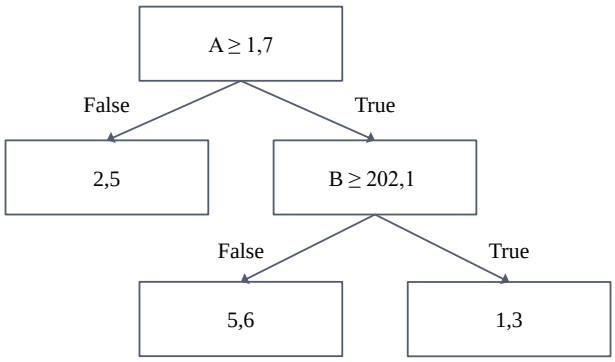

Abb. 5-22: Beispiel Entscheidungsbaum

Die Einfachheit der Struktur von Entscheidungsbäumen bringt jedoch auch mit sich, dass die Vorhersagegüte im Vergleich zu anderen Verfahren schlechter sein kann [Kuhn/Johnson 2013, 181]. Sie neigen zu Overfitting und sind sehr anfällig für kleine Veränderungen der Datengrundlage [Kuhn/Johnson 2013, 182; Ng/Soo 2018, 113, 182]. Indirekt führen Entscheidungsbäume ebenfalls eine Variablenselektion durch, indem ein Prädiktor mit geringem Einfluss nicht als „Split"-Variable genutzt wird [Kuhn/Johnson 2013, 180]. Sind zwei der Prädiktorvariablen sehr stark korreliert, erfolgt die Auswahl zufällig [Kuhn/Johnson 2013, 180]. Um dem Problem der Multikollinearität zu begegnen, kann eine Vielzahl an Entscheidungsbäumen mit jeweils zufälligen Kombinationen und Anordnungen der Variablen konstruiert und als Ensembles zusammengefasst werden [Kuhn/Johnson 2013, 175, 199; Ng/Soo 2018, 124]. Eine dieser Ensemblemethoden ist der Random Forrest.

Die zufälligen Kombinationen und Anordnungen des Random Forrest entstehen durch eine zufällig gewählte Untermenge an Trainingsdaten und eine zufällig gewählte Untermenge der Prädiktorvariablen, sodass viele signifikant verschiedene Entscheidungsbäume mit einer gewissen Vorhersagekraft entstehen [Ng/Soo 2018, 125]. Durch die Bildung des Durchschnittswertes des Ensembles der Entscheidungsbäume werden die Vorhersagen generiert [Kuhn/Johnson 2013, 199]. Dadurch entstehen entscheidende Vorteile gegenüber anderen Vorhersagemethoden, die zur Auswahl dieses Verfahrens als Komplement zur Ridge Regression in der dritten Softwareversion führten: Multikollinearität in den Daten stellt kein Problem dar [Kuhn/Johnson 2013, 199]. Weiterhin ist die Vorhersagegenauigkeit gegenüber einfachen Entscheidungsbäumen erheblich besser, ohne dass die Methode zu Overfitting neigt, und eine Vorverarbeitung der Daten ist nicht notwendig, da die Methode robust ist [Kuhn/Johnson 2013, 175, 200, 550]. Von zentraler Bedeutung ist auch, dass die Entstehung des Endergebnisses für den Anwender zwar nicht transparent ist, die jeweiligen Beiträge der Prädiktoren zur Vorhersagegenauigkeit jedoch klassifizierbar sind [Ng/Soo 2018, 127].

Nachteilig ist, dass durch die Zufälligkeit der erzeugten Entscheidungsbäume ohne klare Vorhersageregeln Intransparenz entsteht. Die Vorhersage des Random Forrests basiert letztlich darauf, dass die Mehrheit der einzelnen Entscheidungsbäume zu demselben Schluss gekommen ist [Ng/Soo 2018, 126]. Hinzu kommt, dass der Random Forrest die Einstellung von Tuningparametern erfordert und somit erweitertes Fachwissen seitens der Anwender benötigt. Dazu zählen die Anzahl der zufällig gewählten Prädiktoren sowie die Anzahl der Entscheidungsbäume[43], die je Ensemble zu lernen sind [Kuhn/Johnson 2013, 199]. Eine Steigerung der Anzahl der Bäume verbessert dabei einerseits die Präzision des Modells, lässt aber auch den Rechenaufwand steigen [Ng/Soo 2018, 126]. Für die dritte Version des KPI Intelligence Tools wurden diese Parameter als Kompromiss zwischen der Generik der Anwendung und der Vorhersagegenauigkeit fixiert. Weiterhin ist auch der Random Forrest instabil im Sinne möglicher drastischer Veränderungen des Modells bei geringfügigen Veränderungen der Daten [Kuhn/Johnson 2013, 174].

Fallabhängig können lineare Regressionsmethoden bessere Ergebnisse liefern als Entscheidungsbäume und umgekehrt [Kuhn/Johnson 2013, 182]. Aus diesem Grund erhält der Nutzer beim Öffnen des Prädiktions- beziehungsweise Simulationsmodus in der dritten Version des KPI Intelligence Tools eine Übersicht über Gütekriterien sowohl bezüglich der Ridge Regression als auch des Random Forrest. Beispielhaft zeigten dies Abb. 5-23 und für die Analyse der Zielwerttabelle (gemäß den Feldern I und J der Tabelle 5-6).

[43] Als Richtwert schlagen [Kuhn/Johnson 2013, 199] mindestens 1000 Entscheidungsbäume für ein Ensemble vor.

Ridge-Regression

Outputgrößen
DLQ_Werk

* Hinweis: Aufgrund von Multikollinearität (gemäß Variance Inflation Factor) ist die Einflussstärke der Variablen den normierten Koeffizienten nicht zu entnehmen. Durch ausschließliche Nutzung der markierten Größen als Prädiktoren kann Multikollinearität vermieden werden.

KPI	Koeffizient	Einfluss
FpE_A2	0 *	-0.0355
DLQ_A3	0.031 *	0.0389
FpE_A4	0 *	-0.0035
FpE_A6	-0.0045 *	-0.0445
NAF1_A4	-0.0011 *	-0.0029

Zeilen pro Seite: 5 6 - 10 / 18

R^2: 0.6997 Adjusted R^2: 0.6826 Mittlere quadratische Abweichung: 0.0001

Abb. 5-23: Gütekriterien im KPI Intelligence Tool v3 – Ridge Regression

Random Forest

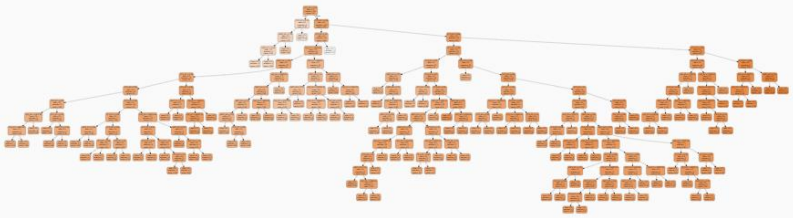

R^2: 0.9592 Mittlere quadratische Abweichung: 0

Abb. 5-24: Gütekriterien im KPI Intelligence Tool v3 – Random Forest

Da beide prädiktiven Algorithmen jeweils nur eine Outputgröße mit einem Modell bestimmen können, lernt die Software für jede Outputgröße ein eigenes Modell für beide Algorithmen. So kann der Anwender in der Mitte der Übersichtsdarstellung auswählen, für welche Outputgröße er die Informationen der Modelle anzeigen möchte. In Abb. 5-23 erfolgt dies für die Kennzahl DLQ_Werk.

Bei prädiktiven Analysen von Einzelprozessen auf Ebene 1 (Feld E und F der Tabelle 5-6) erfolgt die Nutzung der Input-, Stör- und Steuergrößen als Prädiktorvariablen für die jeweilige(n) Outputgröße(n). Im Falle sequentiell modellierter Prozesse gemäß der Felder G und H der Tabelle 5-6 dienen die Outputgrößen des ganz hinten eingeordneten Prozesses als vorherzusagende Größen, während die Outputgrößen der vorgelagerten Prozesse sowie alle Inputgrößen als Prädiktorvariablen fungieren. Folglich erlaubt diese Analyse die Prüfung von Ursachen, deren Wirkungen sich auch in nachgelagerten Prozessen noch niederschlagen. Für Prozessanalysen auf der Ebene 3 erfolgte mangels Anwendungsfällen keine Umsetzung prädiktiver Funktionalitäten. Bei Prozesshierarchien dienen die Outputgrößen der Subprozesse als Prädiktorvariablen für die Outputgrößen des Superprozesses. Für die Analyse der Zielwerttabelle ist dies in Abb. 5-25 dargestellt und der Grund dafür, dass ausschließlich Outputgrößen für den Anwendungsfall modelliert wurden.

Nach dieser Logik richtet sich also, welche Kennzahlen durch das **Tool** als Prädiktoren zu nutzen und demnach auch in der Übersicht der Gütekriterien zu berücksichtigen sind. Auf der linken Seite der Abb. 5-23 sind zu Gunsten der Nachvollziehbarkeit die Prädiktorvariablen mit den Regressionskoeffizienten der Ridge Regression dargestellt. Die Spalte ´Einfluss´ gibt zusätzlich den relativen Einfluss der Prädiktorvariablen nach deren Normierung[44], wie in Kapitel 5.3.2.2 erläutert, an. Außerdem blendet die Anwendung eine Warnung hinsichtlich deren Aussagekraft ein und versieht die Einflusswerte mit einem *, sofern wie in Abb. 5-23 gemäß des VIF (mit dem Schwellwert VIF>5) Multikollinearität vorliegt. In diesen Fällen werden einige der Kennzahlen in der Tabelle fett markiert. Dies deutet darauf hin, dass der Anwender Multikollinearität in dem Modell vermeiden könnte, wenn er für seine Vorhersage ausschließlich die markierten Werte verwendet und die übrigen Größen entfernt. Somit ist die Entscheidung, welche Kennzahlen in dem Modell verbleiben sollen, weiterhin dem Anwender überlassen. Die rechte Seite des Überblicks zeigt den für die jeweilige Outputgröße bestimmten aggregierten Random Forrest. Diese Darstellung soll trotz der geringen Transparenz des Verfahrens dem Anwender einen Einblick in dessen Funktionsweise bieten.

Als Gütekriterium steht unter anderem ein Accuracy-Wert basierend auf einer Cross-Validation in ähnlicher Form wie in Kapitel 5.3.2.2 zur Verfügung. Dabei wurde die Funktion der Cross-Validation angepasst und erweitert. In der dritten Version erfolgt eine 15-fold Cross-Validation[45]. Diese Validierungsmethode teilt die Datensätze 15 mal zufällig in Test- und Lerndatensätze [Vlaming/Groenen

[44] Für metrisch skalierte Variablen.

[45] Anhand von sehr heterogenen Testdatensätzen, welche sowohl aggregierte Managementkennzahlen, als auch Maschinendaten beinhalteten, wurde die 15-fold Cross-Validation als geeigneter Parameter für eine generische Einsetzbarkeit der Methode ermittelt.

2015, 6]. Ähnlich wie zuvor beschrieben, lernt die Software die Vorhersagemodelle auf Grundlage der jeweiligen Lerndatensätze und wendet sie auf die Testdatensätze an. Da sich die Trainingsdatensätze in jeder Iteration unterscheiden, erhält man jeweils unterschiedliche Vorhersagen [Ng/Soo 2018, 17], welche anschließend gemittelt werden.

Der Anwender kann diese Modelle nutzen, indem er für die gewählte Outputgröße den zu erreichenden Zielwert (siehe hierzu Kapitel 2.3) manuell eingibt. Es wird angezeigt, wie viel Prozent der Ausprägungen für diese Kennzahl in dem importierten Datensatz diesen Wert über- oder unterschreiten. Durch Klicken auf die Schaltfläche „Berechnen“ führt das **Tool** sodann für beide Vorhersagealgorithmen die Cross-Validations durch und bestimmt prozentual, wie häufig die einzelnen dabei ermittelten Modelle die Über- oder Unterschreitung des Zielwertes korrekt vorhergesagt haben (vgl. Kapitel 5.3.2.2). Für diese Prozentzahlen wird anschließend der Durchschnitt gebildet, sodass letztlich eine Aussage für die Gesamtmodelle der Ridge Regression und des Random Forrest möglich ist. Durch den Vergleich dieser Ergebnisse mit der Angabe der Häufigkeit der Über- oder Unterschreitung des eingegebenen Wertes in dem importierten Datensatz ist somit abzuschätzen, wie gut die Vorhersage mit dem Modell gegenüber einer Steuerung beispielsweise nach dem Durchschnittswert der Outputgrößen ist. Bezüglich der DLQ ergab eine Steuerung nach dem Durchschnitt in 60% der Fälle eine korrekte Abschätzung der Zielerreichung. Die Genauigkeit der Ridge Regression hingegen lag bei 82% und die des Random Forrest bei 92%. Somit war die Über- oder Unterschreitung des Zielwertes anhand der prädiktiven Modelle mit einer erheblich höheren Genauigkeit korrekt prognostizierbar. Durch diese Form der Cross-Validation ist also eine praxistaugliche Angabe zur Abschätzung der Vorhersagegüte in Prozent verfügbar.

Ergänzend dazu ist der Mean Squared Error (MSE) beider Algorithmen ablesbar. Er ist die am weitesten verbreitete Methode für die Bestimmung der Vorhersagegüte von prädiktiven Modellen und berechnet die quadrierten Abweichungen der Datenpunkte von den durch die Algorithmen bestimmten Punkte und teilt diese durch die Anzahl an Datensätzen [Kuhn/Johnson 2013, 95]. Der Mean Squared Error ermöglicht somit zu interpretieren, wie groß die durchschnittliche Abweichung (bestenfalls ist diese null) von den Punkten der Lerndaten ist [Kuhn/Johnson 2013, 95]. Besonders nützlich ist dieses Gütekriterium zur Vermeidung sehr großer Fehler, da die Abweichungen quadriert werden und sich demnach besonders stark niederschlagen [Ng/Soo 2018, 16]. Er ist im Falle der Zielwerttabelle hinsichtlich der DLQ sehr gering und beträgt für die Ridge Regression 0,0001 und unterschreitet diesen Wert für den Random Forrest sogar noch.

Als drittes Gütekriterium steht das R^2 für jedes der Modelle zur Verfügung (siehe Kapitel 5.3.2.2). Bezüglich dieses Maßes übersteigt die Genauigkeit des Random Forrests mit einem Wert von 0,9667 die der Ridge Regression mit 0,6997 deutlich. Bei der Auswertung dieser Gütekriterien für die Ridge Regression sei noch einmal deutlich auf die Multikollinearität und die hohe Wahrscheinlichkeit eines Overfitting in dem vorliegenden Anwendungsbeispiel hingewiesen. Die Priorisierung, wel-

che Kennzahlen letztlich für Vorhersagen zu nutzen sind, ist durch den entsprechenden Fachanwender durchzuführen. Die Cross-Validation zeigt jedoch, dass sinnvolle Vorhersagen erzielbar sind.

Anhand der Gütekriterien R^2, Cross-Validation und dem MSE hat der Anwender dennoch in jedem Fall die Möglichkeit, die Vorhersagegüte der beiden Modelle der Ridge Regression und des Random Forrest zu vergleichen. Für die Entscheidung, welches Modell im Simulationsmodus genutzt werden soll, ist zudem zu berücksichtigen, ob ein eher transparentes Modell wie die Ridge Regression oder ein weniger transparentes Modell wie der Random Forrest gewünscht wird. Dies muss analog für jede Art[46] der prädiktiven Analyse mit dem **Tool** erfolgen.

Um Simulationen beziehungsweise Vorhersagen durchzuführen, ist in dem Reiter ´Prognose´ das jeweilige anzuwendende Modell auszuwählen. In dem Anwendungsfall in Abbildung Abb. 5-25 fiel die Auswahl auf den Random Forrest[47]. Diese Ansicht zeigt die **Prozessmodelle** hierarchisch[48] angeordnet. Nach der zuvor erläuterten Logik werden die Outputgrößen der Subprozesse als Prädiktoren des Superprozesses genutzt. Besitzt der Superprozess wie in dem Beispiel mehrere Outputgrößen, ist per Klick auf die jeweilige Kennzahl zu definieren, welche Größe vorhergesagt werden soll. Diejenige Fläche wird dadurch dunkelgrau eingefärbt (in Abb. 5-25 ist dies die DLQ_Werk). In den Eingabefeldern für die Prädiktorvariablen hat der Anwender die Möglichkeit, Werte einzugeben, aufgrund derer die Vorhersage durchzuführen ist[49]. Die Software stellt das Ergebnis einerseits als Zahl[50] sowie andererseits in Form eines Tachos dar, dessen Minimum und Maximum den Minimal- und Maximalwerten der Kennzahl des Originaldatensatzes entsprechen. Bei Bedarf kann der Anwender auch das Vorhersagemodell zwischendurch ändern, wobei die manuell eingegebenen Werte gleich bleiben. So hat er die Möglichkeit, Vorhersagen durchzuführen und die wahrscheinlichen Auswirkungen geplanter Maßnahmen durch die Eingabe größerer oder kleinerer Werte im Vorhinein zu prüfen, ohne in den realen Prozess eingreifen zu müssen. Da prädiktive Modelle auf Daten aus der Vergangenheit basieren, ist bei deren Anwendung die Stabilitätshypothese, die besagt, dass definierte Grundstrukturen in der Vergangenheit und Zukunft unverändert wirken, zugrunde zu legen [Felden 2016].

---

[46] Gilt für alle Analysen gemäß der Ebenen 1 bis 4.

[47] Aus Gründen der Übersichtlichkeit wird das Hierarchiemodell mit nur zwei Prozessen auf der untergeordneten Ebene dargestellt. In der Anwendung erfolgt die Darstellung aller modellierten Prozesse.

[48] Abb. 0-5 zeigt den Prädiktionsmodus des KPI Intelligence Tools für einen Einzelprozess.

[49] Wird die Ridge Regression als Vorhersagemodell gewählt, werden unter den Namen der Kennzahlen zusätzlich die relativen Einflussstärken der normierten Daten aus der Ansicht „Überblick“ angezeigt. Für die Berechnung des Ergebnisses kommen allerdings die Regressionskoeffizienten berechnet anhand des Originaldatensatzes zum Einsatz.

[50] Hier aus Datenschutzgründen unkenntlich gemacht.

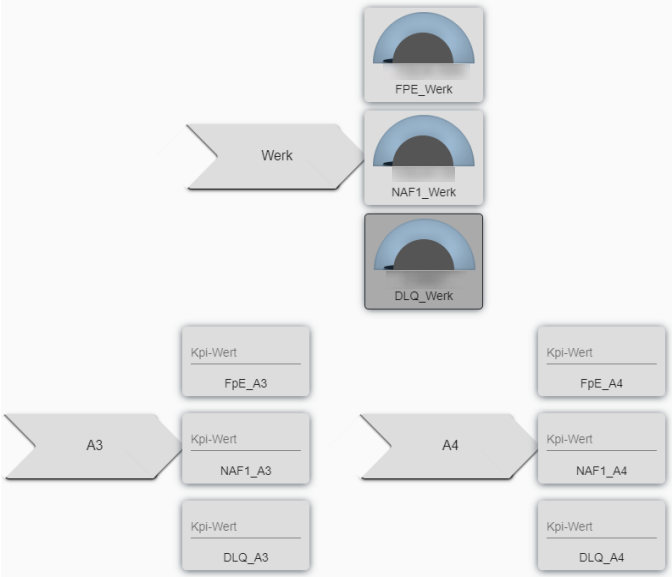

Abb. 5-25: Prädiktionsmodus Hierarchie KPI Intelligence Tool v3

Somit liegen dem Anwender am Ende der Analysephase umfangreiche quantitative Informationen vor, deren Extraktion aus den Daten er gemäß individueller Präferenzen hinsichtlich der Nachvollziehbarkeit der Entstehung vollzogen hat. Diese Informationen gilt es wiederum in der Realisierungsphase zu prüfen und zu interpretieren.

5.5.3 Realisierung

Die Analyse der Kennzahlenrelationen mit der dritten Version des KPI Intelligence Tools erfolgte im Rahmen der Anwendung der Methode für die Digitale Unternehmenssteuerung, wie sie in Kapitel 4.5 dargestellt ist. Die Interpretation der quantitativen Analyse ergab, wie in Kapitel 5.5.2.1 bereits angedeutet, dass die qualitativ definierten Verteilungsschlüssel anhand der Realdaten nur teilweise nachempfunden werden konnten. So wäre gemäß des Verteilungsschlüssels zu erwarten gewesen, dass die stärksten Korrelationen zwischen den Outputgrößen der Prozesse A1 bis A6 und der Werksebene in der in Tabelle 5-7 (linke Spalte) beschriebenen Reihenfolge vorliegen. Tatsächlich weichen die Ergebnisse (rechte Spalte) von den Erwartungen gemäß der Zielwerttabelle ab.

Zielwerttabelle	Datenanalyse
1. A3 2. A6 3. A2 4. A4	1. A3 2. A4 3. A1 & A5

Tabelle 5-7: Gegenüberstellung Zielwerttabelle und Datenanalyse

Zur Gegenüberstellung der Ergebnisse wurden in einem anderen Anwendungsfall mit dem gleichen Vorgehen dieselben Kennzahlen aus dem BMW Group Werk München analysiert und mit den Ergebnissen verglichen, die anhand der für dieses Werk definierten, qualitativ ermittelten Zielwerte zu erwarten waren. Dabei zeigte sich, dass auch in diesem Fall eine Divergenz zwischen den erwarteten und den datenbasiert ermittelten Ursache-Wirkbeziehungen vorlag, diese jedoch geringer ausfiel als im Werk Leipzig. Prozessual sind diese Erscheinungen unter anderem dadurch zu begründen, dass Probleme in bestimmten Funktionsbereichen unterschiedlich starke Auswirkungen auf die Werkskennzahlen haben als andere (wie anhand des Beispiels mit Lackfehlern in Kapitel 5.5.1 erläutert) [Interview 17.04.2019]. Für zukünftige Zieldefinitionen sind diese unerwarteten Beziehungen bezüglich ihrer Kausalitäten zu untersuchen [Interview 17.04.2019]. Ferner sind die Einsatzmöglichkeiten der quantitativen Analyse für die Unterstützung der Herleitung beziehungsweise Aktualisierung des Verteilungsschlüssels zu prüfen [Interview 17.04.2019].

Darüber hinaus zeigten sich deutliche Unterschiede zwischen beiden Standorten hinsichtlich der Korrelationsstärken zwischen den Subprozessen mit den Werkswerten als Superprozesse. Als Konsequenz ist auch hier durch Fachexperten zu untersuchen, wie diese Unterschiede anhand der Kennzahlenerfassung und -dokumentation zu erklären sind [Interview 25.04.2019a].

Anlässlich dieses Anwendungsfalls erfolgte ebenfalls eine Analyse der Kennzahlen Anzahl Nacharbeit (Ursache) und Anzahl Nacharbeit (alle) als Outputgrößen für die jeweiligen Aufgabenbereiche A1-A6 des Werks Leipzig. Die Kennzahl Anzahl Nacharbeit (Ursache) soll erfassen, welche Aufwendungen für die Durchführung einer Fehlerbehebung notwendig sind (z. B. Lackfehler korrigieren), während die Anzahl Nacharbeit (alle) zusätzliche aus der Behebung des Fehlers resultierende Tätigkeiten (z. B. Bauteil mit Lackfehler (de-) montieren) aufnehmen soll. Es zeigten sich innerhalb aller modellierten Prozesse sehr starke Korrelationen (0,94 - 0,9986) zwischen diesen beiden Kennzahlen. In der Folge wurde eine mögliche Redundanz der Kennzahlen diskutiert. Dabei entstand die Vermutung, dass dies eine Erscheinung im Werk Leipzig ist und in anderen Werken so nicht aufzufinden sein wird [Interview 03.04.2019]. Wider Erwarten zeigte eine analoge Betrachtung für das Werk München, nahezu identische Ergebnisse. Für beide Werke verhalten sich die Kennzahlen also beinahe gleich, sodass die eine Kennzahl in Ergänzung zu der anderen (fast) keinen Informationsgewinn enthält, aber dennoch administrative Aufwände erzeugt. Dies veranlasste zur Aufstellung folgender Hypothesen, welche zukünftig zu prüfen sein werden [Interview 24.04.2019]:

1. Es soll ein Effekt abgebildet werden, der nur auf eine der beiden Kennzahlen wirkt, aber auf diese Weise nicht erfassbar ist.
2. Die Kennzahlenerfassung erfolgt nicht wie beabsichtigt, indem Informationen nicht oder unzureichend erfasst werden.

Diese Anwendungsfälle trugen maßgeblich dazu bei, dass der Proof of Concept als erfolgreich und die Methode für die Digitale Unternehmenssteuerung als geeignet für den praktischen Einsatz zur Analyse von prozess- und hierarchieübergreifenden Kennzahlen mit unterschiedlichen Charakteristika (Kosten, Zeit, Qualität etc.) betrachtet wird [Interview 24.04.2019; Interview 25.04.2019a; Interview 25.04.2019b]. Dies führte zur Definition folgender Schritte für deren Einsatz: So soll unter der Verwendung prozessinterner Kennzahlen untersucht werden, wie die Ursache-Wirkbeziehungen der betrachteten Aufgabenbereiche A1-A6 in der Sequenz ausgeprägt sind, um festzustellen, ob bereits in vorgelagerten Prozessen erkannte Fehler im Folgeprozess erneut erscheinen [Interview 25.04.2019b]. Zu prüfen ist dadurch die Wirksamkeit des Kennzahlensystems, da die Annahme besteht, dass wenn vorgelagerte Prozesse ihre Zielvorgaben erreichen, auch nachgelagerte Prozesse ihre Ziele erreichen können und sie letztlich die endkundenrelevanten Kennzahlen wie Gewährleistungskosten positiv beeinflussen [Interview 25.04.2019b].

Weiterhin sollen die Auswirkungen von Problemen abgeschätzt und proaktiv gegengesteuert werden, was mit den aktuellen, starren Verteilungsschlüsseln nicht möglich ist [Interview 17.04.2019]. Vorhersagen der Werkswerte erfolgen in diesem Bereich derzeit durch die Multiplikation der entsprechenden Kennzahlenwerte mit den qualitativ festgelegten Verteilungsschlüsseln [Interview 17.04.2019]. Quantitative Analysen erfolgen derzeit noch nicht, sodass die Vorhersagen bei den Empfängern wenig Vertrauen und eine geringe Akzeptanz haben [Interview 24.04.2019]. Ursächlich dafür ist, dass die Entstehung der qualitativen Vorhersagen nicht hinreichend nachvollziehbar ist [Interview 24.04.2019].

Erschwerend kommen unterjährige Veränderungen der Ursache-Wirkbeziehungen (z. B. täglich, wöchentlich, monatlich) zwischen den Kennzahlen während des realen Prozessbetriebes hinzu [Interview 17.04.2019]. Kausalbeziehungen können sich mit der Zeit ändern oder sich schwankend verhalten (z. B. durch Veränderungen im Prozess, wie der Anlauf eines neuen Fahrzeugderivates), sodass erfasste Ursache-Wirkbeziehungen Momentaufnahmen darstellen [Granger 1969, 428]. Die quantitative Analyse von Kennzahlenrelationen ermöglicht es, diese effizient und effektiv zu untersuchen, indem die Datengrundlage für die spezifischen Zeiträume untersucht wird. Somit sollen Vorhersagen zukünftig quantitativ unterstützt und überprüft werden [Interview 24.04.2019]. Dies beinhaltet die Identifikation der Größen, welche sich besonders gut für die Vorhersage der jeweiligen Zielgrößen eignen [Interview 17.04.2019]. Ziel ist, qualitative und quantitative Vorhersagen gegenüberzustellen. Stimmen die Resultate überein, steigt das Vertrauen in die Ergebnisse; werden Abweichungen identifiziert, sind zukünftig Dialoge mit den Verantwortli-

chen zu führen und die Gründe dafür zu identifizieren [Interview 24.04.2019]. Dabei muss jedoch Bewusstsein dafür herrschen, dass unerwartete, zukünftige wie auch singuläre Ereignisse (z. B. Lieferengpässe durch Naturkatastrophen) durch die prädiktiven Modelle nicht vorhersagbar sind und das reale Ergebnis beeinflussen können. Weiterhin sollen Hypothesen bezüglich regulär auftretender Ereignisse wie saisonale Temperaturschwankungen oder Urlaubszeiten und Feiertage betrachtet werden [Interview 25.04.2019b].

Einen weiteren Schwerpunkt werden Detailanalysen der identifizierten, statistisch relevanten Beitragsleister der Subprozesse zu den Werkskennzahlen bilden (in dem Anwendungsbeispiel Aufgabenbereich A3) [Interview 24.04.2019]. Dies betrifft einerseits die Größen mit starken, aber insbesondere auch die Größen mit mittleren Korrelationsstärken [Interview 24.04.2019]. Um diese Ergebnisse prozessual im Detail nachvollziehen zu können, sollen mittelfristig Untersuchungsaufträge an die Fachbereiche erteilt werden [Interview 25.04.2019a].

Der bereits initial durchgeführte Vergleich von nahezu gleichen Kennzahlenkonstellationen für dieselben Funktionsbereiche unterschiedlicher Werke soll zudem ausgeweitet werden, um Lerneffekte zu übertragen und die Kennzahlenerfassung und -dokumentation für ein hohes Maß an Vergleichbarkeit zwischen den Werken zu erhöhen [Interview 25.04.2019b]. Dies fördert auch die Identifikation von redundanten Kennzahlen im Werkeverbund, gibt den Verantwortlichen ein besseres Gefühl für die großen Kennzahlenmengen und fördert letztlich das Verständnis für das gesamte Kennzahlensystem [Interview 25.04.2019a]. Der Fokus liegt bei diesen Analysen eher auf regelmäßigen Analysen in angemessenen Zeitabständen als auf Echtzeitanalysen [Casares 2019, 110] und gibt den Reportingstellen durch die Möglichkeit quantitativer Analysen unter Anwendung von Advanced Analytics-Methoden eine zunehmend beratende Funktion [Interview 24.04.2019].

Hinsichtlich der Erfüllung der **Leitmerkmale** erreicht das KPI Intelligence Tool Version 3 deutliche Fortschritte gegenüber den beiden ersten Versionen:

Leitmerkmale	Erfüllungsgrad
Prozess- und hierarchieübergreifende Analysen	++
Komplementär eingesetzte Analysemethoden	+
Komparativ eingesetzte Analysemethoden	+
Objektivität der Analyseergebnisse	+
Anwenderfreundlichkeit bei der Durchführung und Interpretation	+
Schaffen von Vertrauen in die Ergebnisse	+
Nachvollziehbarkeit der Ergebnisentstehung ohne automatisierte Entscheidungen	+ +
Wirtschaftlichkeit durch generisch einsetzbare und skalierbare Lösungen	+

Tabelle 5-8: Erfüllung der Leitmerkmale durch das KPI Intelligence Tool v3

So erfolgt eine neuartige Unterstützung der prozess- und hierarchieübergreifenden, quantitativen Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen durch die **vier Modellierungsebenen**. Auf diese Modelle sind die deskriptiven/diagnostischen sowie prädiktiven **Techniken** komplementär anwendbar. Diese wurden mit dem Korrelationskoeffizienten nach Spearman, der Ridge Regression und dem Random Forrest mit robusten und praxistauglichen Advanced Analytics-Methoden umgesetzt. Insbesondere der komparative Einsatz der Ridge Regression und des Random Forrest tragen zur Auflösung des zweiten in Kapitel 3.7 aufgezeigten Spannungsfeldes zwischen der Interpretierbarkeit der Ergebnisentstehung, der generischen Einsetzbarkeit der Algorithmen und einer hohen Genauigkeit der Anwendung bei. Die Verfügbarkeit der Streudiagramme, der grundlegenden statistischen Angaben wie auch der Regressionsgleichungen mit ihren Einflussstärken sorgen für ein hohes Maß an Interpretierbarkeit [Interview 23.04.2019] und schaffen somit Vertrauen in die Ergebnisse. Auch der Visualisierung von Entscheidungsbäumen begegneten Anwender sehr positiv [Casares 2019, 96]. Da in der dritten Umsetzung ebenfalls keine automatisierten Entscheidungen getroffen werden, sondern der Anwender durch zahlreiche Gütekriterien befähigt wird, selbst eine fundierte Entscheidung beispielsweise für die Wahl des Vorhersagealgorithmus zu treffen, ist die Nachvollziehbarkeit der Anwendung gestiegen. Nachdem die Entwicklung des **Tools** abgeschlossen war, beriet ein Data Scientist daher lediglich den Fachexperten bei dem Anwendungsfall. Der Data Scientist half bedarfsweise bei der Analyse der Ergebnisse, ohne wie bisher üblich die gesamte Analyse durchführen zu müssen. Dabei blieb die Objektivität der Ergebnisse auf hohem Niveau.

Eines der Hauptmerkmale von Analyseanwendungen ist, dass deren Design die Bedürfnisse der Anwender hinsichtlich einer einfach und intuitiv benutzbaren Oberfläche erfüllt, ohne dass Codefragmente selbst geschrieben oder Expertenkenntnisse bezüglich Advanced Analytics vorhanden sein müssen [Castellanos et al. 2005, 5]. [Alt et al. 2020, 615] sprechen von low-code und no-code-tools für „…those in the company that run the processes and profoundly understand the business to solve everyday problems themselves…". In diesem Sinne ist in dem KPI Intelligence Tool Version 3 eine hohe Anwenderfreundlichkeit erreicht [Interview 23.04.2019]. Wesentlich dafür sind beispielsweise die intuitive Modellierung der Prozesse, wie auch die einfach nutzbare Datenbereinigungsfunktion. Bezüglich der in Abb. 3-2 dargestellten Levels der Self-Service BI befindet sich die Anwendung in den Bereichen „Access to analytical functions" sowie „Creation of information resources". Gleichzeitig erfüllt sie ein hohes Maß an Wirtschaftlichkeit, da sie durch die Fähigkeit zur Analyse unterschiedlichster Prozesse und den Private Cloud-Ansatz ohne Lizenzkosten und Installationsaufwendungen für einzelne Anwender sehr gut skalierbar ist. Darüber hinaus weist das **Tool** eine hohe generische Einsetzbarkeit durch die Verarbeitung heterogener Kennzahlendaten und übertragbarer Analytics-Algorithmen auf. Der in diesem Kontext herausfordernden Fragestellung der richtigen Einstellungen von Tuningparametern wird durch den komparativen Einsatz der prädiktiven Algorithmen begegnet, sodass sehr gute Vorhersageergebnisse erzielt werden. Eine Quantifizierung des wirtschaftlichen Nutzens dieser Anwendung ist, wie häufig beim Einsatz von Analysesoftware, allerdings sehr schwer ausweisbar [Interview 01.02.2018]. Daher dient folgende Umfrage der qualitativen Erfassung des Nutzerfeedbacks.

5.5.4 Anwenderumfrage

Eine Anwenderumfrage in der BMW Group diente der Erfassung des Nutzens der dritten Version des KPI Intelligence Tools. Im Rahmen dessen beurteilten es insgesamt 16 der zu diesem Zeitpunkt über 55 registrierten Anwender qualitativ, indem Sie ihre Einschätzung bezüglich 26 vorbereiteter Fragen anhand einer Likert-Skala abgaben: Stimme voll und ganz zu (1), stimme zu (2), unentschieden (3), stimme nicht zu (4), stimme überhaupt nicht zu (5). Die Thesen vervollständigen jeweils einen der folgenden Halbsätze:

- Durch die Nutzung des KPI Intelligence Tools…
- Ich möchte das KPI Intelligence Tool zukünftig nutzen…
- Das KPI Intelligence Tool eignet sich...

Die Ergebnisse sind vollständig in Abb. 0-6 dokumentiert. Zur Vereinfachung erfolgt hier die Interpretation der Antwortmöglichkeiten (1) und (2) als positiv, Antwortmöglichkeit (3) als neutral und Antwortmöglichkeiten (4) und (5) als negativ.

Anhand der Einschätzungen hinsichtlich der Fragen 1 bis 3 ermöglicht das KPI Intelligence Tool einer sehr deutlichen Mehrheit an Fachanwendern einen vereinfachten Zugriff auf Advanced Analytics-Methoden. Dies schafft neue Möglichkeiten für die Nutzung von Daten und bietet zusätzliche, objektive Informationen für die Entscheidungsfindung.

Ebenfalls beurteilen die Anwender überwiegend positiv, dass sich die Auswirkungen von Maßnahmen durch den Einsatz des Tools besser abschätzen lassen. Gleiches gilt hinsichtlich der Reduktion von Entscheidungen auf Erfahrungswissen basierend sowie der Reduktion von Unsicherheiten während der Entscheidungsfindung. Die Ableitung effizienterer und effektiverer Maßnahmen schätzten die Fachanwender mehrheitlich positiv ein, wobei jedoch knapp 45% von ihnen eine neutrale Bewertung abgaben. Dies ist vermutlich auf den Bedarf einer weiteren Evaluierung der Lösung zurückzuführen, da sich die Wirkung von Maßnahmen üblicherweise erst zu einem späteren Zeitpunkt vollständig einstellt (Fragen 4 bis 7).

Breite Zustimmung zeigt sich auch hinsichtlich der Fragen 8 – 10, welche die quantitative Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen, die Überprüfung von Annahmen und Hypothesen sowie die quantitative Fundierung von Entscheidungen beziehungsweise Maßnahmen betreffen.

Die Anwender sehen mit großer Übereinstimmung einen Nutzen des KPI Intelligence Tools bei der Identifikation von unerwarteten Beziehungen zwischen Kennzahlen und von Redundanzen. Bezüglich der Steigerung der Wirksamkeit von Maßnahmen erfolgte auffällig häufig eine neutrale Bewertung, was auf eine gewisse Unsicherheit der Anwender hinsichtlich dieser These in der Kürze des Einsatzzeitraumes schließen lässt. Allerdings bestätigten Experten diesen Aspekt wiederholt in den von dieser Befragung unabhängig durchgeführten Interviews (Fragen 11 - 13).

Anhand der Antworten auf die Fragen 14 bis 17 zeigt sich, dass die Anwender Vorteile bei der Förderung prozess- und hierarchieübergreifender Analysen und der Beschleunigung von Datenanalysen sehen. Im Vergleich dazu steigt die Anzahl neutraler Bewertungen hinsichtlich der verbesserten Vergleichbarkeit verschiedener Werke bei dennoch einigen positiven Stimmen.

Mehrheitlich schätzen die Anwender positiv ein, dass das KPI Intelligence Tool hilft, die in der vorliegenden Arbeit umfassend diskutierte Komplexität der Prozesssteuerung zu reduzieren. Ebenso trägt es dazu bei, die Transparenz der Ursache-Wirkbeziehungen zwischen Kennzahlen zu steigern. Die Förderung einer proaktiven und zukunftsorientierten Prozess- und Unternehmenssteuerung beurteilt knapp die Hälfte der Anwender positiv, während eine ähnliche Anzahl neutral votierte. Dies zeigt sich in den Antworten auf die Fragen 18 bis 21.

Angesichts der in Kapitel 5.5.3 diskutierten Optimierungspotentiale, welche das Tool in der Version 3 hat, ist besonders bemerkenswert, dass die sehr heterogene Anwendergruppe in einer deutlichen Mehrheit und ohne eine einzige negative Beurteilung das Aufwand-/Nutzen-Verhältnis des KPI Intelligence Tools bei Frage 22 positiv einschätzt.

Die Anwender bestätigen in sehr deutlicher Mehrheit die Nutzungsabsicht für die adressierten Anwendungsbereiche des KPI Intelligence Tools zur Schaffung von Transparenz anhand deskriptiver und diagnostischer **Techniken** sowie zur Simulation und Prognose mittels prädiktiver Algorithmen (Fragen 23 und 24). Gleiches gilt für bedarfsbezogene Analysen bezüglich spezifischer Fragestellungen. Analysen in regelmäßigen Zeitabständen beurteilen ca. 44% der Befragten positiv und in gleicher Anzahl neutral (Fragen 25 und 26).

Der praktische Einsatz der Techniken für die Analyse von Kennzahlenrelationen in der Fallstudie mit den verschiedenen Anwendungsfällen und das Feedback der Anwender dienen der Beantwortung der dritten Teilforschungsfrage.

5.6 Zusammenfassung: Quantitative Analyse von Kennzahlenrelationen

Teilforschungsfrage 3: Wie kann die Digitale Unternehmenssteuerung mittels quantitativer Analyse von Kennzahlenrelationen implementiert werden?

Ein zentrales Vorhaben der vorliegenden Dissertation ist, die Bedürfnisse von Fachanwendern zu verstehen und geeignete Techniken zu bestimmen und zur Verfügung zu stellen, sodass sie die bisher unzureichend ausgeschöpften Potentiale von Kennzahlendaten in Form von verborgenen Informationen nutzen können. Die Ergebnisse sind eine Weiterentwicklung der klassischen kennzahlenbasierten Steuerung durch Instrumente der Digitalisierung und als ein Schritt des Paradigmenwechsels hin zu einer Digitalen Unternehmenssteuerung aufzufassen.

Die Diskussion der Charakteristika sowie der Vor- und Nachteile verschiedener Advanced Analytics-Algorithmen in mehreren Entwicklungsstufen war die Grundlage der Analyse von deren Eignung für die Unterstützung der kennzahlenbasierten Unternehmenssteuerung. Der direkte praktische Einsatz der entwickelten Anwendungen ermöglichte die Erzeugung der übrigen Elemente der Methode für die Digitale Unternehmenssteuerung. Diese praxistaugliche Methode versetzt Fachanwender in die Lage, selbständig Ursache-Wirkbeziehungen zwischen Kennzahlen innerhalb einzelner Prozesse sowie prozess- und hierarchieübergreifend mittels quantitativer Verfahren zu analysieren und durch deren Interpretation qualitatives Wissen zu ergänzen. Reportingstellen ziehen unternehmensinterne sowie unternehmensexterne Daten heran und untersuchen diese siloübergreifend hinsichtlich ihrer Ursache-Wirkbeziehungen. Zudem führen sie auf Basis der quantitativ ermittelten Informationen Simulationen und Vorhersagen durch und stellen diese im Unternehmen zur Verfügung. Dabei ist das Vorgehen ein iterativer und sich wiederholender Prozess, der in vielen Fällen eher dabei hilft, die richtigen Fragen zu stellen, als abschließende Antworten zu generieren. Dies ergibt sich daraus, dass das Analysieren durch das kritische Prüfen und Aufstellen von Hypothesen sowohl hinsichtlich der Kennzahlensteuerung als auch hinsichtlich der quantitativen Ergebnisse ein wesentlicher

Bestandteil der Methode für die Digitale Unternehmenssteuerung ist und die Analytics-Algorithmen keine absoluten Wahrheiten oder Kausalitäten belegen. Bei geeigneter Anwendung tragen diese Techniken jedoch wesentlich zur Steigerung der Transparenz und folglich zu Reduktion der Komplexität der Unternehmenssteuerung bei.

Bei der Implementierung der Digitalen Unternehmenssteuerung sind unternehmens- beziehungsweise anwendungsfallspezifische Präferenzen hinsichtlich der aufgestellten Leitmerkmale zu berücksichtigen. In der durchgeführten Fallstudie führte dies dazu, dass die Anwendung der Methode die Beantwortung der in Abb. 4-8 und Abb. 4-9 hinsichtlich der Erkenntnisbeiträge der Deskription/Diagnostik und Prädiktion gestellten Fragestellungen gemäß der Bedürfnisse der Fachanwender ermöglichte. Da der derzeitige Stand der Technik noch keine Rückschlüsse ohne die Interpretation der Informationen zulässt [Zumstein/Gächter 2016, 378], konnte eine Präskription noch nicht realisiert werden. Nichtsdestotrotz unterstützte die Methode für die Digitale Unternehmenssteuerung die erfolgreiche Informationssystemgestaltung maßgeblich, sodass eine Validierung der Erkenntnisse erfolgte. Daher wurde das Gestaltungsziel erreicht.

Ein Überblick über die gewonnenen Erkenntnisse dieser Dissertation, eine wissenschaftliche Einordnung dieser sowie weitere abschließende Überlegungen folgen im Kapitel Schlussbetrachtungen.

6 Schlussbetrachtungen

Große Produktionssysteme bestehen aus einer Vielzahl interdependenter Prozesse, deren Leistungserbringung einen Mehrwert für den Endkunden erzeugen muss, um wirtschaftlichen Unternehmenserfolg zu erzielen. Die hochkomplexe Aufgabe der Steuerung der Prozesse im Sinne der definierten Unternehmensziele obliegt dem Management. Dabei stehen ihm eine zunehmende Dynamik, Unsicherheit und Komplexität gegenüber, die immer neue, fundierte Maßnahmen zur Planung, Steuerung und Kontrolle abverlangen. Als Hilfsmittel setzen Entscheidungsträger Prozesskennzahlen ein und definieren Zielwerte, die es zu erreichen gilt, um den Erfolg der Steuerung zu messen. Diese Kennzahlen repräsentieren die zugehörigen Prozesse und ermöglichen die Analyse von Ursache-Wirkbeziehungen innerhalb und zwischen den Prozessen. Derartige Analysen erfolgen derzeit wenn überhaupt qualitativ und verursachen hohen personellen und zeitlichen Aufwand, sodass Entscheidungen überwiegend auf Arbeitshypothesen, Annahmen, Intuitionen und Erfahrungswissen beruhen. Somit sind die Auswirkungen von Maßnahmen kaum vorhersagbar und es drohen Fehlsteuerung und Ineffizienzen wegen des Einsatzes ungeeigneter Kennzahlen oder Zielvorgaben. Außerdem fördert dies das Denken in Silos und eine reaktive statt einer proaktiven Prozesssteuerung. Daher wurden bei der Beantwortung der Teilforschungsfrage 1 Anforderungen an die kennzahlenbasierte Unternehmenssteuerung abgeleitet. Kapitel 6.1 geht auf diese noch einmal ein.

Während das Management zur Erfüllung seiner Aufgaben schnelle, aktuelle und relevante Informationen sowie prädiktive und simulative Analysen benötigt und die Durchdringung der digitalen Transformation in zahlreichen Unternehmensbereichen massiv zunimmt, schöpfen die Unternehmen die Potentiale von Advanced Analytics für die kennzahlenbasierte Unternehmenssteuerung in aktuellen BI-Anwendungen nicht aus. Die zur Beantwortung von Teilforschungsfrage 2 hergeleiteten Leitmerkmale dienen der Unterstützung bei der Erstellung von Software-Lösungen, die den Einsatz wissenschaftlicher Erkenntnisse aus dem Bereich Advanced Analytics für die Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen ermöglichen. Sie schaffen eine Orientierung und sind je nach Unternehmens- und Anwendungskontext zu priorisieren und einzusetzen.

Die Leitmerkmale sind eines der Elemente der Methode für die Digitale Unternehmenssteuerung, dessen praktischer Einsatz gezeigt hat, auf welche Art und Weise die quantitative Analyse von Kennzahlenrelationen implementierbar ist und somit die Beantwortung der Teilforschungsfrage 3 ermöglichte. Diese Erkenntnisse führen in Summe zur Beantwortung der Hauptforschungsfrage.

6.1 Evaluation von Advanced Analytics-Algorithmen in der Digitalen Unternehmenssteuerung

Hauptforschungsfrage: Wie können Advanced Analytics-Algorithmen zur Digitalen Unternehmenssteuerung beitragen?

Eine Evaluation beinhaltet laut [Benyon et al. 2006, 268] „…reviewing, trying out or testing a design, a piece of software or a product to discover whether it is learnable, effective and accommodating … for its intended user population." In Anlehnung daran erfolgte der praktische Einsatz von diversen Advanced Analytics-Algorithmen als Elemente der Methode für die Digitale Unternehmenssteuerung in einer Fallstudie mit mehreren Anwendungsfällen und Softwareversionen für die Analyse von Kennzahlenrelationen bei der BMW Group (siehe Kapitel 5). Das in dieser Fallstudie erhaltene Feedback durch die Praxisanwender sowie die zuvor durchgeführte Literaturanalyse stellen die Grundlagen für die Ermittlung der Beiträge dar. Diese unterstützen, wie folgend und in Tabelle 6-1 dargestellt, die Erfüllung der in Kapitel 2.5 aufgestellten Anforderungen an die kennzahlenbasierte Unternehmenssteuerung.

So besagt die erste Anforderung, dass sich Zielwertvorgaben für Prozesse und die Beurteilung der Prozessleistung an den Anforderungen interner und externer Kunden sowie an den übergeordneten Unternehmenszielen orientieren und die resultierenden Kennzahlensysteme aktuell, konsistent, verständlich und richtig bewertbar sind sowie eine proaktive, zukunftsorientierte Unternehmenssteuerung ermöglichen. Die Orientierung der Zielvorgaben für Prozesse und die Leistungsbeurteilung der Prozesse anhand der Anforderungen interner und externer Kunden sowie den übergeordneten Unternehmenszielen wird durch die Methode unterstützt, indem Ursache-Wirkbeziehungen quantitativ unter anderem sequentiell wie auch hierarchisch untersucht werden können. Dabei sind die Elemente der Methode so ausgerichtet, dass Kennzahlen unterschiedlicher Granularität beziehungsweise unterschiedlicher Prozessebenen analysierbar sind. Dies hilft bei der Ausrichtung bereichsspezifischer Aktivitäten auf die obersten Unternehmensziele und bei der Schaffung eines unternehmensweit einheitlichen Kennzahlensystems. Auf welcher Grundlage das Kennzahlensystem initial erstellt wurde (z. B. Du Pont, BSC) spielt eine untergeordnete Rolle.

Die Steigerung der Transparenz hinsichtlich der Ursache-Wirkbeziehungen und der Möglichkeit, Prognosen sowie Simulationen von Maßnahmen durchzuführen, fördern die Aktualität, Konsistenz, Verständlichkeit und richtige Bewertbarkeit von Kennzahlensystemen und eine proaktive, zukunftsorientierte Unternehmenssteuerung. Ferner sind redundante oder noch fehlende, zu erstellende Kennzahlen identifizierbar, was die Anpassung, Pflege und Aktualisierung von Kennzahlensystemen vereinfacht. Das Handling großer Kennzahlendatenmengen durch Strukturierungen mittels der Algorithmen reduziert Unsicherheiten und folglich die Steuerungskomplexität wie auch die kognitive Belastung von Entscheidungsträgern. Wesentlich ist dabei die Verwendung der Algorithmen als Black Box. Dies bedeutet nicht, dass die Algorithmen zwingend selbst eine Black Box darstellen. Vielmehr ist gemeint,

dass der eigentliche Realprozess nicht detailliert auf einzelne Kausalitäten untersucht, sondern anhand relevanter Kennzahlen modelliert und analysiert wird. Dies vereinfacht die Analyse deutlich und ermöglicht somit beispielsweise, sich über verschiedene Zeiträume verändernde Interdependenzen zu betrachten und das implizite Wissen zu erweitern.

Um eine Entscheidung zu treffen, muss das jeweilige Problem verstanden worden sein [Saaty 2008, 84]. Außerdem ist wichtig, dass die Absichten der Entscheidung, dessen (Sub-) Kriterien, Stakeholder und beeinflusste Gruppen sowie alternative Handlungen bekannt sind [Saaty 2008, 84]. Darauf folgt die Auswahl der besten verfügbaren Maßnahmen. Dementsprechend ist die zweite Anforderung an die kennzahlenbasierte Unternehmenssteuerung aus Kapitel 2.5, dass effiziente und effektive Maßnahmen durch transparente Ursache-Wirkbeziehungen zwischen den Kennzahlen die Unternehmensleistung verbessern und den eigenen Beitrag der Mitarbeiter zur Erreichung der Unternehmensziele verdeutlichen. Die Steigerung von Effizienz und Effektivität ergibt sich, wie exemplarisch in den Anwendungsfällen im operativen Tagesgeschäft und der Anwenderumfrage dargestellt, sowohl durch quantitative Analysen auf Einzelprozessebene, wie auch sequentiell, parallel und hierarchisch. So ist im Vorhinein prüfbar, ob die Auswirkungen verschiedener Maßnahmen sehr wahrscheinlich auf eine bestimmte Art und Weise eintreten. Daraus kann die Wirksamkeit von Maßnahmen abgeleitet und das Abwägen von Alternativen[51] unterstützt werden. Gleichermaßen sind auf diese Weise Treiber von Ergebnissen identifizierbar und besonders wirksame Eingriffe oder Gründe für Probleme isolierbar. Die Wirksamkeit ergibt sich demnach durch unternehmerische Abwägungen hinsichtlich der erzeugten Vorteile für das Unternehmen gegenüber den zu tätigenden Investitionen beziehungsweise Aufwendungen.

Die Analyse von Kennzahlenrelationen unter Einsatz von Advanced Analytics-Algorithmen reduziert also den Anteil, den Annahmen und das Bauchgefühl der Verantwortlichen bei der Entscheidungsfindung klassischerweise innehaben. Dadurch können Entscheidungen fundierter getroffen werden und deren Aussagekraft steigt. Die Analyse der Kennzahlendaten hilft dem Management Gründe für Maßnahmen zu belegen und die Entscheidungen zu untermauern, indem der quantitative Teil der Entscheidungsgrundlage anderen zugänglich gemacht wird.

Entscheidungsträger erhalten Zielvorgaben für die ihnen zugeteilten Kennzahlen, nach deren Erreichung sie streben. Diese können aber – durchaus gewollt – zwischen verschiedenen Unternehmensprozessen in einem konkurrierenden Verhältnis stehen. Die quantitative Analyse der Kennzahlenrelationen fördert das Finden silo-übergreifender Optima im Sinne der Unternehmensziele anhand transparenter Ursache-Wirkbeziehungen. Die Berücksichtigung der interprozessualen Vernetztheit durch die übergreifende Verknüpfung von Kennzahlendaten reduziert das Siloden-

[51] Wie beispielsweise bei der Erstellung der Abweichungsdokumente aus Kapitel 2.3.4.

ken in Unternehmen und unterstützt die Kompromissfindung. Auf diese Weise werden Schäden für das Unternehmen durch eine reduzierte Fehlsteuerung abgewendet und dessen Produktivität gesteigert.

Als dritte Anforderung sind Ursache-Wirkbeziehungen zwischen Kennzahlen und Prozessen bewusst, nachvollziehbar und reproduzierbar zu lernen, zu dokumentieren, zu aktualisieren und für andere nutzbar zu machen. Dadurch herrscht ein einheitliches Verständnis diesbezüglich und bezüglich zu ergreifender Maßnahmen. Dies stellt das Teilen erlangten Wissens über Ursache-Wirkbeziehungen zwischen Kennzahlen in den Mittelpunkt. Durch den Einsatz von Advanced Analytics können diese nicht nur analysiert und die Ergebnisse vergleichsweise einfach reproduziert, sondern auch dokumentiert werden. Somit stehen sie auch anderen als objektive Informationsquelle zur Verfügung und geben beispielsweise denjenigen, die keine Experten für den jeweiligen Prozess sind, eine erste Grundlage, diesen kennenzulernen und einzuschätzen.

Durch die Ergänzung impliziten Wissens steigt die Qualität des Entscheidungsprozesses und verbessert folglich die Steuerung von Produktionssystemen. Konkret bedeutet dies das Messen von Prozessergebnissen durch Kennzahlen, die diese auch tatsächlich beeinflussen, die Reduktion des Risikos von Fehlinterpretationen und die Überprüfung, Ergänzung und Aktualisierung mentaler Modelle. Ein durch den erhöhten Automatisierungsgrad erheblich geringerer Aufwand zur Erfassung der Ursache-Wirkbeziehungen mittels quantitativer gegenüber qualitativen Analysen begünstigt dies. Während bei qualitativen Ansätzen die Erfassung der Relationen umfassende Beteiligungen von Prozessexperten benötigt, berechnen quantitative Methoden diese innerhalb weniger Sekunden, sofern eine geeignete Datenbasis zur Verfügung steht. So verlagert sich der Ressourceneinsatz von Unternehmen weg von der Datenerfassung und der Extraktion von Informationen hin zu deren Analyse. Daher sollten Fachanwender die analytischen Werkzeuge mit einer hinreichend hohen Anwenderfreundlichkeit zur Verfügung gestellt bekommen, sodass sie sie unabhängig von Analysespezialisten nutzen können[52]. Insbesondere für klassische Reportingstellen in Fachbereichen bietet dies große Potentiale im Sinne eines Job-Enrichment, sodass diese anstelle der reinen Erzeugung und Ausleitung von Standardberichten mit entsprechenden Werkzeugen fortgeschrittene Analysetätigkeiten übernehmen können. Deren Bedeutung steigt somit für das Unternehmen und Data Scientists, die üblicherweise mit einer sehr großen Menge an Anfragen konfrontiert werden, werden entlastet.

[52] "…the business analyst can´t get into too much trouble because the data has already been determined. He or she can experiment and explore models that have, in essence, been approved by the data scientist … Using this approach, the business analyst can create numerous models without daily reliance on a statistician/data scientist to built the models." [Halper 2014, 17]

Anforde-rung Nr.	Chancen
1	- Quantitative Analyse von Ursache-Wirkbeziehungen - Analyse von Ursache-Wirkbeziehungen für einzelne, parallele, sequentielle sowie hierarchische Prozesse - Analyse von Kennzahlen unterschiedlicher Granularität - Unterstützung der Ausrichtung von Aktivitäten auf die obersten Unternehmensziele - Unterstützung der Schaffung unternehmensweit einheitlicher Kennzahlensysteme auf Basis bestehender Kennzahlensysteme (z. B. Du Pont, BSC) - Transparenz der Ursache-Wirkbeziehungen zwischen Kennzahlen sowie Prognosen und Simulationen unterstützen Aktualität, Konsistenz, Verständlichkeit, richtige Bewertbarkeit von Kennzahlensystemen - Unterstützung von Anpassung, Pflege und Aktualisierung von Kennzahlensystemen z. B. durch Identifikation redundanter Kennzahlen - Reduktion von Unsicherheit und kognitiver Belastung für das Management - Ergänzung impliziten Wissens
2	- Steigerung von Effizienz und Effektivität der Maßnahmenauswahl durch Prüfung von deren Wirksamkeit - Identifikation von Ergebnistreibern für den wirtschaftlichen Einsatz von Detailanalysen - Reduktion des Anteils des Bauchgefühls von Entscheidungen durch Fundierung von Annahmen - Steigerung der Transparenz des Entscheidungsprozesses - Förderung der Identifikation siloübergreifender Optima im Sinne der Unternehmensziele - Reduktion von Fehlsteuerung und Schäden für das Unternehmen durch reduziertes Silodenken
3	- Dokumentation und Reproduktion erlangten Wissens über Ursache-Wirkbeziehungen wird vereinfacht - Objektive Informationen steht auch Dritten zur Verfügung - Steigerung der Qualität des Entscheidungsprozesses und folglich Verbesserung der Steuerung von Produktionssystemen durch Unterstützung mentaler Modelle - Reduktion des Erfassungsaufwandes von Ursache-Wirkbeziehungen durch erhöhten Automatisierungsgrad - Verfügbarkeit von Analysewerkzeugen für Fachanwender

Tabelle 6-1: Chancen des Einsatzes von Advanced Analytics-Algorithmen

Diesen zahlreichen Beiträgen von Advanced Analytics als Element der Methode für die Digitale Unternehmenssteuerung stehen jedoch auch Herausforderungen, die deren Einsatz mit sich bringt, gegenüber (siehe auch Tabelle 6-2). So liefern die Algorithmen nur gute Ergebnisse, wenn die richtigen Kennzahlen in der richtigen Prozessstruktur zum Einsatz kommen. Eine Vollständigkeit aller Ursache-Wirkbeziehungen ist jedoch auch bei gewissenhafter Auswahl der Größen nicht anzunehmen. Weder können mit Sicherheit alle Einflüsse mathematisch erkannt, noch in Form von Daten in das Modell eingebracht werden. Zum Beispiel sind unerwartete und singuläre Ereignisse durch Daten nicht vorhersehbar und können die Genauigkeit der Ergebnisse beeinflussen.

Ebenfalls einen großen Einfluss auf die Güte der Ergebnisse hat die Beschaffenheit der Daten an sich. Ändern sich die Prozesse oder die Berechnungslogik der Kennzahlen, ist die Datengrundlage besonders kritisch zu hinterfragen. Das gleiche gilt bei der Datenbereinigung aufgrund von falschen, fehlenden, nicht repräsentativen oder unterschiedlich aggregierten Werten. Erfolgt ein zu starker Eingriff in die Daten, kann sich deren Aussagekraft reduzieren.

Für die Erreichung einer hohen Aussagekraft sind zudem mathematische Anforderungen der Analytics-Algorithmen zu berücksichtigen. Werden Vorgaben (z. B. hinsichtlich Multikollinearität von Prädiktorvariablen) verletzt, sind davon unabhängige Parameter zur Feststellung der Modellgüte (z. B. Accuracy) zu prüfen. Weiterhin nehmen bei einigen Algorithmen Tuningparameter eine zentrale Rolle ein, die zu Over- beziehungsweise Underfitting führen und Anwender hinsichtlich der Anwendung der Algorithmen und der Interpretation der Ergebnisse vor Herausforderungen stellen können. Nicht zuletzt sind die Skalierungen der Kennzahlen (z. B. binär, numerisch, kategoriell) ausschlaggebend für die Anwendbarkeit der Algorithmen, welche unterschiedliche Variablen verarbeiten können.

Ist eine hinreichende Modellgüte erreicht, ist dennoch zu beachten, dass aus den Ergebnissen keine Kausalitäten oder Wirkrichtungen (wirkt a auf b, b auf a oder haben die Wirkungen von a und b eine gemeinsame Ursache) ableitbar sind. Derartige Rückschlüsse sind durch den Anwender zu leisten, ebenso wie ein kritisches Hinterfragen der Ergebnisse, da Fehlinterpretationen nicht auszuschließen sind. Dabei muss demjenigen bewusst sein, dass obwohl die Informationen aus den Datenanalysen ein hohes Maß an Objektivität vorweisen können, durch Schritte wie die Datenauswahl oder -bereinigung oder die Realisierungsphase subjektive Einflüsse unumgänglich sind.

Insgesamt ist die Bewertung von Handlungsalternativen und das Ableiten geeigneter Maßnahmen Aufgabe des Entscheidungsträgers, welcher die zusätzlichen Informationen aus der Datenanalyse zur Anreicherung seiner persönlichen mentalen Modelle nutzen und auf kreative Art und Weise mit diesem Wissen verknüpfen sollte. Sehr komplexe Betrachtungen wie Kosten-/Nutzenbeurteilungen, die Wirkung verborgener Einflüsse, die Prüfung, ob sich positive und negative Effekte gegenseitig aufheben, oder die Berücksichtigung der Latenzen zwischen einer Maßnahme und deren Wirkungen sind durch Daten nur sehr schwer zu unterstützen. Hinzu kommt, dass in den Daten identifizierte Beziehungen nicht zwingend im physischen Prozess existieren müssen oder vorhandene Beziehungen nicht mit Sicherheit gefunden werden. Dabei ist auch die Aktualität der Modelle ein Faktor, den es zu prüfen und gegebenenfalls zu berichtigen gibt. Es ist also nicht zu gewährleisten, dass die aufgrund der Datenanalyse hergeleiteten Maßnahmen die erwünschte Wirkung erzielen, wodurch der Anwender weiterhin die Verantwortung für die durch ihn getroffenen Entscheidungen trägt.

Dies betrifft auch die Ableitungen, die hinsichtlich der Kennzahlensysteme von Unternehmen getroffen werden. Ein Kennzahlensystem ist wegen unzureichender statistischer Nachweisbarkeit zwar zu hinterfragen, aber nicht grundsätzlich als ungül-

tig zu betrachten. Gleichermaßen ist ein Kennzahlensystem aufgrund guter analytischer Nachvollziehbarkeit nicht automatisch vollständig oder bestmöglich konstruiert. Dennoch leisten Advanced Analytics-Algorithmen eingegliedert in die Methode für die Digitale Unternehmenssteuerung bei funktionsgemäßem Einsatz vielfältige positive Beiträge für die kennzahlenbasierte Unternehmenssteuerung.

Herausforderungen
- Die Auswahl geeigneter Kennzahlen ist entscheidend für die Qualität der Ergebnisse - Eine Vollständigkeit der Erfassung von Ursache-Wirkbeziehungen ist nicht anzunehmen - Singuläre oder unerwartete Ereignisse verzerren die Analyseergebnisse - Eine hohe Datenqualität ist eine zentrale Voraussetzung für eine hohe Qualität der Ergebnisse - Mathematische Anforderungen der Algorithmen sind zu berücksichtigen und bei der Beurteilung und Interpretation der Ergebnisse kritisch miteinzubeziehen - Durch die Analyse von Daten ist nicht automatisch auf Kausalitäten oder Wirkrichtungen zu schließen - Datenanalysen enthalten in der Regel subjektive Einflüsse, die es bei der Interpretation zu berücksichtigen gilt - Entscheidungsträger müssen die gewonnenen Informationen mit ihrem impliziten Wissen verknüpfen und tragen die Verantwortung für die Schlussfolgerungen - Analyseergebnisse sind kritisch zu hinterfragen - Nicht erkannte Ursache-Wirkbeziehungen können existieren; erkannte statistische Beziehungen müssen in der Praxis nicht existieren

Tabelle 6-2: Herausforderungen des Einsatzes von Advanced Analytics-Algorithmen

Die Vision der Digitalen Unternehmenssteuerung in Kapitel 1.3 beinhaltet schwerpunktmäßig die Nutzung der Potentiale der Digitalisierung, insbesondere von Advanced Analytics, für eine proaktive, kennzahlenbasierte Unternehmenssteuerung. Sie impliziert einen fundamentalen Wandel der Nutzung von Kennzahlen und der Steuerung in Unternehmen. Die in dieser Dissertation erzeugte Methode leitet Unternehmen bei der Realisierung dessen an. Ein wesentlicher Beitrag ist die quantitative Analyse der Kennzahlendaten von Einzelprozessen sowie sequentiell, parallel und hierarchisch angeordneter Prozesse zur Schaffung von Transparenz bezüglich deren Ursache-Wirkbeziehungen. Dies dient der in der Vision adressierten Ableitung effizienter und effektiver Maßnahmen für die Erreichung übergeordneter Unternehmensziele. Zum Einsatz kommen dabei interne sowie externe, hoch-aggregierte sowie Rohdaten. Diese bilden die Grundlage für die Erzeugung von Modellen, anhand derer Vorhersagen und Simulationen durchführbar sind, sodass sich die angestrebte Positivspirale leistungsverbessender Handlungen und Steuerungsmaßnahmen ergibt und die Leistungsfähigkeit von Kennzahlensystemen steigt. Die Ergebnisse zeigen demnach, dass die Hypothese eines fundamentalen Wandels der Unternehmenssteuerung unter Zuhilfenahme fortgeschrittener Datenanalysealgorithmen zu akzeptieren ist (vgl. Kapitel 1.3).

6.2 Beurteilung der Ergebnisse nach Design Science Research

Wie in Kapitel 1.4 avisiert, erfolgt die Beurteilung der in der vorliegenden Dissertation erzeugten Ergebnisse gemäß der *Leitlinien des Design Science Research* nach [Hevner et al. 2004, 82 ff.]:

Als erstes benennen diese das „Design as an Artifact". Darunter ist zu verstehen, dass Design Science Research ein brauchbares und zukunftsfähiges Artefakt in Form eines Konstruktes, eines Modells, einer Methode oder einer Instanziierung hervorbringen muss. In Orientierung an dem etablierten Methoden Engineering nach [Gutzwiller 1994] wurde die Methode für die Digitale Unternehmenssteuerung entwickelt und die Beziehungen zwischen den Elementen der Methode dargelegt, sodass ein entsprechendes, neues Artefakt als Resultat der durchgeführten Forschung zur Verfügung steht.

Zweitens muss das erstellte Artefakt nach Design Science Research eine Lösung für relevante und wichtige Probleme in der Unternehmenswelt darstellen. Dazu ist die Akzeptanz des Beitrages zu adressieren, indem technologiebasierte, organisationsbasierte und anwenderbasierte Artefakte beinhaltet sind. Insbesondere im Rahmen der umfassenden Beantwortung der Teilforschungsfrage 1[53] erfolgte die Darstellung der Relevanz sowie der großen Bedeutung der untersuchten Problemstellung für Unternehmen auf Basis von wissenschaftlicher Literatur und zahlreichen Einblicken in die Praxis. Ferner zeigt die detaillierte Beantwortung der Teilforschungsfrage 2[54] die große Divergenz hinsichtlich des Einsatzes fortgeschrittener quantitativer Analysemethoden zwischen dem aufgezeigten Zielzustand und der tatsächlichen Kennzahlensteuerung in Unternehmen auf. Die Interaktion der beteiligten Personen, der organisatorischen Rahmenbedingungen und Auswirkungen sowie der Informationstechnologie bildete dabei stets die thematische Klammer. In besonderem Maße zeigt sich dies in der Methode selbst.

Der dritte Aspekt der Leitlinien des Design Science Research ist die „Design Evaluation", welche fordert, dass der Nutzen, die Qualität und die Wirksamkeit des Artefaktes mittels geeigneter Evaluationsmethoden zu demonstrieren ist. Zu beantworten ist dabei, ob die Anforderungen und Einschränkungen der Problemstellung berücksichtigt und gelöst wurden. Nach der umfassenden Untersuchung der betrieblichen und analytischen Anforderungen und Einschränkungen und der Entwicklung von Lösungsansätzen, wurden diese anhand von Anwendungsfällen in der Praxis in

[53] TFF 1: Welche Herausforderungen stellen sich dem Management großer Produktionsunternehmen bei der kennzahlenbasierten Unternehmenssteuerung?

[54] TFF 2: Wie können Kennzahlenrelationen zur Entscheidungsunterstützung in der Unternehmenssteuerung analysiert werden?

der Tiefe untersucht und schrittweise in einem ´Generate/Test Cycle` weiterentwickelt. So erfolgte die differenzierte Darlegung des Nutzens, der Qualität und der Wirksamkeit der Erzeugnisse.[55]

Viertens müssen die Forschungsergebnisse klare und verifizierbare Beiträge liefern. Dies wird im Design Science Research häufig durch das Artefakt selbst erbracht. [Beverungen et al. 2017, 138 f.] sehen als eine Quelle von Innovationen für Services die Rekombination bestehender Lösungen und nennen dafür vier grundlegende Prinzipien. Diese können, wie in Abb. 6-1 dargestellt, auch auf weitere Anwendungsbereiche zum Beispiel in Form eines ´Recombinant Innovation Engineering´ übertragen werden.

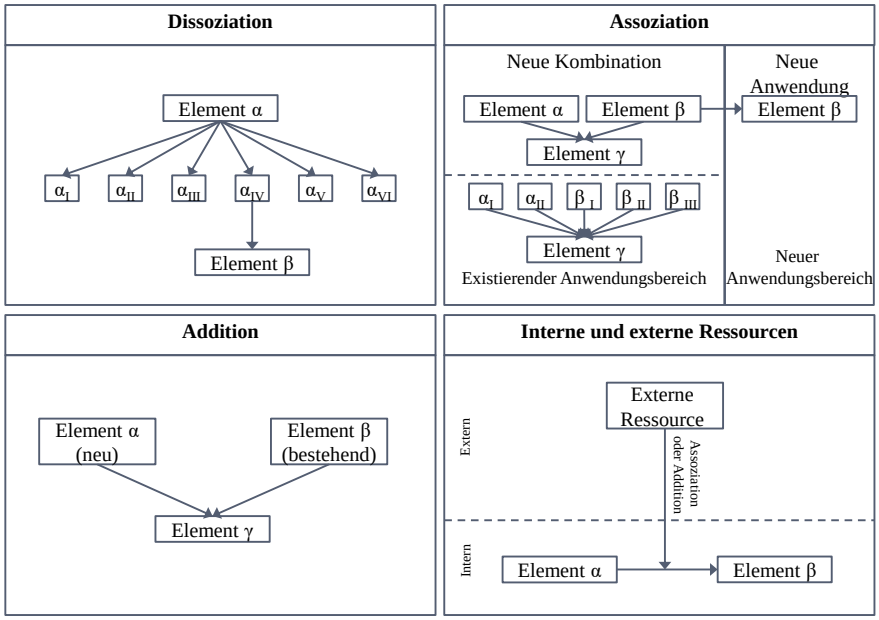

Abb. 6-1: Prinzipien rekombinanter Innovationen
(in Anl. an [Beverungen et al. 2017, 139])

Bei der Dissoziation wird ein bestehendes Element in einzelne Teilelemente heruntergebrochen und eines oder mehrere davon zur Problemlösung eingesetzt (z. B. Aufteilung von Software-Komplettlösungen in Microservices). Die Addition beschreibt den Fall, dass zu einem bestehenden Element ein neues hinzugefügt und somit Innovation geschaffen wird (z. B. Staubsaugerroboter, welche klassische Staubsauger und Vorteile von moderner Software und Sensorik kombinieren). Die

[55] Siehe dazu auch Abb. 5-1 und Design Evaluation Methods: Observational – Case Study [Hevner et al. 2004, 86].

dritte Form der rekombinanten Generierung von Innovationen basiert auf der Zusammenführung interner und externer Ressourcen, wie beispielsweise Wissen (z. B. personalisierte Werbung durch Nutzung extern beschaffter Kundendaten). Das letzte Prinzip rekombinanter Innovationen ist die Assoziation, bei welcher zwei oder mehrere existierende Elemente auf neuartige Weise kombiniert und (teilweise) auf neue Bereiche angewendet werden (z. B. die Anwendung von Drohnentechnologie und Quadrocoptern für die Auslieferung von Paketen).

Die Vision und die Methode für die Digitale Unternehmenssteuerung sind Innovationen im Sinne der Assoziation. Schwerpunktmäßig verwenden und kombinieren sie Elemente aus den Bereichen Controlling, Business Intelligence und Analytics auf eine neue Art und Weise. Für die Wissenschaft erzeugt die vorliegende Dissertation somit Beiträge, indem sie für das Controlling der Zukunft einen noch stärkeren Fokus auf die (fortgeschrittene) Analyse von Kennzahlendaten, insbesondere bezüglich des automatisierten Lernens von Ursache-Wirkbeziehungen, legt. Dazu bietet sie einen Überblick und eine Klassifizierung von Ansätzen aus der wissenschaftlichen Literatur und liefert darauf aufbauend Belege für die empirische Nachweisbarkeit von Ursache-Wirkbeziehungen. Damit reichert sie die kontroverse wissenschaftliche Diskussion (vgl. Kapitel 2.5) hinsichtlich der Machbarkeit an. Darauf aufbauend bieten sich neue Möglichkeiten, erfolgreiche und etablierte Werkzeuge für die qualitative Analyse von Kennzahlenrelationen wie die BSC um quantitative Elemente zu ergänzen oder die Erfüllung von Kriterien für die Eignung von Kennzahlen, wie beispielsweise [Richter 2007] sie in seiner Dissertationsschrift nennt, quantitativ unterstützt zu prüfen.

Die Digitale Unternehmenssteuerung bietet überdies neue Perspektiven für die kennzahlenbasierte Unternehmenssteuerung. Sie erweitert die Theorie und das Verständnis, indem die Kennzahlen nicht mehr für sich allein als Prozessmessgrößen in Kennzahlensystemen stehen, sondern als Informationsquelle für Prozessinterdependenzen dienen. Dafür benennt die vorliegende Dissertation Anforderungen an die kennzahlenbasierte Unternehmenssteuerung. Zudem zeigt die Fallstudie die erfolgreiche Zusammenführung klassischer Prozessmessgrößen mit externen Daten wie zum Beispiel Feiertagen durch die Nutzung von Advanced Analytics Werkzeugen auf. Letztere ermöglichen mehr als zuvor die Zusammenführung operativer, strategischer, überbetrieblicher sowie externer Kennzahlendaten. Dies bietet neue Chancen für die Forschung und die Entwicklung zukünftiger Methoden für die Erzeugung von Kennzahlensystemen über die Kombination klassischer, monetär ausgerichteter Controlling-Größen mit Kennzahlen des Prozesscontrollings hinaus.

Maßgeblich dafür ist das generische Prozessverständnis, welches die silo-, hierarchie- und unternehmensübergreifende Verknüpfung der Prozessdaten fördert. Die Integration dieser Kombination von Controlling und Analytics in die Business Intelligence, welche Advanced Analytics-Funktionen derzeit kaum einschließt, adressiert mit ihren Möglichkeiten der anwenderfreundlichen Visualisierung und Interaktion zentrale Herausforderungen der kennzahlenbasierten Unternehmenssteuerung für das Management. Dazu gehören der Umgang mit sehr komplexen Syste-

men und die proaktive, wirksame Unternehmenssteuerung. Die entwickelte Methode liefert dazu einen generischen Ansatz, welcher eine hohe Integrierbarkeit in die Praxis aufweist. Dabei überträgt sie das Verständnis der Kybernetik von Sub- und Supersystemen auf Sub- und Superprozesse in Unternehmen und kombiniert dies mit Advanced Analytics-Methoden.

Innovative Beiträge für die Praxis ergeben sich unter anderem durch die Ergänzung bisher überwiegend angewendeter qualitativer Verfahren für die Analyse von Ursache-Wirkbeziehungen zwischen Kennzahlen durch anwenderfreundliche, quantitative Analysen. Elementar dafür ist die bei der BMW Group praktisch eingesetzte und im Rahmen dieser Dissertation entwickelte Software „KPI Intelligence". Darüber hinaus schafft die durchgeführte Untersuchung ein verbessertes Bewusstsein für die Notwendigkeit der silo- und hierarchieübergreifenden Analyse von Kennzahlen und der Erzeugung eines wirksamen Kennzahlensystems. Die Methode für die Digitale Unternehmenssteuerung dient der Orientierung bei der Umsetzung dessen. Folglich sind klare und verifizierte Beiträge durch die Forschung erbracht worden.

Die Leitlinie Nummer fünf des Design Science Research verlangt die Anwendung von Methoden mit hinreichender wissenschaftlicher Strenge bei der Konstruktion sowie Evaluation von Artefakten. Die wissenschaftliche Lücke bezüglich der drei Bereiche Controlling, Business Intelligence und Analytics, die den Schwerpunkt der Forschung darstellten, sowie derzeit in der Praxis angewandter Methoden zur Analyse von Ursache-Wirkbeziehungen wurden umfassend dargelegt und bestehende Erkenntnisse zur Problemlösung zusammengeführt und ergänzt. Unter Vermeidung von exzessivem Formalismus wurde der Stand der Technik beschrieben und mit Hilfe bewährter wissenschaftlicher Methoden eine Lösung erarbeitet. Dessen Anwendbarkeit und Generalisierbarkeit wurden unter geeigneten Rahmenbedingungen in der betrieblichen Praxis erprobt und bestätigt.

Sechstens fordert die Design Science Research für die Suche nach geeigneten Artefakten die Anwendung verfügbarer Mittel zur Erreichung der Zielstellung in Form eines Prozesses und gleichzeitigem Gerecht-werden der Bedingungen des Problemumfeldes. Diese Bedingungen wurden initial ausführlich untersucht und in Form von Anforderungen und Leitmerkmalen transparent aufgeführt. Anhand der Anwendungsfälle zeigte sich, dass sie ihre erzielte Wirkung entfalten, indem sie eine Orientierung bei der Einschätzung von erzeugten Lösungen geben und den Einsatz von Advanced Analytics für die Analyse von Kennzahlenrelationen fördern: Es erfolgte ein mehrstufiger Prozess, dessen (Zwischen-) Ergebnisse die Bedingungen, jeweils als Teilprobleme fokussiert, bei der praktischen Erprobung schrittweise immer besser erfüllten.

Letztlich müssen die mittels Design Science Research erzeugten Ergebnisse kommuniziert und sowohl technologieorientiertem, als auch managementorientiertem Publikum zugänglich gemacht werden. Wie in Abb. 1-3 dargestellt, wurden die Forschungsergebnisse in Form von Beiträgen auf wissenschaftlichen wie auch praxisorientieren Konferenzen vorgestellt sowie in der vorliegenden Dissertationsschrift

zugänglich gemacht. Insbesondere letztere macht die schrittweise (Weiter-) Entwicklung der Methode für die Digitale Unternehmenssteuerung und des KPI Intelligence Tools transparent. Dazu wurde gezielt deren Anwendbarkeit in der Praxis adressiert, um die Lücke zwischen wissenschaftlichen Erkenntnissen und dem Einsatz in der Praxis zu schließen und den Ad-hoc-Charakter rein technologieorientierter Ansätze zu vermeiden (siehe Kapitel 3.2 und [Hevner et al. 2004, 98]). Des Weiteren erfolgte eine umfangreiche Kommunikation innerhalb der BMW Group.

Folglich fanden alle sieben Leitlinien des Design Science Research Anwendung. Der Einordnung der Ergebnisse dient darüber hinaus die kritische Würdigung im nächsten Kapitel.

6.3 Kritische Würdigung

Wie einleitend in Kapitel 1 erwähnt, hängt die digitale Transformation in Unternehmen von einer Vielzahl von Faktoren ab. Die Entwicklung und Evaluation der Methode für die Digitale Unternehmenssteuerung in direktem Praxisumfeld lässt zahlreiche Rückschlüsse für die Gestaltung dieser Transformation zu. Diese sind in Tabelle 6-3 zusammengefasst. So liegen nun Belege vor, dass Advanced Analytics Algorithmen für die kritische Prüfung mentaler Modelle für die Steuerung von Unternehmensprozessen sinnvoll einsetzbar sind. Die Anwender waren schnell in der Lage, die Methode anzuwenden und konnten die Ergebnisse gut interpretieren. Ferner brachten sie diesen ein hohes Maß an Vertrauen entgegen. Allerdings verlangt die Anwendung der Methode für die Digitale Unternehmenssteuerung statistisches Grundwissen seitens der Anwender. Demnach sind umfangreiche Qualifizierungsmaßnahmen für entsprechende Aufgabenträger in den Unternehmen vonnöten. Diese sollten unter anderem Inhalte hinsichtlich statistischer Methoden, deren Interpretation sowie kritische Auseinandersetzung mit den Ergebnissen einschließen. Ein Beispiel für die Notwendigkeit solcher Maßnahmen betrifft die diskutierte Objektivität von Datenanalysen. Sie stellt einen maßgeblichen Vorteil quantitativer Analysen gegenüber qualitativen Analysen dar. Das Vorgehensmodell in Abb. 4-2 verdeutlicht allerdings anhand der Markierungen hinsichtlich der überwiegend qualitativen oder quantitativen Eigenschaften der drei Analysephasen (Initialisierung, Analyse, Realisierung), dass subjektive Einflüsse der Anwender unumgänglich sind. Die Prozessmodellierung sowie Datenbereinigung ebenso wie die Analyse der Informationen, die Prüfung auf Kausalitäten und das Ziehen von Schlussfolgerungen gemäß dem individuellen Wissensstand des Anwenders reduzieren die Objektivität. Nichtsdestotrotz erfolgt die Analyse der Ursache-Wirkbeziehungen zwischen den Kennzahlen deutlich objektiver als dies bisher qualitative Methoden ermöglichen. Dessen sollten sich die Anwender der Methode bewusst sein.

Zusätzlich zu der Eignung von Advanced Analytics Algorithmen für die kritische Prüfung mentaler Modelle zeigt sich deren sinnvolle Einsetzbarkeit zur Analyse prozess- und hierarchieübergreifender Kennzahlenrelationen. Der vereinfachte Zu-

griff auf die Algorithmen führte zu einer großen, dauerhaften Bereitschaft der Anwender, Prozesse zu modellieren und zu analysieren. Herausforderungen stellten sich dabei bezüglich der Datenverfügbarkeit und der Datenqualität. Diese gilt es bei der Weiterentwicklung der Prozesssteuerung für Produktionsunternehmen im Allgemeinen potentialorientiert zu berücksichtigen. Die Weiterentwicklung sollte auch Steuerungsmechanismen beinhalten, die es dem Anwender vereinfachen, die Erkenntnisse aus den Analyseergebnissen in die unternehmerische Praxis zu überführen. Einen wesentlichen Einfluss darauf hat der notwendige kulturelle Wandel hinsichtlich der Kennzahlensteuerung in Unternehmen, der für die Einführung der Digitalen Unternehmenssteuerung notwendig ist. Findet der Wandel nicht statt, können digitale Hilfsmittel und analytische Methoden ihre Wirkung nicht oder nur beschränkt entfalten. Trotz derzeit noch bestehender Hürden stießen die beschriebenen Aktivitäten kreative Prozesse für Verbesserung der zukünftigen Unternehmenssteuerung (z. B. bezüglich der Zielwerttabelle) an.

Hinsichtlich der angewandten Advanced Analytics Algorithmen ist hervorzuheben, dass die Techniken in dem untersuchten Kontext eines beispielhaften großen Produktionsunternehmens geeignet waren. Je nach Fragestellung oder auch verfügbarer Datenstruktur kann sich die Verwendung anderer oder ergänzender Techniken anbieten. Allerdings kam die Methode für die Digitale Unternehmenssteuerung innerhalb des Unternehmens in sehr unterschiedlichen Anwendungsfällen in verschiedenen Fachbereichen an mehreren Unternehmensstandorten unter Verwendung von Daten vielfältigen Ursprungs und mit verschiedenen Charakteristika zum Einsatz. Dabei bewährte sich die getroffene Auswahl der Algorithmen, sodass von einer Übertragbarkeit der Lösungen auszugehen ist.

Eine Evaluierung der Ergebnisse im überbetrieblichen Kontext ist im Rahmen dieser Arbeit noch nicht erfolgt. Insofern ist dieser Teil der Vision der Digitalen Unternehmenssteuerung zukünftig zu realisieren. Da aber keinerlei Unternehmensspezifika in den Beitrag eingeflossen sind, ist wiederum die Übertragbarkeit auf andere Unternehmen und Prozesse anzunehmen. Dies stützt der Einsatz in diversen Prozessen. Jedenfalls dient die diskutierte Lösung der Orientierung und als Best Practice für zukünftige Analysen.

Der vielseitige praktische Einsatz der Methode und der entwickelten technischen Lösung ermöglicht ferner die qualitative Nutzenbeurteilung anhand des Anwenderfeedbacks. Da aber, wie zuvor diskutiert, in der Regel ein wesentlicher zeitlicher Versatz zwischen der Identifikation von Maßnahmen und der vollständigen Entfaltung der Wirkung vorliegt und die Anpassung der kennzahlenbasierten Unternehmenssteuerung ein langfristiges Unterfangen ist, war zum Zeitpunkt der Beendigung des Dissertationsprojektes eine wirtschaftliche Nutzenbewertung noch nicht möglich.

Chancen
- Sinnvolle Einsetzbarkeit von Advanced Analytics zur kritischen Prüfung mentaler Modelle belegt - Anwender verstehen schnell, wie die Methode anzuwenden ist und können die Ergebnisse gut interpretieren - Großes Vertrauen in statistische Ergebnisse - Sinnvolle Einsetzbarkeit von Advanced Analytics zur Analyse prozess- und hierarchieübergreifender Kennzahlenrelationen belegt - Vereinfachter Zugriff auf Advanced Analytics Algorithmen - Große, dauerhafte Bereitschaft der Anwender, Datenanalysen durchzuführen und eigene Prozesse zu modellieren - Prozess zur Verbesserung der Unternehmenssteuerung angestoßen - Sehr hohe Variantenvielfalt bei Anwendungsfällen während praktischem Einsatz der Methode
Herausforderungen
- Qualifizierungsmaßnahmen hinsichtlich statistischer Methoden nötig - Subjektive Einflüsse durch den Anwender sind auch bei der Datenanalyse unumgänglich - Datenverfügbarkeit und Datenqualität erschwerten teilweise die Analyse - Übertragung der Ergebnisse der Datenanalyse in die unternehmerische Praxis war bei aktuellen Prozesskonfigurationen teilweise schwierig - Wandel der der Kultur von Unternehmen bezüglich der Kennzahlensteuerung nötig - Anwendung der Methode erfolgte in nur einem großen Produktionsunternehmen - Überbetrieblicher Einsatz nicht erfolgt - Wirtschaftliche Vorteile waren schwer zu bestimmen

Tabelle 6-3:Rückschlüsse für die Gestaltung der digitalen Transformation in Unternehmen

6.4 Ausblick

Da die Vision der Digitalen Unternehmenssteuerung einen neuen Ansatz darstellt, gibt es zahlreiche interessante Fragestellungen, die zu deren zukünftigen Realisierung zu untersuchen sind. So ist zu klären, inwiefern sich die kennzahlenbasierte Unternehmenssteuerung transformieren muss, um die Potentiale neuer, digitaler Technologien bestmöglich auszuschöpfen und wie diese Transformation zu steuern ist, ohne dass sich die Menschen, die mit diesen Technologien zukünftig arbeiten sollen, von der Entwicklung überholt fühlen[56]. Zentrale Elemente sind dabei vertrauens- und fortbildende Maßnahmen, zur Vermittlung von entsprechendem Know-how. Ferner spielt bei der zukünftigen Gestaltung von Unternehmensorganisationen und Prozessstrukturen die Gewährleistung der Erhebung hochqualitativer

[56] "Research over the years suggests that the overall failure rate of IT projects is around 70%. We know that when IT projects fail, it is usually not because the technology didn't work (although this can sometimes be the case), but because the changes required at an organizational and employee level weren't managed effectively. Quite simply, adding technology does not automatically confer expected benefits; these benefits have to be unlocked and this can only happen through achieving organizational changes." [Peppard 2016]

Daten (auch im überbetrieblichen Kontext) eine wichtige Rolle, da zu erwarten ist, dass der Mehrwert quantitativer Optimierungen und Entscheidungen den zusätzlichen Planungsaufwand deutlich übersteigen wird. Daraus folgen interessante Fragestellungen hinsichtlich der Integration derartiger Daten und Technologien in etablierte Management-Werkzeuge mit derzeit überwiegend qualitativer Ausrichtung wie der BSC.

Weitere Möglichkeiten werden ständig neu entwickelte Technologien, wie beispielsweise der aktuell zunehmende parallele Einsatz von Hardware-Komponenten und die gleichzeitige Verarbeitung unterschiedlicher Algorithmen (Docker-Container, Hadoop etc.), mit sich bringen. Dies eröffnet unter anderem neue Potentiale und Forschungsfelder bezüglich der hochperformanten Analyse großer Datenmengen. Neue Lösungsansätze sollten insofern hinreichend generisch erweiterbar sein, um die Integration von technischen Fortschritten in den Status quo möglichst reibungslos zu ermöglichen.

Die Generik ermöglicht auch den zukünftig zu erprobenden, überbetrieblichen Einsatz, um Ursache-Wirkbeziehungen zwischen Partnerunternehmen zu untersuchen. [Sauer/Sturm 2019, 38] betonen, dass das Potential der Digitalisierung nur in vollem Umfang nutzbar ist, wenn sie nicht an den Unternehmensgrenzen Halt macht, sondern auch Kunden und Zulieferer einbindet. Einen wesentlichen Beitrag zu derartigen überbetrieblichen Datenanalysen werden zukünftig Initiativen wie Catena-X liefern. Catena-X ist eine im Jahr 2021 gegründete Allianz für sicheren Datenaustausch in der Automobilindustrie, in welcher sowohl OEMs wie auch n-tier Zulieferer beigetreten sind, um entlang der gesamten Lieferketten Daten auszutauschen, zu verknüpfen und zu analysieren. Hier bieten sich demnach Möglichkeiten, die entwickelte Methode stärker an derartige Plattformen zur überbetrieblichen Analyse anzupassen. Eine weitere Initiative, die eine überbetriebliche Analyse von Kennzahlendaten fördern könnte, ist die Open Manufacturing Platform. In dieser haben sich die BMW Group, Microsoft und weitere Partner zusammengeschlossen, um die Entwicklung innovativer Lösungen aus dem Bereich Industrie 4.0 in der Automobil- und Fertigungsindustrie voranzutreiben [BMW Group 2019]. Dazu gehört die Schaffung einer Technologieplattform mit einem offenen Datenmodell in Kombination mit einem Open-Community-Ansatz [BMW Group 2019].

Eine andere Stoßrichtung für eine Weiterentwicklung der Methode für die Digitale Unternehmenssteuerung bietet sich in im Sinne von Assistenzsystemen für die Prozesssteuerung (vgl. [Sauer/Sturm 2019, 35]). Während die Diskussion um autonom fahrende Fahrzeuge bereits in der Mitte der Gesellschaft angekommen sind, wäre zukünftig verstärkt zu untersuchen, inwiefern Prozesse anhand in Echtzeit erfasster und analysierter Daten (teil-) autonom steuerbar sind.

Neben den zukünftig zu ergänzenden Technologien stehen bereits heute zahlreiche Algorithmen zur Verfügung, deren komplementärer Einsatz die Analyse von Kennzahlenrelationen weiterhin unterstützen kann. Hier wäre zu prüfen, wie der Herausforderung zeitlicher Latenzen zwischen Ursachen und Wirkungen begegnet werden kann. Vielversprechende deskriptive Algorithmen sind beispielsweise das Dynamic

Time Warping oder auch Kreuzkorrelationen. Im prädiktiven Umfeld bieten Algorithmen wie das Reinforcement Learning Möglichkeiten, die entwickelte Lösung zu ergänzen. Präskriptive Analysen wurden nur ansatzweise konzeptionell betrachtet, sodass auch diese zukünftig umfassend zu untersuchen sind. Nicht zuletzt werden durch den Einsatz der Advanced Analytics-Algorithmen in der kennzahlenbasierten Unternehmenssteuerung neue Anforderungen, wie beispielsweise deren Generalisierbarkeit bei hoher Anwenderfreundlichkeit und hoher Vorhersagegenauigkeit, an diese gestellt. Daher wäre zu klären, welche Algorithmen und Tuningparametereinstellungen für die jeweilige Aufgabenstellung am besten geeignet sind. Forschungsansätze wie das Synthetic Reasoning können Fachanwendern bei der Interpretation der Ergebnisse jener Algorithmen helfen [Zimmermann 2019]. Daher birgt die Zusammenführung dessen mit der Digitalen Unternehmenssteuerung großes Potential.

Die Identifikation geeigneter Maßnahmen für die Steuerung von Unternehmensprozessen schließt überdies auch die Analyse von deren Wirtschaftlichkeit ein. Insofern wären in Kombination zur Digitalen Unternehmenssteuerung Ansätze für die Bewertung von Komplexität durch Ursache-Wirkbeziehungen einerseits und andererseits zur Bewertung der Aufwände, die durch das Ergreifen von Maßnahmen entstehen, zu beurteilen. Ziel dessen ist die Unterstützung von Entscheidungsträgern bei der Einschätzung von Maßnahmen hinsichtlich der Kosten, die durch diese entstehen, und des Nutzens, welcher angesichts der Gesamtheit der Interdependenzen großer Unternehmen erreichbar ist. Hilfreich können dabei auch die retrospektive Beurteilung der Wirksamkeit von Maßnahmen über einen definierten Zeitraum sein. Ideen, wie eine solche Lösung aussehen könnte, liefert zum Beispiel [Rezgui 2018]. Ferner beinhaltet der Beitrag Vorschläge zur Dokumentation von Maßnahmen.

Darüber hinaus sollten Synergien zwischen bestehenden wissenschaftlichen und in der Praxis im Einsatz befindlichen Ansätzen verstärkt genutzt werden. So stellt die Verknüpfung von Regressionskoeffizienten oder anderweitig ermittelte Einflussstärken für die Modellbeschreibung im System Dynamics-Umfeld möglicherweise eine interessante Ergänzung dar. Ebenfalls wurde während der Evaluationen des KPI Intelligence Tools wiederholt die Kombination mit Ansätzen aus dem Process Mining diskutiert und als aussichtsreich eingeschätzt. Weiterhin ist die die Zusammenführung neuerer Kennzahlen-Cockpits wie von [Hesse 2015] oder [del-Río-Ortega et al. 2017] und fortgeschrittener Analyse-Algorithmen voranzutreiben.

7 Literaturverzeichnis

Alpar, P., Alt, R., Bensberg, F., Weimann, P., Anwendungsorientierte Wirtschaftsinformatik, Springer, Wiesbaden, 2019.

Alpar, P., Schulz, M., Self-Service Business Intelligence, in: Business & Information Systems Engineering, 58, 2016, 2, S. 151–155.

Alt, R., Überbetriebliches Prozessmanagement, 1. Aufl., Logos, Berlin, 2008.

Alt, R., Electronic Markets on Digitalization, in: Electronic Markets, 28, 2018, 4, S. 397–402.

Alt, R., Leimeister, J.M., Priemuth, T., Sachse, S., Urbach, N., Wunderlich, N., Software-Defined Business, in: Business & Information Systems Engineering, 62, 2020, 6, S. 609–621.

Alt, R., Puschmann, T., Digitalisierung der Finanzindustrie, Gabler, Berlin, 2016.

Arndt, P., Eine Methode zur Erstellung eines kennzahlenbasierten Unternehmenssteuerungsmodells unter Berücksichtigung von Wirkbeziehungen zwischen Kennzahlen und Zielen, Masterarbeit, Martin-Luther-Universität Halle-Wittenberg, 2017.

Arnold, A., Liu, Y., Abe, N., Temporal Causal Modeling with Graphical Granger Methods, in: Berkhin, P. (Hrsg.), Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM Press, New York, 2007, S. 66–76.

Ashby, W.R., An introduction to cybernetics, J. Wiley, New York, 1956.

Astatkie, T., Design and Analysis of Experiments for Post Harvest Management and Value Addition Studies with Applications to Essential Oils, in: Ethiopian Journal of Applied Science and Technology, 2013, 1, S. 67–79.

Backhaus, K., Erichson, B., Plinke, W., Weiber, R., Multivariate Analysemethoden, Springer, Berlin, 2016.

Bange, C., Werkzeuge für analytische Informationssysteme, in: Gluchowski, P., Chamoni, P. (Hrsg.), Analytische Informationssysteme, 5. Aufl., Springer, Berlin, 2015, S. 97–126.

Becker, J., Holten, R., Knackstedt, R., Niehaves, B., Forschungsmethodische Positionierung in der Wirtschaftsinformatik, in: Arbeitsberichte des Instituts für Wirtschaftsinformatik, 2003, 93, S. 1–31.

Becker, J., Winkelmann, A., Handelscontrolling, Springer, Berlin, 2014.

Becker, W., Schuhknecht, F., Botzkowski, T., Die Balanced Scorecard als Instrument zur Entwicklung und Implementierung von Digitalisierungsstrategien, in: Becker, W., Eierle, B., Fliaster, A., Ivens, B., Leischnig, A., Pflaum, A., Sucky, E. (Hrsg.), Geschäftsmodelle in der digitalen Welt, Springer Fachmedien, Wiesbaden, 2019, S. 37–56.

Beer, S., Cybernetics and Management, English Universities Press, ltd., London, 1959.

Behnke, S., Dias, P., Haastert, R., Hechler, W., Luckmann, F., Kennzahlenorientierte Steuerung eines Übertragungsnetzbetreibers, in: Controller Magazin, 39, 2014, 1.

Benyon, D., Turner, P., Turner, S., Designing Interactive Systems, 1. Aufl., Addison-Wesley, Harlow, 2006.

Berger, D., Introduction to Multiple Regression, Claremont Graduate University, 2008.

Berrah, L., Foulloy, L., Towards a Unified Descriptive Framework for Industrial Objective Declaration and Performance Measurement, in: Computers in Industry, 64, 2013, 6, S. 650–662.

Beverungen, D., Lüttenberg, H., Wolf, V., Recombinant Service System Engineering, in: Leimeister, J.M., Brenner, W. (Hrsg.), Proceedings der 13. Internationalen Tagung Wirtschaftsinformatik (WI 2017), St. Gallen, 2017, S. 136–150.

Bititci, U.S., Modelling of Performance Measurement Systems in Manufacturing Enterprises, in: International Journal of Production Economics, 42, 1995, 2, S. 137–147.

BMW Group, Handbuch BMW Group Prozessmodell, München, 2016.

BMW Group, Werk Leipzig - Kennzahlen im Überblick, 2022b, URL: https://www.bmwgroup-werke.com/leipzig/de/unser-werk.html, gelesen am 20.01.2022.

BMW Group, Die Open Manufacturing Platform, 2019, URL: https://www.bmwgroup.com/de/innovation/unternehmen/open-manufacturing-cloud.html, gelesen am 15.12.2019.

BMW Group, Die BMW Group in Zahlen (2020), 2022a, URL: https://www.bmwgroup.com/unternehmen, gelesen am 20.01.2022.

Breitner, M., Vorgehensmodell, 2012, URL: http://www.enzyklopaedie-der-wirtschaftsinformatik.de/lexikon/is-management/Systementwicklung/Vorgehensmodell, gelesen am 22.12.2018.

Cai, J., Liu, X., Xiao, Z., Liu, J., Improving Supply Chain Performance Management, in: Decision Support Systems, 46, 2009, 2, S. 512–521.

Caruana, R., Lou, Y., Gehrke, J., Koch, P., Sturm, M., Elhadad, N., Intelligible Models for HealthCare: Predicting Pneumonia Risk and Hospital 30-day Readmission, in: Cao, L., Zhang, C. (Hrsg.), Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Sydney, 2015, S. 1721–1730.

Casares, D., Evaluation von Predictive Data Analytics als Entscheidungsunterstützung für eine proaktive kennzahlenbasierte Unternehmenssteuerung am Beispiel der Logistik eines Automobilherstellers, Masterarbeit, Technische Universität Berlin, 2019.

Castellanos, M., Salazar, N., Casati, F., Dayal, U., Shan, M.-C., Predictive Business Operations Management, in: Bhalla, S. (Hrsg.), Databases in Networked Information Systems. DNIS 2005. Lecture Notes in Computer Science, Springer, Berlin, 2005, S. 1–14.

Chamoni, P., Gluchowski, P., Business Analytics — State of the Art, in: Controlling & Management Review, 61, 2017, 4, S. 8–17.

Cios, K., Pedrycz, W., Swiniarski, R., Kurgan, L., Data Mining, Springer, US, 2007.

Cleff, T., Deskriptive Statistik und Explorative Datenanalyse, Gabler, Wiesbaden, 2015.

Cokins, G., Driving Acceptance and Adoption of Business Analytics, in: Journal of Corporate Accounting & Finance, 24, 2013, 2, S. 69–74.

Cundius, C., Wertbeitrag analytischer Echtzeitinformationssysteme, Dissertation, Universität Leipzig, 2018.

Dassault Systèmes, Product KPI Intelligence, 2018, URL: https://ifwe.3ds.com/industrial-equipment/equipment-intelligence/product-kpi-intelligence, gelesen am 05.01.2019.

Davenport, T.H., Cause and Effect Reporting, Harvard Business Review, 2007, URL: https://hbr.org/2007/04/cause-and-effect-reporting, gelesen am 29.11.2020.

Davenport, T.H., Business Intelligence and Organizational Decisions, in: International Journal of Business Intelligence Research, 1, 2010, 1, S. 1–12.

del-Río-Ortega, A., Resinas, M., Durán, A., Bernárdez, B., Ruiz-Cortés, A., Toro, M., Visual PPinot, in: Business & Information Systems Engineering, 5, 2017, 10, S. 28.

Delsol, J., Solloway, S., KPI Intelligence SAS, 2018, URL: https://www.kpi-intelligence.com/?lang=en, gelesen am 05.01.2019.

Deuter, A., Entwurf und Evaluierung einer kennzahlenorientierten Gestaltung des Softwareentwicklungsprozesses in produzierenden Betrieben, Dissertation, Universität Paderborn, 2018.

Deutsches Institut für Normung, Qualitätsmanagementsysteme - Grundlagen und Begriffe, DIN EN ISO 9000:2015, 2015.

Di Ciccio, C., Marrella, A., Russo, A., Knowledge-Intensive Processes: Characteristics, Requirements and Analysis of Contemporary Approaches, in: Journal on Data Semantics, 4, 2015, 1, S. 29–57.

Di Francescomarino, C., Dumas, M., Federici, M., Ghidini, C., Maggi, F.M., Rizzi, W., Predictive Business Process Monitoring Framework with Hyperparameter Optimization, in: Nurcan, S., Soffer, P., Bajec, M., Eder, J. (Hrsg.), Advanced Information Systems Engineering, Springer, New York, S. 361–376.

Diekmann, I., Sümmchen, M., Digitalisierung der Unternehmenssteuerung, 2016, URL: https://luenendonk-shop.de/out/pictures/0/lue_wp_idl_f061016_fl.pdf, gelesen am 29.08.2018.

Dittmar, C., Die nächste Evolutionsstufe von AIS: Big Data, in: Gluchowski, P., Chamoni, P. (Hrsg.), Analytische Informationssysteme, 5. Aufl., Springer, Berlin, 2015, S. 55–65.

Dittmar, C., Felden, C., Finger, R., Scheuch, R., Tams, L., Big Data, Heidelberg, 2016.

Domingos, P., A Few Useful Things to Know about Machine Learning, in: Communications of the ACM, 55, 2012, 10, S. 69–78.

Druckenmiller, D.A., Acar, W., An Agent-Based Collaborative Approach to Graphing Causal Maps for Situation Formulation, in: Journal of the Association for Information Systems, 3, 2009, 10.

Druzdzel, M.J., Flynn, R.R., Decision Support Systems, in: Bates, M.J., Maack, M.N. (Hrsg.), Encyclopedia of Library and Information Sciences, 3. Aufl., CRC Press, 2009, S. 1–9.

Ebers, Mark, Frost, Jetta, Gundei, J., Reihlen, M., Schewe, G., Wolf, J., Implikationen der Digitalisierung für die Organisation, in: Krause, S., Pellens, B. (Hrsg.), Betriebswirtschaftliche Implikationen der digitalen Transformation, Springer, Wiesbaden, 2018, S. 3–28.

Eley, M., Simulation in der Logistik, Springer, Berlin, 2012.

Entreß-Fürsteneck, M.v., Karl, J., Urbach, N., Performance Measurement im Zeitalter der Digitalisierung: Eine Balanced Scorecard für die Industrie 4.0, in: Schenk, M., Mieke, C., Berger, U., Winkler, H. (Hrsg.), Flexibilisierung der Fabrik im Kontext von Industrie 4.0, Logos Verlag, Berlin, 2017, S. 107–132.

Fayyad, U., Piatetsky-Shapiro, G., Smyth, P., From Data Mining to Knowledge Discovery in Databases, in: AI Magazine, 17, 1996a, 3, S. 37–54.

Fayyad, U.M., Piatetsky-Shapiro, G., Smyth, P., Knowledge Discovery and Data Mining: Towards a Unifying Framework, in: Simoudis, E., Han, J., Fayyad, U. (Hrsg.), Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, AAAI Press, Menlo Park, 1996b, S. 82–88.

Felden, C., Business Analytics, 2012, URL: http://www.enzyklopaedie-der-wirtschaftsinformatik.de/wi-enzyklopaedie/lexikon/daten-wissen/Business-Intelligence/Analytische-Informationssysteme--Methoden-der-/Business-Analytics, gelesen am 26.10.2018.

Felden, C., Vorausschauende Datenanalyse als Treiber der Geschäftstätigkeit, 2016, URL: http://www.sigs.de/publications/bi/2016/Predictive_AdvancedAnalytics/felden_BIS_OTS_2016.pdf, gelesen am 29.05.2020.

Field, A., Discovering Statistics using IBM SPSS Statistics, 4. Aufl., Sage, Los Angeles, 2013.

Finch, W.H., Hernández Finch, M., Multivariate Regression with Small Samples, in: General Linear Model Journal, 43, 2017, 1, S. 16–30.

Forrester, J.W., Some Basic Concepts in System Dynamics, Sloan School of Management MIT, Massachusetts, 2009.

Gericke, A., Bayer, F., Kühn, H., Rausch, T., Strobl, R., Der Lebenszyklus des Prozessmanagements, in: Bayer, F., Kühn, H. (Hrsg.), Prozessmanagement für Experten, Springer, Berlin, 2013, S. 11–33.

Ghalayini, A.M., Noble, J.S., Crowe, T.J., An Integrated Dynamic Performance Measurement System for Improving Manufacturing Competitiveness, in: International Journal of Production Economics, 48, 1997, 3, S. 207–225.

Gladen, W., Performance Measurement, 6. Aufl., Springer, Wiesbaden, 2014.

Glaser, C., Leasing A - Z - Kennzahlenbasierte Unternehmenssteuerung, Springer, Wiesbaden, 2016.

Gluchowski, P., Entwicklungstendenzen bei Analytischen Informationssystemen, in: Gluchowski, P., Chamoni, P. (Hrsg.), Analytische Informationssysteme, 5. Aufl., Springer, Berlin, 2015, S. 225–238.

Gluchowski, P., Business Analytics – Grundlagen, Methoden und Einsatzpotenziale, in: HMD Praxis der Wirtschaftsinformatik, 53, 2016, 3, S. 273–286.

Gluchowski, P., Chamoni, P., Analytische Informationssysteme, 5. Aufl., Springer, Berlin, 2015.

Gluchowski, P., Dittmar, C., Gabriel, R., Management Support Systeme und Business Intelligence, 2. Aufl., Springer, Berlin, 2008.

Granger, C.W.J., Investigating Causal Relations by Econometric Models and Cross-spectral Methods, in: Econometrica, 37, 1969, 3, S. 424.

Greiling, D., Performance Measurement in Nonprofit-Organisationen, 1. Aufl., Gabler, Wiesbaden, 2009.

Groesser, S.N., Jovy, N., Business Model Analysis Using Computational Modeling, in: Journal of Management Control, 27, 2016, 1, S. 61–88.

Gröger, C., Schwarz, H., Mitschang, B., Prescriptive Analytics for Recommendation-Based Business Process Optimization, in: Abramowicz, W., Kokkinaki, A. (Hrsg.), Proceedings of the 17th International Conference on Business Information Systems, Springer, Cham, 2014, S. 25–37.

Guschlbauer, E., Lichka, C., Umsetzung des Prozesscontrollings, in: Bayer, F., Kühn, H. (Hrsg.), Prozessmanagement für Experten, Springer, Berlin, 2013, S. 273–291.

Gustafsson, J., Singe Case Studies vs. Multiple Case Studies, Literaturreview, Halmstad University, 2017.

Gutzwiller, T., Das CC RIM-Referenzmodell für den Entwurf von betrieblichen, transaktionsorientierten Informationssystemen, Physica-Verlag HD, Heidelberg, 1994.

Halford, G.S., Baker, R., McCredden, J.E., Bain, J.D., How Many Variables can Humans Process?, in: Psychological science, 16, 2005, 1, S. 70–76.

Halper, F., Predictive Analytics for Business Advantage, Renton, 2014.

Hammer, M., Hershman, L.W., Faster Cheaper Better, Crown Business, New York, 2010.

Hänel, T., Felden, C., Operational Business Intelligence Meets Manufacturing, in: Association for Information Systems (Hrsg.), AMCIS 2013 Proceedings, Chicago, 2013, S. 1–9.

Hänel, T., Felden, C., Operational Business Intelligence im Zukunftsszenario der Industrie 4.0, in: Gluchowski, P., Chamoni, P. (Hrsg.), Analytische Informationssysteme, 5. Aufl., Springer, Berlin, 2015, S. 260–280.

Heath, F., Hull, R., Analytics Process Management, in: Fournier, F., Mendling, J. (Hrsg.), Business Process Management Workshops, Springer, Cham, 2015, S. 175–185.

Heimes, H., Kampker, A., Bührer, U., Krotil, S., Potenziale und Hürden von Data Analytics in der Serienfertigung, in: Industrie 4.0 Management, 2019, 1, S. 57–60.

Hesse, S., Struktur und Gestaltung von Informationsvisualisierungen zur Entscheidungsunterstützung, Dissertation, Technische Universität Dresden, 2015.

Hesse, S., Groh, R., Towards a Model for the Integration of Time into a Graph-based Key Performance Indicator Analysis, in: Obaid, M., Sjölie, D., Sintorn, E., Fjeld, M. (Hrsg.), Proceedings of SIGRAD 2014, Linköping University Electronic Press, Göteborg, 2014.

Hevner, A.R., March, S., Park, J., Design Science in Information Systems Research, in: MIS Quarterly, 28, 2004, 1, S. 75–105.

Heym, M., Österle, H., A Reference Model for Information Systems Development, in: Kendall, K.E., Lyytinen, K., DeGross, J.I. (Hrsg.), The impact of computer supported technologies on information systems development, North-Holland, Amsterdam, 1992a, S. 215–239.

Heym, M., Österle, H., A Semantic Data Model for Methodology Engineering, in: Forte, G., Müller, H.A., Madhavji, N.H. (Hrsg.), Proceedings, fifth International

Workshop on Computer-Aided Software Engineering, Montréal, Québec, Canada, July 6-10, 1992, IEEE Computer Society Press, Los Alamitos, 1992b, S. 142–155.

Hirzel, M., Prozess-Steuerung, in: Hirzel, M., Geiser, U., Gaida, I. (Hrsg.), Prozessmanagement in der Praxis, Gabler, Wiesbaden, 2013, S. 45–58.

Hoberecht, S., Alt, R., Studie zu Business Intelligence - Systemen im Rahmen des Projekts „KPI Intelligence“, Institut für Angewandte Informatik e. V., 2018.

Horkoff, J., Barone, D., Jiang, L., Yu, E., Amyot, D., Borgida, A., Mylopoulos, J., Strategic Business Modeling, in: Software & Systems Modeling, 13, 2014, 3, S. 1015–1041.

Horváth, P., Controlling, 11. Aufl., Vahlen, München, 2009.

Hügens, T., Balanced Scorecard und Ursache-Wirkungsbeziehungen, Gabler, Wiesbaden, 2008.

Imran, A., Zoha, A., Challenges in 5G, in: IEEE Network, 28, 2014, 6, S. 27–33.

Interview 01.02.2018, KPI Intelligence Tool - Leiter IT Werk Leipzig, Spezialist Product Portfolio Management, Spezialist Künstliche Intelligenz, BMW Group, Interviewer: Burdensky, D., Leipzig, München.

Interview 03.04.2019, KPI Intelligence Tool - Reportingspezialist Qualitätsmanagement Standort B, BMW Group, Interviewer: Burdensky, D., Leipzig, München.

Interview 09.02.2018, Leitfaden KPI Intelligence - Spezialistin Qualitätsmanagement, Reportingspezialist Qualitätsmanagement, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 12.01.2018, Leitfaden KPI Intelligence - Meister Montage, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 14.02.2018, KPI Intelligence Tool - Meister Montage, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 15.02.2018, Reporting im BMW Group Werk Leipzig - Expertin Fertigungssteuerung Montage, Expertin Produktionssteuerung, Fachprojektleiter IT, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 15.08.2018, Leitfaden KPI Intelligence -Leiter Qualitätssicherung, BMW Group, Interviewer: Burdensky, D., Hoppert, F., Leipzig.

Interview 17.04.2019, KPI Intelligence Tool - Steuerungsverantwortlicher Zielwertvereinbarung, Reportingspezialist Qualitätsmanagement Standort A, Spezialistin Qualitätsmanagement, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 17.07.2018, Leitfaden KPI Intelligence - Meisterin Montage, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 22.05.2018, KPI Intelligence - Dienstleistersteuerung Logistik, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 23.02.2018, Leitfaden KPI Intelligence - Leiterin Meisterbereiche Qualitätssicherung, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 23.04.2019, KPI Intelligence Tool - Führungskraft Produktionssystem, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 23.08.2018, Führungskräfteworkshop - Vertreter der Werkleitung, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interview 24.04.2019, KPI Intelligence Tool - Reportingspezialist Qualitätsmanagement Standort B, BMW Group, Interviewer: Burdensky, D., Leipzig, München.

Interview 25.04.2019a, KPI Intelligence Tool - Vertreter Qualitätsstrategie, BMW Group, Interviewer: Burdensky, D., Leipzig, München.

Interview 25.04.2019b, KPI Intelligence Tool - Leiter Qualitätsmanagement, Reportingspezialist Qualitätsmanagement Standort A, Spezialistin Qualitätsmanagement, Fachprojektleiter IT, BMW Group, Interviewer: Burdensky, D., Leipzig.

Interviews 01.02.2017 & 25.07.2018, KPI Intelligence Tool - Head of Reporting and Analytics, Beratungsunternehmen, Interviewer: Burdensky, D., Leipzig, Landshut.

ISO, Automation systems and integration — Key performance indicators (KPIs) for manufacturing operations management - Definitions and descriptions, ISO 22400-2, 2014.

ISO, Quality management systems - Requirements, ISO 9001:2015, 2015.

Kaiser, R., Qualitative Experteninterviews, Springer, Wiesbaden, 2014.

Kaplan, R.S., Norton, D., The Balanced Scorecard, in: Harvard Business Review, 70, 1992, 1, S. 71–79.

Karnopp, D.C., Margolis, D.L., Rosenberg, R.C., System Dynamics, John Wiley & Sons, Inc, Hoboken, 2012.

Kemper, H.-G., Baars, H., Mehanna, W., Business Intelligence – Grundlagen und praktische Anwendungen, 3. Aufl., Vieweg+Teubner, Wiesbaden, 2010.

Kieninger, M., Mehanna, W., Vocelka, A., Wie Big Data das Controlling verändert, in: Controlling, 28, 2016, 4/5.

Kieninger, M., Michel, U., Mehanna, W., Auswirkungen der Digitalisierung auf die Unternehmenssteuerung, in: Horváth, P., Michel, U. (Hrsg.), Controlling im digitalen Zeitalter, 1. Aufl., Schäffer-Poeschel, Stuttgart, 2015, S. 3–13.

Knabke, T., Olbrich, S., Grundlagen und Einsatzpotentiale von In-Memory-Datenbanken, in: Gluchowski, P., Chamoni, P. (Hrsg.), Analytische Informationssysteme, 5. Aufl., Springer, Berlin, 2015, S. 187–203.

Knobloch, B., Weidner, J., Eine kritische Betrachtung von Data Mining-Prozessen — Ablauf, Effizienz und Unterstützungspotenziale, in: Jung, R., Winter, R. (Hrsg.), Data Warehousing 2000, Springer, Heidelberg, 2013, S. 345–365.

Kober, R., Northcott, D., Testing cause-and-effect relationships within a balanced scorecard, in: Account Finance, 41, 2020, S. 1–35.

Kottbauer, M., Das BI-Haus, in: Business Reporting, 1, 2015, S. 6–9.

Kotzanikolaou, P., Theoharidou, M., Gritzalis, D., Interdependencies between Critical Infrastructures, Springer, Berlin, 2013.

Kowalczyk, M., Gerlach, J., Business Intelligence & Analytics and Decision Quality, in: Becker, J., Vom Brocke, J., Marco, M. de (Hrsg.), ECIS 2015 Completed Research Papers, 2015.

Kruse, P., Wie reagieren Menschen auf wachsende Komplexität, o. D., URL: https://www.youtube.com/watch?v=yn0MU1tW4jg, gelesen am 03.08.2018.

Kuhn, M., Johnson, K., Applied Predictive Modeling, Springer, New York, 2013.

Küpper, H.-U., Controlling, 6. Aufl., Schäffer-Poeschel, Stuttgart, 2013.

Lambeck, C., User Interfaces im Kontext von Unternehmensanwendungen, Dissertation, Technische Universität Dresden, 2015.

Laney, D., Bitterer, A., Sallam, R., Kart, L., Predicts 2013: Information Innovation, Gartner, Stamford, 2012.

Lange, I., Schneider, O., Schnetzler, M., Jones, L., Understanding the Interdependences Among Performance Indicators in the Domain of Industrial Services, in: Olhager, J., Persson, F. (Hrsg.), Advances in Production Management Systems. IFIP — The International Federation for Information Processing, Springer, Boston, 2007, S. 379–386.

Legner, C., Benchmarking informationssystemgestützter Geschäftsprozesse, Deutscher Universitätsverlag, Wiesbaden, 1999.

Linden, M., Geschäftsmodellbasierte Unternehmenssteuerung mit Business-Intelligence-Technologien, 1. Aufl., Gabler, Wiesbaden, 2016.

Lou, Y., Caruana, R., Gehrke, J., Intelligible Models for Classification and Regression, in: Yang, Q., Agarwal, D., Pei, J. (Hrsg.), Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and data Mining, Peking, 2012, S. 150–158.

Luhn, H.P., A Business Intelligence System, in: IBM Journal of Research and Development, 2, 1958, 4, S. 314–319.

Maggi, F.M., Di Francescomarino, C., Dumas, M., Ghidini, C., Predictive Monitoring of Business Processes, in: Hutchison, D., Kanade, T., Kittler, J., Kleinberg, J.M., Kobsa, A., Mattern, F., Mitchell, J.C., Naor, M., Nierstrasz, O., Pandu Rangan, C., Steffen, B., Terzopoulos, D., Tygar, D., Weikum, G., Jarke, M., Mylopoulos, J., Quix, C., Rolland, C., Manolopoulos, Y., Mouratidis, H., Horkoff, J. (Hrsg.), Advanced Information Systems Engineering, Springer, Cham, 2014, S. 457–472.

Malik, F., Strategie, 2. Aufl., Campus Verlag, Frankfurt am Main, 2013.

Malina, M., Nørreklit, H., Selto, F., Relations among Measures, Climate of Control, and Performance Measurement Models, in: Contemporary Accounting Research, 24, 2006, 3, S. 935–982.

Mariotto, F., Zanni, P., Moraes, G., What is the Use of a Single-Case Study in Management Research?, in: Revista de Administração de Empresas, 54, 2014, 4, S. 358–369.

May, G., Barletta, I., Stahl, B., Taisch, M., Energy Management in Production, in: Applied Energy, 2015, 149, S. 46–61.

Mehanna, W., Müller, F., Tunco, C., Predictive Forecasting und die Digitalisierung der Unternehmenssteuerung, in: IM+io - Fachzeitschrift für Innovation, Organisation, 2015, 4, S. 28–32.

Mertens, P., Wirtschaftsinformatik — Von den Moden zum Trend, in: König, W. (Hrsg.), Wirtschaftsinformatik ’95, Physica-Verlag HD, Heidelberg, 1995, S. 25–64.

Mertens, P., Bodendorf, F., König, W., Schumann, M., Hess, T., Buxmann, P., Mertens, Grundzüge der Wirtschaftsinformatik, Springer, Berlin, Heidelberg, 2017.

Mertens, P., Meier, M.C., Planungs- und Kontrollsysteme in der Industrie, 10. Aufl., Gabler, Wiesbaden, 2009.

Mertens, P., Zeller, A.J., Große-Wilde, J., Kooperative Vorhersage in Unternehmensnetzwerken, in: Mertens, P., Rässler, S. (Hrsg.), Prognoserechnung, Physica-Verlag HD, Heidelberg, 2012, S. 621–637.

Metzger, A., Leitner, P., Ivanovic, D., Schmieders, E., Franklin, R., Carro, M., Dustdar, S., Pohl, K., Comparing and Combining Predictive Business Process Monitoring Techniques, in: IEEE Transactions on Systems, Man, and Cybernetics, 45, 2015, 2, S. 276–290.

Moellers, T., Bansemir, B., Pretzl, M., Gassmann, O., Design and Evaluation of a System Dynamics based Business Model Evaluation Method, in: Mädche, A., Vom Brocke, J., Hevner, A.R. (Hrsg.), Designing the Digital Transformation, Springer, Cham, 2017, S. 124–144.

Moellers, T., Bansemir, B., Pretzl, M., Gassmann, O., Assessing the Usefulness of System Dynamics for Corporate BMI, 2019.

Muschter, S., IS-gestütztes Prozessmanagement, Dissertation, Universität St. Gallen, 1999.

Navrade, F., Strategische Planung mit Data-Warehouse-Systemen, 1. Aufl. Aufl., Gabler, Wiesbaden, 2008.

NCSS Statistical Software, Ridge Regression, URL: https://ncss-wpengine.netdna-ssl.com/wp-content/themes/ncss/pdf/Procedures/NCSS/Ridge_Regression.pdf, gelesen am 04.03.2019.

Neumann, S., Probst, C., Wernsmann, C., Kontinuierliches Prozessmanagement, in: Becker, J., Kugeler, M., Rosemann, M. (Hrsg.), Prozessmanagement, Springer, Berlin, Heidelberg, 2012, S. 303–325.

Ng, A., Soo, K., Data Science – Was ist das eigentlich?!, Springer, Berlin, 2018.

Norreklit, H., The Balance on the Balanced Scorecard, in: Management Accounting Research, 11, 2000, 1, S. 65–88.

Odell, J.J., A Primer to Method Engineering, in: Brinkkemper, S., Lyytinen, K., Welke, R. (Hrsg.), Method Engineering. ME 1996. IFIP — The International Federation for Information Processing, Springer, Boston, 1996, S. 1–7.

Österle, H., Business Engineering, 2. Aufl., Springer, Berlin, 1995.

Österle, H., Becker, J., Frank, U., Hess, T., Karagiannis, D., Krcmar, H., Loos, P., Mertens, P., Oberweis, A., Sinz, E.J., Memorandum zur gestaltungsorientierten Wirtschaftsinformatik, in: Zeitschrift für betriebswirtschaftliche Forschung, 2010, 62, S. 664–672.

Österle, H., Otto, B., Konsortialforschung, in: Wirtschaftsinformatik, 52, 2010, 5, S. 273–285.

Patel, B., Chaussalet, T., Millard, P., Balancing the NHS Balanced Scorecard, in: European Journal of Operational Research, 185, 2008, 3, S. 905–914.

Peffers, K., Tuunanen, T., Rothenberger, M., Chatterjee, S., A Design Science Research Methodology for Information Systems Research, in: Journal of Management Information Systems, 2007, 24, S. 1–42.

Peng, W., Sun, T., Rose, P., Li, T., Computation and Applications of Industrial Leading Indicators to Business Process Improvement, in: International journal of intelligent control and systems, 13, 2008, 3, S. 196–207.

Peppard, J., A Tool to Map Your Next Digital Initiative, 2016, URL: https://hbr.org/2016/06/a-tool-to-map-your-next-digital-initiative, gelesen am 18.04.2019.

Peral, J., Maté, A., Marco, M., Application of Data Mining Techniques to Identify Relevant Key Performance Indicators, in: Computer Standards & Interfaces, 2017, 50, S. 76–85.

Piatetsky-Shapiro, G., Brachmann, R., Khabaza, T., Kloesgen, W., Simoudis, E., An Overview of Issues in Developing Industrial Data Mining and Knowledge Discovery Applications, in: Simoudis, E., Han, J., Fayyad, U. (Hrsg.), Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, AAAI Press, Menlo Park, 1996.

Posselt, G., Mitarbeiter führen mit Kennzahlen - Attention Leadership, Springer, Wiesbaden, 2014.

Rahman, N., Feis, G.L. de, Strategic Decision-Making: Models and Methods in the Face of Complexity and Time Pressure, in: Journal of General Management, 35, 2009, 2, S. 43–59.

Rao, R.B., Fung, G., Rosales, R., On the Dangers of Cross-Validation, in: Apte, C., Park, H., Wang, K., Zaki, M. (Hrsg.), Proceedings of the 2008 SIAM International Conference on Data Mining, CD Rom, Atlanta, 2008, S. 588–596.

Reichmann, T., Hoffjan, A., Controlling mit Kennzahlen, 8. Aufl., Vahlen, München, 2011.

Rezgui, A., Decision Evaluation System, Dissertation, Carl von Ossietzky Universität, 2018.

Richter, A., Entwicklung und Umsetzung eines Kennzahlensystems zur Leistungsmessung im Karosseriebau, Dissertation, Technische Universität Dresden, 2007.

Richter, T., Entwicklung eines Konzeptes für einen zielbasierten Management Report im Werkleitungskreis des BMW Group Werkes Leipzig ausgehend von dem EFQM-Modell, Masterarbeit, Hochschule Anhalt, 2017.

Riexinger, G., Holtewert, P., Bruns, A., Wahren, S., Tran, K., Bauernhansl, T., KPI-focused Simulation and Management System for Eco-Efficient Design of Energy-Intensive Production Systems, The 22nd CIRP conference, 2015, S. 68–73.

Rodriguez, R.R., Saiz, J.J.A., Bas, A.O., Quantitative Relationships between Key Performance Indicators for Supporting Decision-Making Processes, in: Computers in Industry, 60, 2009, 2, S. 104–113.

Ropers, J., Operative Prozesse mit Kennzahlen zielorientiert steuern, in: Controller Magazin, 2013, 1, S. 4–13.

Rozinat, A., van der Aalst, W.M.P., Decision Mining in Business Processes, Beta, Research School for Operations Management and Logistics, Eindhoven, 2006.

Rüegg-Stürm, J., The New St. Gallen Management Model, Palgrave Macmillan, Houndmills, New York, 2014.

Rupprecht, M., Schweinberger, A., Kausale Zusammenhänge in der Ökonometrie - Die Granger-Kausalität am Beispiel von Immobilienvermögen und Konsum, in: WiSt - Wirtschaftswissenschaftliches Studium, 37, 2008, 12, S. 666–668.

Saaty, T.L., Decision Making with the Analytic Hierarchy Process, in: International Journal of Services Sciences, 1, 2008, 1, S. 83–98.

Sauer, K., Sturm, J., Digitale Assistenten in der Unternehmenssteuerung?, in: Controlling & Management Review, 63, 2019, 4, S. 34–44.

Schieder, C., Historische Fragmente einer Integrationsdisziplin, in: Gluchowski, P., Chamoni, P. (Hrsg.), Analytische Informationssysteme, 5. Aufl., Springer, Berlin, 2015, S. 13–30.

Schmalzried, D., Cundius, C., Franke, R., Lambeck, C., Alt, R., Zimmermann, W., Groh, R., In-Memory basierte Real-Time Supply Chain Planung, Proceedings of the 11th International Conference on Wirtschaftsinformatik, Universität, Leipzig, 2013, S. 197–211.

Schön, D., Planung und Reporting im BI-gestützten Controlling, 3. Aufl., Springer, Wiesbaden, 2018.

Schumacher, W., Maurer, M., Grundlagen der Regelungstechnik, Vorlesungsskript, Technische Universität Braunschweig, 2014.

Schwaninger, M., Intelligent Organizations, John Wiley & Sons, Ltd., 2001.

Schwaninger, M., Systemtheorie - Eine Einführung für Führungskräfte, Wirtschafts- und Sozialwissenschaftler, 3. Aufl., Institut für Betriebswirtschaft, Universität St. Gallen, St. Gallen, 2004.

Schwaninger, M., Kaiser, C., Erfolgsfaktoren organisatorischen Wandels, in: Schmalenbachs Zeitschrift für betriebswirtschaftliche Forschung, 59, 2007, 2, S. 150–172.

Senger, E., Österle, H., PROMET Business Engineering Case Studies (BECS), Universität St. Gallen, 2004.

Shimizu, S., Hyvärinen, A., Hoyer, P.O., Kano, Y., Finding a Causal Ordering via Independent Component Analysis, in: Computational Statistics & Data Analysis, 50, 2006, 11, S. 3278–3293.

Shin, Y., Chae, C.-B., Kim, S., Multiple Regression Models for a Big Data empowered SON Framework, The 7th International Conference on Ubiquitous and Future Networks, IEEE, Piscataway, 2015, S. 982–984.

Simon, H.A., Administrative Decision Making, in: Public Administration Review, 25, 1965, 1, S. 31–37.

Simon, H.A., Causal Ordering and Identifiability, in: Models of Discovery. Boston Studies in the Philosophy of Science, 1977, 54, S. 53–80.

Sprotte, A., Performance Measurement auf der Basis Performance Measurement auf der Basis von Kennzahlen aus betrieblichen Anwendungssystemen, Arbeitsberichte aus dem Fachbereich Informatik, Universität Koblenz-Landau, Koblenz, 2009.

Sterman, J.D., System Dynamics Modeling, in: California Management Review, 43, 2001, 4, S. 8–25.

Steuernagel, A., Strategische Unternehmenssteuerung im digitalen Zeitalter, Springer, Wiesbaden, 2017.

Strohhecker, J., Factors Influencing Strategy Implementation Decisions, in: Journal of Management Control, 27, 2016, 1, S. 89–119.

Sultan, N., Khedr, A., Idrees, A., Kholeif, S., Data Mining Approach for Detecting Key Performance Indicators, in: Journal of Artificial Intelligence, 10, 2017, 2, S. 59–65.

Suwignjo, P., Bititci, U., Carrie, A., Quantitative Models for Performance Measurement System, in: International Journal of Production Economics, 64, 2000, 1-3, S. 231–241.

Tax, N., Verenich, I., La Rosa, M., Dumas, M., Predictive Business Process Monitoring with LSTM Neural Networks, in: Dubois, E., Pohl, K. (Hrsg.), Advanced Information Systems Engineering, Springer, Cham, 2017, S. 477–492.

Thornton, C., Hutter, F., Hoos, H.H., Leyton-Brown, K., Auto-WEKA, in: Ghani, R., Senator, T., Bradley, P., Parekh, R., He, J. (Hrsg.), The 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, New York, 2013, S. 847–855.

Töpfer, A., Erfolgreich Forschen, Springer, Berlin, Heidelberg, 2012.

Trier, M., Bobrik, A., Neumann, N., Wyssussek, B., Systemtheorie und Modell, in: Krallmann, H., Bobrik, A., Levina, O. (Hrsg.), Systemanalyse im Unternehmen, 6. Aufl., Oldenbourg, München, 2013, S. 41–72.

Tröger, R., Supply Chain Event Management – Bedarf, Systemarchitektur und Nutzen aus Supply Chain Event Management, Dissertation, Universität Leipzig, 2014.

van der Aalst, W., Process Mining, Springer, Berlin, 2011.

van Helden, A., Buck-Emden, R., Alda, S., Präskriptive Entscheidungsunterstützung für wissensintensive Geschäftsprozesse, in: HMD Praxis der Wirtschaftsinformatik, 55, 2018, 1, S. 197–222.

Vasile, E., Carapancea, D., Nicolae-Balan, M., Types of Decisions Based on Multi-Criteria Analysis Applicable to Extractive Industry, in: Annals of the University of Petrosani, 2011, 11, S. 267–276.

Venable, J., Pries-Heje, J., Baskerville, R., FEDS: a Framework for Evaluation in Design Science Research, in: European Journal of Information Systems, 25, 2016, 1, S. 77–89.

Verein Deutscher Ingenieure, Simulation von Logistik-, Materialfluss- und Produktionssystemen, VDI 3633, 2016.

Vlaming, R. de, Groenen, P.J.F., The Current and Future Use of Ridge Regression for Prediction in Quantitative Genetics, in: BioMed research international, 2015, 178, S. 1–18.

Wallenburg, C.M., Weber, J., Ursache-Wirkungsbeziehungen der Balanced Scorecard - Empirische Erkenntnisse zu ihrer Existenz, WHU Otto Beisheim School of Management, Vallendar, 2006.

Wikfeldt, E., Generalising from Case Studies, Halmstad University, 2016.

Wilde, T., Hess, T., Forschungsmethoden der Wirtschaftsinformatik, in: Wirtschaftsinformatik, 2007, 49, S. 280–287.

Witten, I.H., Frank, E., Hall, M.A., Data Mining, 3. Aufl., Morgan Kaufmann Publisher, Cambridge, 2011.

Witten, I.H., Frank, E., Hall, M.A., Pal, C.J., Data Mining, 4. Aufl., Morgan Kaufmann Publisher, Cambridge, 2017.

Wolle, M., Entwicklung eines generischen Modells zur Herleitung neuer Kennzahlensysteme im BMW Werk Leipzig, Masterarbeit, Hochschule für Technik und Wirtschaft, 2016.

Yin, R.K., Case Study Research and Applications, 6. Aufl., Sage, Los Angeles, 2018.

Youngblood, A.D., Collins, T.R., Addressing Balanced Scorecard Trade-off Issues Between Performance Metrics Using Multi-Attribute Utility Theory, in: Engineering Management Journal, 15, 2015, 1, S. 11–17.

Zeise, N., Modellierung von Kennzahlensystemen mit BPMN, in: Engels, G. (Hrsg.), Software Engineering 2010, Ges. für Informatik (GI), Bonn, 2010, S. 63–74.

Zielonka, A., Kennzahlenorientierte Steuerung digitaler Plattformen. Neue Kennzahlen für neue Geschäftsmodelle, in: Controller Magazin, 4, 2018, 43.

Zimmermann, R., Synthetic Reasoning für BI, in: BI-Spektrum, 2019, 04, S. 18–23.

Zumstein, D., Gächter, I., Digital Analytics – Strategien im digitalen Geschäft umsetzen und mit KPIs überprüfen, in: HMD Praxis der Wirtschaftsinformatik, 53, 2016, 3, S. 371–388.

Index

Abhängige Variable 85, 87, 110, 112
Abhängigkeitsgraph 109, 121, 123, 137, 139
Accuracy 113, 146
Advanced Analytics 51, 62, 115, 161
Aktivität 67
Akzeptanz 32, 59, 103, 151, 165
Anwenderfreundlichkeit 60, 63, 118, 129, 130, 154
Artefakt 99
Ausreißer 78, 117, 135, 136, 142
Autokorrelation 113
Balanced Scorecard 31
Black Box 62
Bravais-Pearson 81, 107, 117, 121
Business Analytics 44
Business Intelligence 43
Causal Loop Diagramme 56
Cloud-Computing 131
Controlling 20
CRISP-DM 68, 97
Cross-Validation 113, 146
Data Mining 52
Datenbereinigung 78, 117
Datenreduktionsfunktion 57
Deskription 107
Deskriptiv 48, 58, 80
Deterministisch 7
Diagnostik 107
Diagnostisch 48, 58, 80
Digitale Unternehmenssteuerung 9, 96
Digitalisierung 1, 9
Durbin-Watson Test 113
Dynamic Time Warping 56
Effektivität 36
Effizienz 36
Einflussfaktorenanalyse 11
Einflussstärke 112, 146
Empirisch 32
Ensemble 143, 144
Entscheidungsbaum 56, 87, 142
Entscheidungsunterstützungssystem 5, 43
Entwurfsergebnis 67, 91
Explorativ 59
Fehlsteuerung 26, 29, 36, 161
F-Test 113
Generik 59, 64, 118, 130, 136
Granger-Kausalität 56
Gütekriterien 112, 144
Hauptkomponentenanalyse 56, 57
Hidden Layer 125
Hierarchieübergreifend 63
Hierarchisch 32, 130
Initialisierungsphase 104
Interdependenzen 6, 31, 109
Interpretierbarkeit 59, 64, 110
Intransparenz 8, 26
Kategorische Variablen 142
Kausalität 81, 108
Kennzahl 22
Kennzahlenorientierte Unternehmenssteuerung 9
Kennzahlenrelationen 115
Kennzahlensystem 31, 34, 84
Knowledge Discovery in Databases 68
Komparativ 58, 64, 118, 129
komplementär 109
Komplementär 35, 56, 58, 64, 118, 129
Komplexität 8, 30
Komplexitätsreduktion 25, 32
Konfidenzintervall 110
Konkretisierung 25
Konkurrierend 35, 109
Konsistenz 36
Kontrolle 25
Korrelation 29, 56, 107, 115
Korrelationskoeffizient 107, 121
Kybernetik 19
Latenz 56, 65, 106
Leitmerkmale 117
Lerndatensatz 146
Logisch 32
Management 9
Managementprozess 1
Mean Squared Error 147
Mentale Modelle 3
Metamodell 67, 96
Methoden Engineering 66
Metrisch 108
Multikollinearität 110, 141
Multivariate Lineare Regression 57, 81, 87, 110, 117, 129
Multivariaten Lineare Regression 125

Multivariaten Linearen Regression 111
Nachvollziehbarkeit 64, 118, 129
Neo4J 106, 109
Neuronales Netz 125, 129
Normalverteilung 108, 110
Normierung 111, 146
Nullhypothese 108
Objektivität 58, 64, 118, 129
On-Premises 131
Operational BI 45
Operations Research 90
Optimierung 11
Ordinal 136
Ordinary Least Squares Regression 110
Orientierungsfunktion 25
Overfitting 60, 129, 141, 143, 147
Parallel 130
Parametertuning 60, 130
Performance-Management-System 31
Prädiktiv 49, 58, 83
Prädiktor 110
Präskriptiv 49, 58, 89
Private Cloud 131
Proaktiv 8, 83, 116
Probabilistisch 7
Process Mining 56
Prognose 29, 49
Prozess 21
Prozessmanagement 21
Prozesssteuerung 20, 21
Prozessübergreifend 63
Public-Cloud 131
P-Wert 108
Python 106
QlikSense 121
R (Statistiksoftware) 121
R^2 113, 147
Random Forrest 143
Rangkorrelationskoeffizient 81, 136
Reaktiv 26, 29, 83, 116
Redundanz 30, 36
Regressionskoeffizient 110, 146
Reinforcement Learning 173
Reproduzierbarkeit 118
Ridge Regression 141
Robustheit 79
Rollen 67
Schieberegler 123
Self-Service BI 45
Sensitivitätsanalyse 38
Sequentiell 130
Signifikanz 108, 110, 137
Siloübergreifend 37
Simulation 5, 11, 29, 84, 116
Skalierbarkeit 59, 64, 130
Spearman 81, 136
Stepwise Multiple Linear Regression 141
Streudiagramme 108
Stützbereich 117
System Dynamics 55
Systemtheorie 19
Tabellenschlüssel 106, 134
Technik 67
Techniken 79
Testdatensatz 113, 146
Tool 67, 95
Trainingsdatensatz 113
Transparenz 25
Tuningparameter 59, 110, 118, 129, 144
Überparametrisierung 111
Unabhängige Variable 110
Unsicherheit 36
Ursache-Wirkbeziehung 34, 112
Variance Inflation Factor 141, 146
Varianz 110, 113
Vertrauen 59, 64, 88, 118
Verzielte Kennzahl 23
Vorgehensmodell 68, 97
Vorhersage 49, 113, 116
Vorhersagegenauigkeit 59, 111, 113, 114
Vorhersagegüte 127
Wirksamkeit 29
Wirtschaftlichkeit 64, 118
Zeitreihenanalyse 56

Anhang

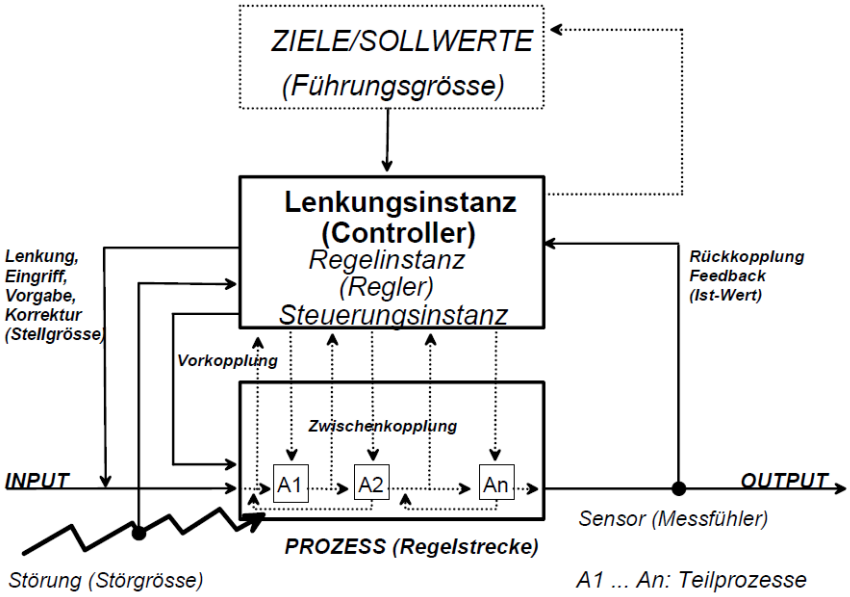

Abb. 0-1: Erweitertes Schema des Regelkreises [Schwaninger 2004, 12]

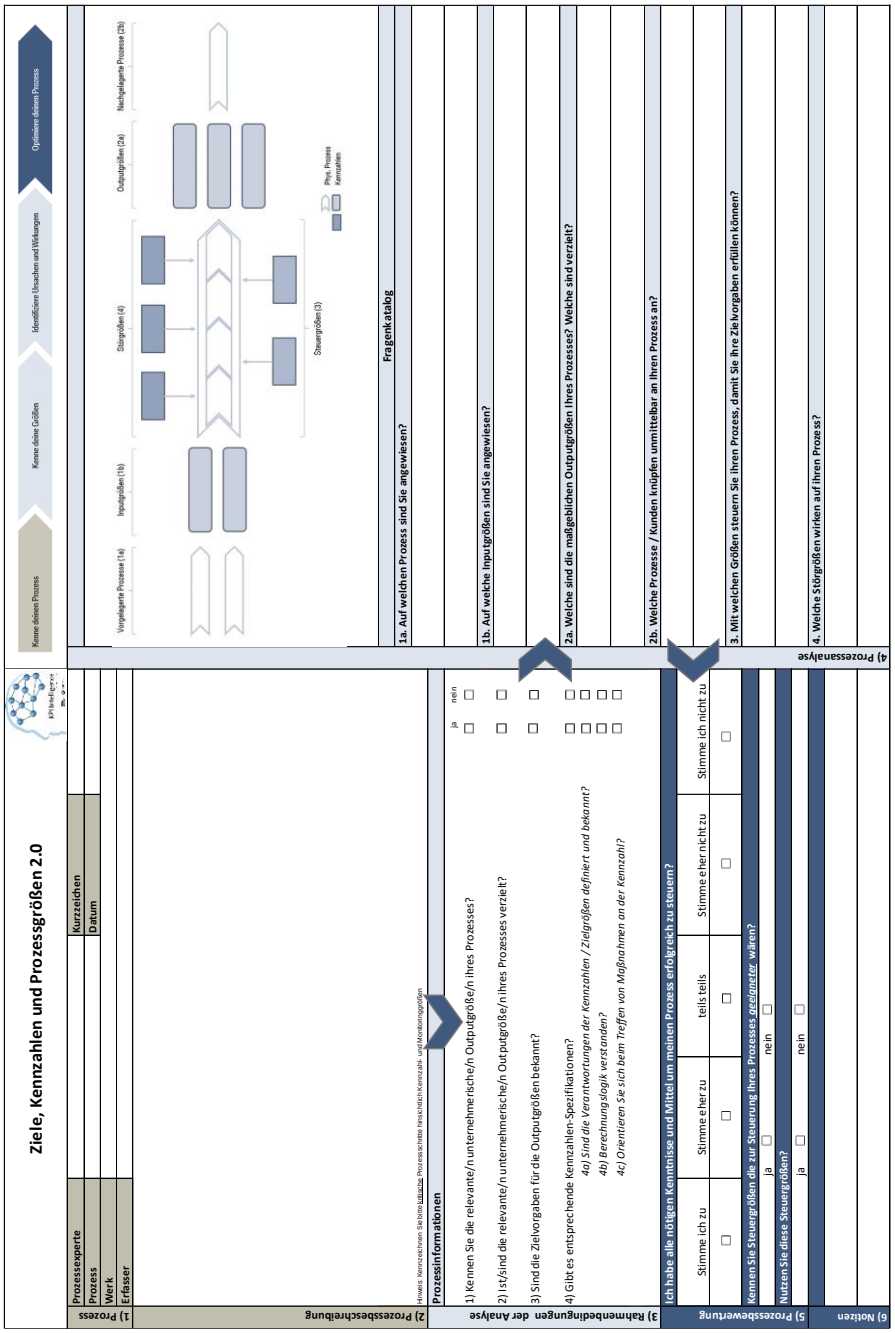

Abb. 0-2: Leitfaden KPI Intelligence

	Multiple lineare Regression	Logistische Regression	Regularisierte lineare und logistische Regression	Entscheidungsbaum (J48;C4.5;C5.0;CART;VFDT)	Entscheidungsregeln/ Entscheidungstabellen	Gradient Boosting	Random Forest	Künstliche Neuronale Netze
Robustheit	✗	○	✗	○	○	○	✓	○
Automatische Variablenauswahl	✗	✗	○	✓	✓	✓	✓	✓
Anzahl Tuningparameter	✓	✓	✓	○	○	○	✗	○
Interpretierbarkeit	✓	✗	✓	○	○	✗	✗	✗
Geringe Rechenzeit	✓	✓	✓	✓	✓	✗	○	✗
Vorhersagegenauigkeit	○	○	○	○	○	✓	✓	✓
Geeignet für numerische Variablen	✓	✓	✓	✓	✓	✓	✓	✓
Geeignet für kategorische Variablen	✗	✓	✓	✓	✓	✓	✓	✓
Geeignet für kleine Stichproben	✓	○	✓	○	○	✓	✓	○
Geeignet für große Stichproben	○	✓	✓	✓	✓	○	✓	✓
Geringe Datenvorverarbeitung	✗	○	○	✓	✓	✓	✓	○

Regressionsmethode

Klassifikationsmethode

Regressions- und Klassifikationsmethode

✓ Starke Ausprägung

○ Mittlere Ausprägung

✗ Schwache Ausprägung

Tabelle 0-1: Kriterienkatalog [Casares 2019, 67]

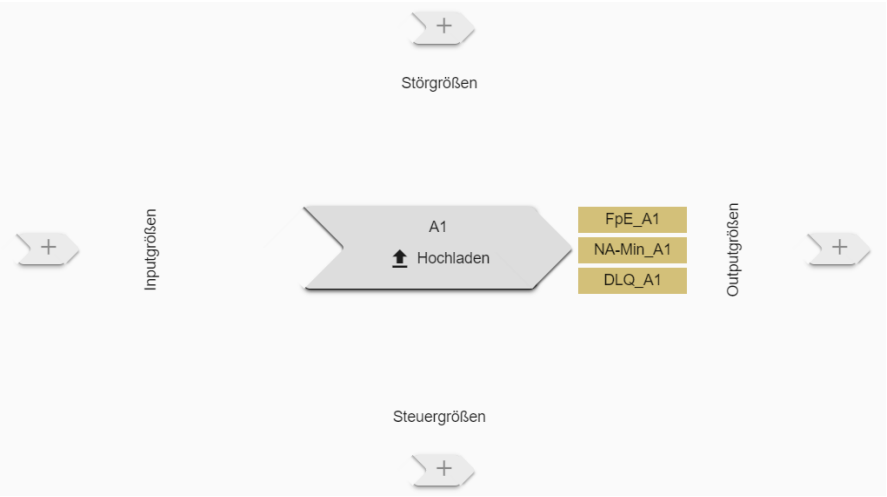

Abb. 0-3: Modellierung mehrerer Ebenen im KPI Intelligence Tool

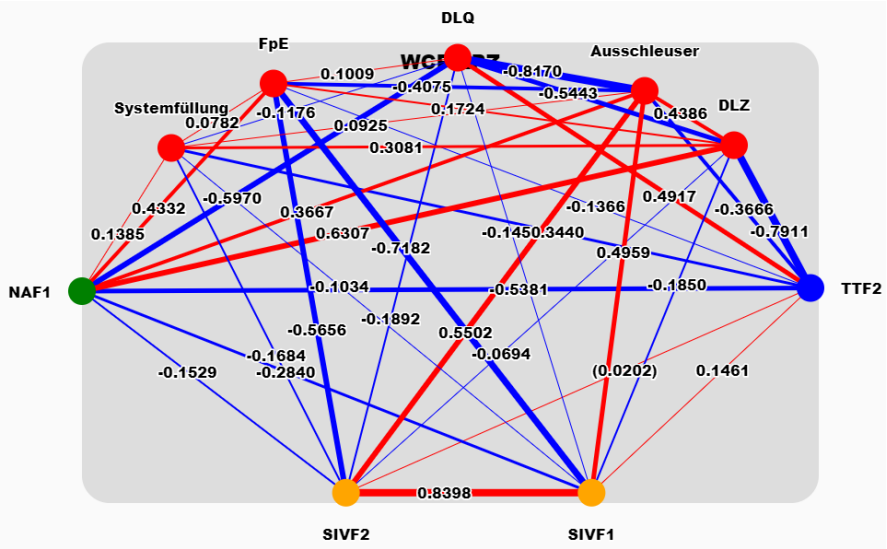

Abb. 0-4: Abhängigkeitsgraph des KPI Intelligence Tools (Ebene 1)

Abb. 0-5: Prädiktionsansicht des KPI Intelligence Tools (Ebene 1)

Interviewpartner	Zusammenfassung
Head of Reporting and Analytics Global tätiges Beratungsunternehmen 01.02.2017, 25.07.2018	- Keine Analytics-Funktionen in BI-Welt - „Es besteht eine Grenze zwischen diesen beiden Feldern…“ (zwischen BI und Analytics); - Haben intern getrennte Teams für BI und Analytics - Experten aus beiden Welten wollen diese nicht vereinen - Ansatz der Kennzahlenanalyse wie im KPI Intelligence Tool unbekannt - Einordnung Stand der Analytics-Kernaktivitäten in der BI in Abb. 3-3 bestätigt - Bei der Entwicklung von IT-Lösungen ist die Berücksichtigung des Domänenwissens extrem wichtig, da selbst fertige, jedoch nicht praxistaugliche Lösungen nicht eingesetzt werden
Meister Montage BMW Group 12.01.2018	- Meisterbereich hat die Aufgabe, die Fahrzeuge auf Fehler vorangegangener Prozesse zu prüfen und diese zu beseitigen - Erstellt Berichte unter anderem für die Kennzahl Nacharbeitsminuten - Nacharbeitsminuten, die nicht in dem Bereich verursacht wurden, fallen an - Die Kennzahl wird zwar überwacht und berichtet, eignet sich jedoch für den Meister für die eigentliche Prozesssteuerung nicht
Leiter IT Werk Leipzig, Spezialist Product Portfolio Management, Spezialist Künstliche Intelligenz BMW Group 01.02.2018	Nutzen des Tools - Wertbeitrag von Kennzahlen kann geprüft werden - Wirksamkeit der Kennzahlen ermitteln - Prozesse sind anhand der richtigen Größen analysierbar - Redundante Kennzahlen können eliminiert werden - „Richtige“ Interpretation von Wirkbeziehungen zwischen Kennzahlen auf Basis quantitativer Informationen - Hinleiten zu den richtigen, wirksamen Maßnahmen - Nicht zielführendes Reporting verhindern - „Enabling“ des Managements Herausforderung: - Nutzen der Anwendung schlecht ausweisbar
Spezialistin Qualitätsmanagement, Reportingspezialist Qualitätsmanagement BMW Group 09.02.2018	- Daten modellierter Kennzahlen können nicht einfach abgezogen und die Analysen durchgeführt werden - Kennzahlenexperten müssen validieren, ob die Kennzahlen gemäß Berechnungslogik und Prozesslogik die Aussage treffen können, die im Anschluss an das Interview untersucht werden sollen

Interviewpartner	Zusammenfassung
Meister Montage BMW Group 14.02.2018	- Die Analyse des Einflusses der Outputgrößen auf die Input-/Outputgrößen des nachgelagerten Prozesses wären interessant - eine solche Auswertung erfolgt derzeit nicht - Probleme aus vorgelagertem Prozess werden nur physisch durch Prozesssteuerer und Vorarbeiter erkannt; dessen Kennzahlen sind nicht einsehbar, sofern dieser in einem anderen Kennzahlenbereich liegen
Expertin Fertigungssteuerung Montage, Expertin Produktionssteuerung, Fachprojektleiter IT BMW Group 15.02.2018	- Die Art der Berichte und Visualisierungen ist abhängig von den unterschiedlichen Anforderungen der Führungskräfte - Berichte beinhalten überwiegend Diagramme mit Kennzahlen über die Zeit, Sollwert, Istwert, Vorjahreswert, Durchschnittswert usw. - Vereinzelt werden Korrelationen berechnet oder paarweise Betrachtungen durchgeführt - Wie weit Kennzahlen heruntergebrochen werden, hängt von den Führungskräften ab - Erfassung der Kennzahlen auf verschiedenen Ebenen erfolgt im Zielemanagementsystem und dient u. a. dem Nachweis, dass die verzielten Kennzahlen auch zur Steuerung genutzt werden, was bei externen Audits eine zentrale Anforderung ist - Bei Abweichungen von Zielwerten müssen Führungskräfte ein Abweichungsdokument erstellen - Es besteht die Tendenz eher mehr Kennzahlen zu berichten und mit Zielvorgaben zu versehen, als diese zu reduzieren
Leiterin Meisterbereiche Qualitätssicherung BMW Group 23.02.2018	- Der eigene Beitrag der Mitarbeiter für die Werkskennzahlen muss nachvollziehbar sein - Es besteht großes Interesse an quantitativen Kennzahlenanalysen zur Steigerung der Transparenz hinsichtlich der positiven/negativen Auswirkungen von Maßnahmen - Aktuelle Kennzahlensteuerung verleitet zu reaktivem Handeln, da erst eingegriffen wird, wenn Schwellwert überschritten ist - Kennzahlendaten sind vorhanden, werden aber nicht umfassend genutzt - Eine Maßnahme, die die Kennzahlen nicht positiv beeinflusst, wird nicht durchgeführt - Die Kennzahlensteuerung erfolgt überwiegend reaktiv

Interviewpartner	Zusammenfassung
Dienstleistersteuerung Logistik BMW Group 22.05.2018	Optimierungsszenario: - Anlage in der Logistik fällt aus → hochfrequente Versorgung der Montage wird unterbrochen - Montage produziert weiter und braucht alle Bestände am Band auf - Logistik kann nicht flächendeckend nachversorgen, sondern nur punktuell auffüllen - Fahrzeuge werden so weit wie möglich fertiggestellt und fehlende Teile in der Nacharbeit ergänzt, wodurch die Nacharbeitsmitarbeiter vor große Herausforderungen gestellt werden → das Problem verlagert sich aus der Logistik über die Montage in die Nacharbeit - Fragestellung: Wann ist es sinnvoll, die Produktion zu unterbrechen, um anschließend einen stabilen Prozessfortlauf zu gewährleisten
Meisterin Montage BMW Group 17.07.2018	- Maßnahmen werden in Orientierung an den Kennzahlen getroffen - Zielvorgabe erfolgt bis auf Meisterebene - Meisterin trifft mit Vorarbeitern Vereinbarungen derselben Kennzahlen, überwacht sie aber nicht konsequent, da die Werte zu kleinteilig sind - Sie dienen als Grundlage zur Besprechung von Problemen - Zusätzliche Kennzahlen zur internen Steuerung werden definiert, aber nicht mit Vorgesetzten vereinbart - Kennzahlen sollten für die gesamte Abteilung und nicht nur die einzelnen Meisterbereiche betrachtet werden - Sofern falsche Kennzahlen vereinbart werden, wird das System falsch gesteuert, da versucht wird, eigene Zielvorgaben zu erreichen
Leiter Qualitätssicherung BMW Group 15.08.2018	- Das Ableiten von Maßnahmen erfolgt anhand der Zielvorgaben für Kennzahlen - Eigene, nicht verzielte Kennzahlen werden erstellt und erfasst, um den verantworteten Prozess zu steuern, aber nicht an Vorgesetzten weitergegeben - Kennzahlensteuerung erfolgt reaktiv - Es existieren redundante Kennzahlen, die Aufwände verursachen

Interviewpartner	Zusammenfassung
Vertreter der Werkleitung BMW Group 23.08.2018	- Die Dynamik in der Wirtschaft steigt - Die Komplexität der Unternehmenssteuerung hat stark zugenommen - Wirkzusammenhänge müssen schneller verstanden werden - Schnelle und richtige Entscheidungen müssen getroffen werden - Ableitung wirksamer Maßnahmen ist notwendig - Transparenz über Ursache-Wirkbeziehungen des Kennzahlensystems ist notwendig - KPI-Baum, der Wirkbeziehungen visualisiert, wird gefordert - Korrelationen erkennen ist wichtig - Vernetzung zwischen Prozessen ist essentiell - Mehr proaktive Steuerung wird gefordert - Vorhersagen von wahrscheinlichen Ereignissen werden benötigt - Prognosen müssen besser werden - Simulationen sind notwendig
Reportingspezialist Qualitätsmanagement Standort B BMW Group 03.04.2019	- Sehr starke Korrelation zwischen Anzahl NA (Ursache) und Anzahl NA (alle), die werkeübergreifend definiert sind, in Werk A - Vorschlag, diese werkeübergreifend im Vergleich prüfen - Vermutung: Werk B nutzt Kennzahlen anders als Werk A und wird vermutlich keine so starke Korrelation der beiden Kennzahlen aufweisen

Interviewpartner	Zusammenfassung
Steuerungsverantwortlicher Zielwertvereinbarung Standort A, Reportingspezialist Qualitätsmanagement Standort A, Spezialistin Qualitätsmanagement BMW Group 17.04.2019	- Verteilungsschlüssel für Zielwerte werden für das gesamte Jahr vereinbart - Zeitliche Veränderungen der Beziehungen sollten berücksichtigt werden (täglich, wöchentlich, monatlich); erfolgt durch Vereinbarung von Jahreswerten nicht - Wenn eine Kennzahl um bestimmte Werte schwankt, beeinflusst das mehrere Kennzahlen - Probleme bestimmter Bereiche können deutlich stärkere Auswirkungen auf die Werkskennzahlen haben als die der anderen (z. B. Probleme, die durch die Entwicklung verursacht wurden, können nicht so schnell beseitigt werden das Entfernen einen Lackfehlers) - Vorhersagen erfolgen anhand der Multiplikationen mit Verteilungsschlüsseln - Unterstützung der Ableitung des Verteilungsschlüssels beabsichtigt - Nur aus der Korrelationsanalyse kann der Verteilerschlüssel nicht abgeleitet werden, daher ist zum Beispiel eine lineare Regression zu berechnen Vorteile - Bei Problemen Auswirkungen abschätzen und proaktiv gegensteuern; mit starrem Verteilungsschlüssel nicht möglich - Identifikation, mit welchen Größen die Zielvariable vorhergesagt werden kann – wirksame Prädiktoren erkennen - Bessere Vorhersagen
Führungskraft Produktionssystem BMW Group 23.04.2019	- KPI Intelligence Tool mit sehr hoher Anwenderfreundlichkeit - Sehr gute Interpretierbarkeit

Interviewpartner	Zusammenfassung
Reportingspezialist Qualitätsmanagement Standort B BMW Group 24.04.2019	Vgl. Interview 03.04.2019 - Sehr starke Korrelation zwischen Anzahl NA (Ursache) und Anzahl NA (alle) in Werk A bestehen entgegen der Vermutungen auch in Werk B → mögliche Entfernung einer der Kennzahlen prüfen - Gründe für Existenz beider Kennzahlen ermitteln - Hypothese 1: Es soll ein Effekt abgebildet werden, der über diese Kennzahlen nicht erfasst werden kann - Hypothese 2: Kennzahlenerfassung erfolgt nicht wie beabsichtigt Hierarchische Analyse der Zielwertvereinbarungen: - Bereich B_3 wurde als größter Beitragsleister zu den Kennzahlen von Werk B ermittelt → diesen als nächstes detailliert untersuchen - Starke Korrelationen sind interessant, aber auch mittlere Korrelationen werden zukünftig detailliert untersucht - Vorhersagen werden im Qualitätswesen qualitativ erzeugt - Quantitative Analyse fehlt - Vorhersagen sind unzuverlässig und haben wenig Akzeptanz - Zentralstellen erhalten qualitative Vorhersagen von Fachbereichen und können diese nicht prüfen oder bewerten - Vorhersagen sollten quantitativ unterstützt und überprüft werden, um Vertrauen und Akzeptanz zu steigern - Quantitative Vorhersagen sollten durch fachliche Informationen ergänzt werden (z. B. geplante Maßnahmen) - Durch quantitative Analysen sollten qualitative Vorhersagen kritisch hinterfragt werden: Stimmen die Vorhersagen überein, wurde Vertrauen erzeugt. Stimmen diese nicht überein, kann ein Dialog gestartet und die Begründung für die Einschätzung (z. B. zukünftige Maßnahmen) erfragt werden - Reportingstellen erhalten eine zunehmend beratende Funktion durch die Möglichkeit, quantitative Analysen durchzuführen - Lerneffekte aus anderen Werken können übertragen werden (z. B. wie wirkt sich die Einführung einer weiteren Schicht auf die Kennzahlen aus? → Analyse der Daten eines Werkes, welches bereits eine weitere Schicht hat) - Methode für die Digitale Unternehmenssteuerung ist für Einsatz in der Analyse von Kennzahlenrelationen geeignet - Methode auf unterschiedliche Kennzahlen wie Herstellkosten, Zeit pro Einheit, Qualität anwendbar

Interviewpartner	Zusammenfassung
Leiter Qualitätsmanagement, Reportingspezialist Qualitätsmanagement Standort A, Spezialistin Qualitätsmanagement, Fachprojektleiter IT BMW Group 25.04.2019b	- Anwendungsfall Zielwerttabelle nimmt Perspektive von Montage in Leipzig ein - Misst anhand der Kennzahlen den Schlupf, also die Fehler die in der Montage gefunden und anderen Bereichen zugeordnet werden - Die prozessinternen Kennzahlen der übrigen Prozesse werden nicht betrachtet Nächste Schritte: - Interne Kennzahlen vor- und nachgelagerter Prozesse analysieren → Hypothese: Wenn Fehler, die bereits im vorgelagerten Prozess erkannt wurden, im Folgeprozess wieder erscheinen, funktioniert die Kennzahlensteuerung nicht - Hypothese: Wenn der vorgelagerte Prozess seine internen Zielvorgaben erreicht, erreicht auch der nachgelagerte Prozess seine Ziele - Wie wirken sich Produktionskennzahlen auf endkundenrelevante Kennzahlen aus? Z. B. Qualitätskennzahlen auf Gewährleistungskosten - Gegenüberstellung der Ursache-Wirkbeziehungen gleicher Funktionsbereiche aus unterschiedlichen Werken - Weitere Hypothesen aufstellen und prüfen

Interviewpartner	Zusammenfassung
Vertreter Qualitätsstrategie BMW Group 25.04.2019a	- Funktionalität der Methode für die Digitale Unternehmenssteuerung wird nach Rücksprache mit Reportingexperten als erwiesen angesehen Nutzen: - Gefühl für große Kennzahlenmengen - Analyse des Gesamtbildes der Hierarchie - Stärkste Hebel identifizieren Nächste Schritte bei der Analyse: - Wie sind die Ursache-Wirkbeziehungen zwischen den Kennzahlen aus verschiedenen Prozessen/Abteilungen - Redundanzen prüfen - Daten für mehrere Werke ausleiten und vergleichend analysieren - Mittelfristig werden Untersuchungsaufträge an Fachbereiche erteilt, um mathematische Ergebnisse aus deren Sicht zu erklären Überraschende Erkenntnisse - B-2 wirkt schwächer auf Werkswerte als erwartet → Kennzahlenerfassung und Dokumentation prüfen - Anzahl NA (Ursache) und Anzahl NA (Gesamt) korrelieren fast perfekt in zwei unterschiedlichen Werken → Dokumentation von Fehlern prüfen

Tabelle 0-2: Kernaussagen Praxis-Interviews

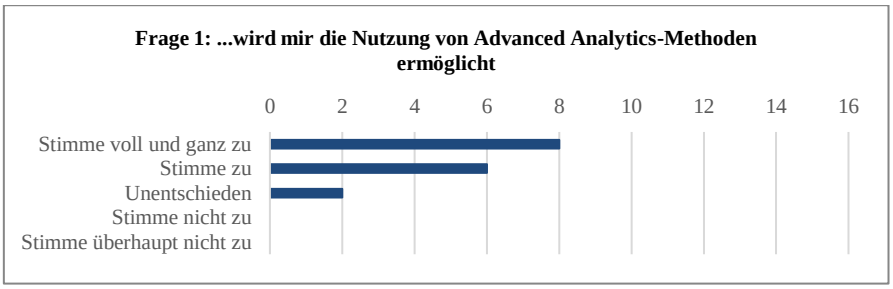
Frage 1: ...wird mir die Nutzung von Advanced Analytics-Methoden ermöglicht
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

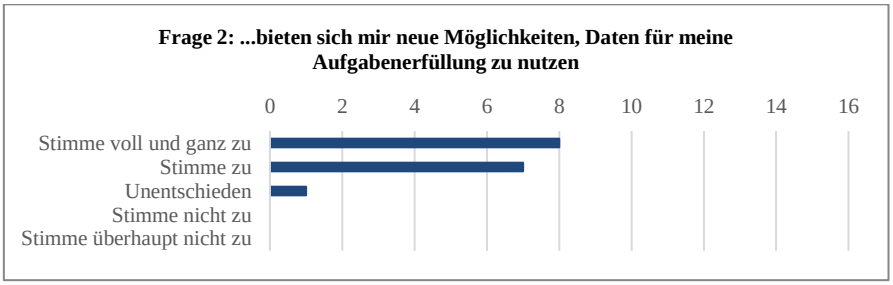
Frage 2: ...bieten sich mir neue Möglichkeiten, Daten für meine Aufgabenerfüllung zu nutzen
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

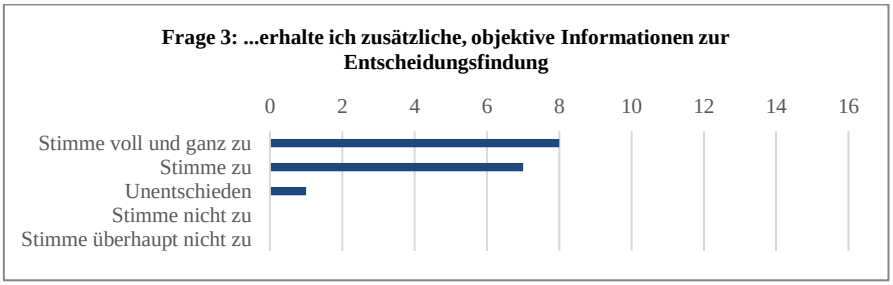
Frage 3: ...erhalte ich zusätzliche, objektive Informationen zur Entscheidungsfindung
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

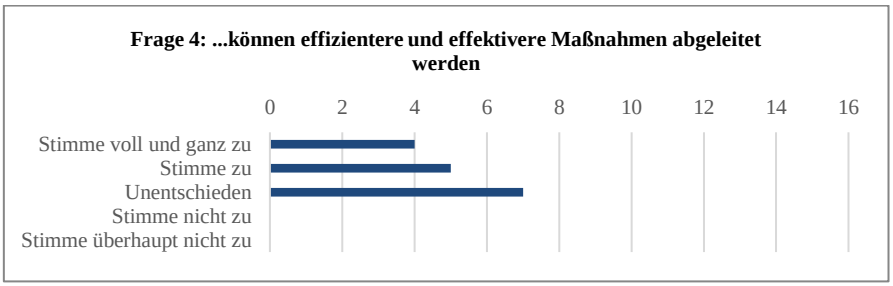
Frage 4: ...können effizientere und effektivere Maßnahmen abgeleitet werden
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

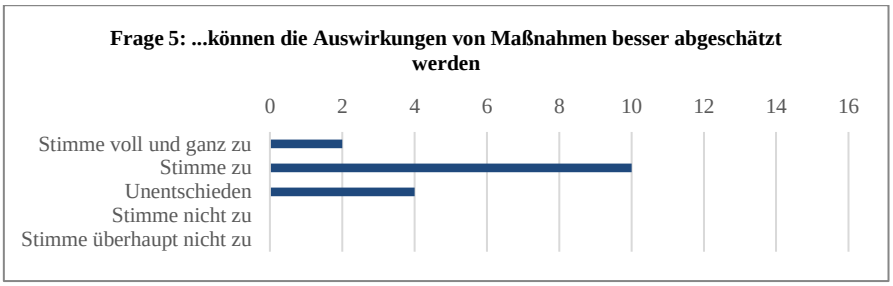
Frage 5: ...können die Auswirkungen von Maßnahmen besser abgeschätzt werden
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

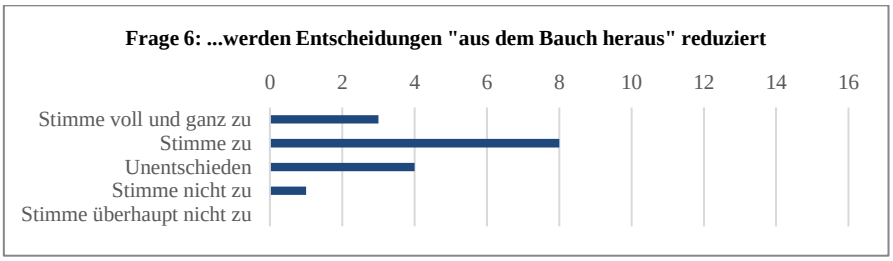
Frage 6: ...werden Entscheidungen "aus dem Bauch heraus" reduziert
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

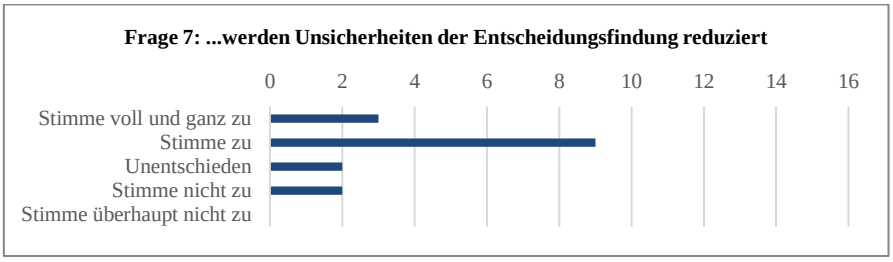
Frage 7: ...werden Unsicherheiten der Entscheidungsfindung reduziert
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

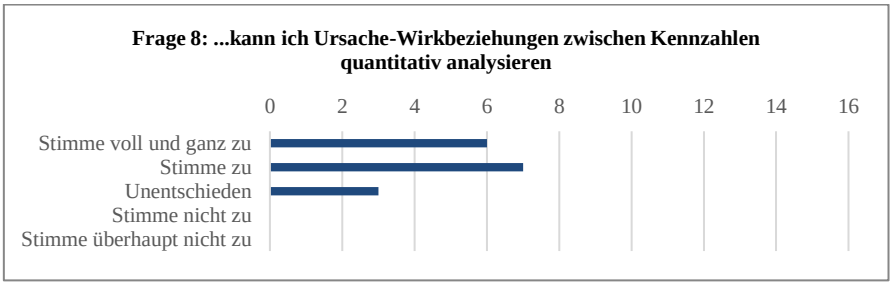
Frage 8: ...kann ich Ursache-Wirkbeziehungen zwischen Kennzahlen quantitativ analysieren
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

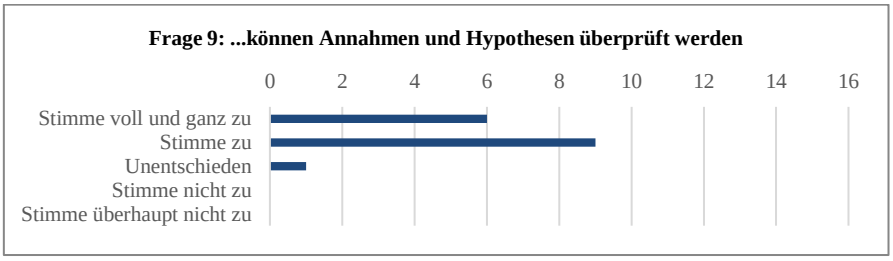
Frage 9: ...können Annahmen und Hypothesen überprüft werden
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

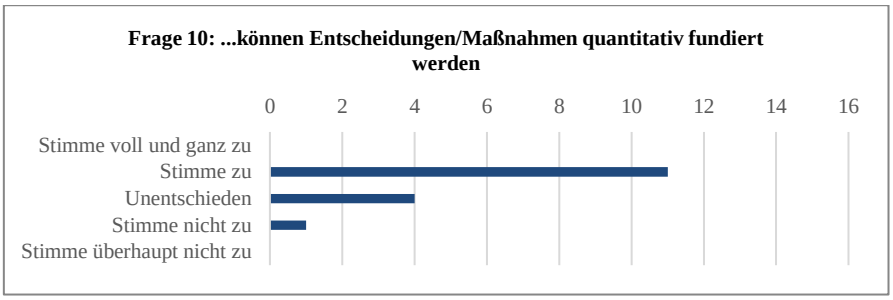
Frage 10: ...können Entscheidungen/Maßnahmen quantitativ fundiert werden
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

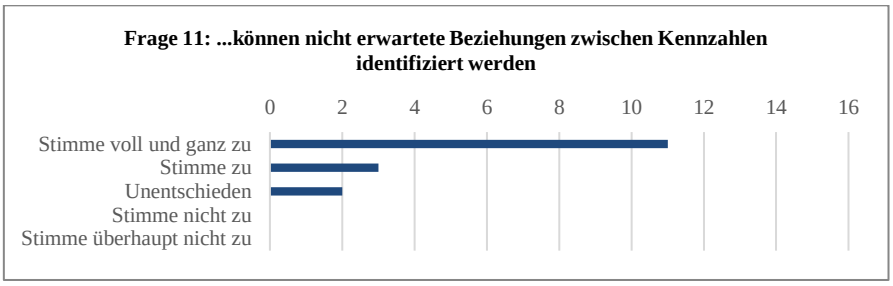
Frage 11: ...können nicht erwartete Beziehungen zwischen Kennzahlen identifiziert werden
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

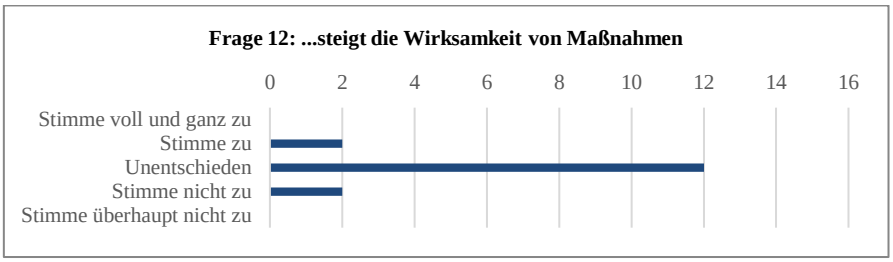
Frage 12: ...steigt die Wirksamkeit von Maßnahmen
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

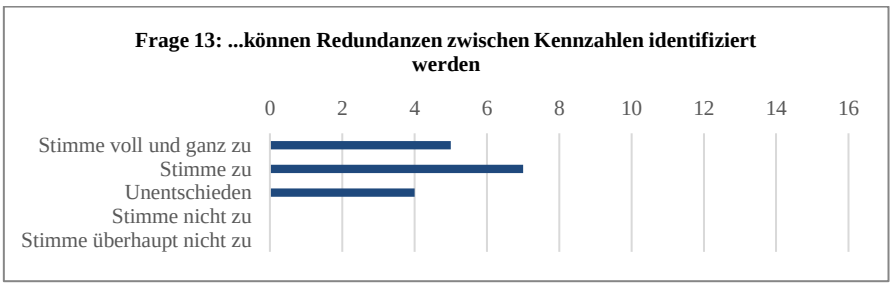
Frage 13: ...können Redundanzen zwischen Kennzahlen identifiziert werden
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

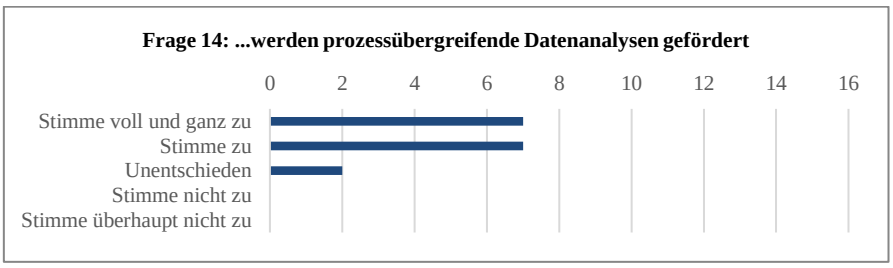
Frage 14: ...werden prozessübergreifende Datenanalysen gefördert
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

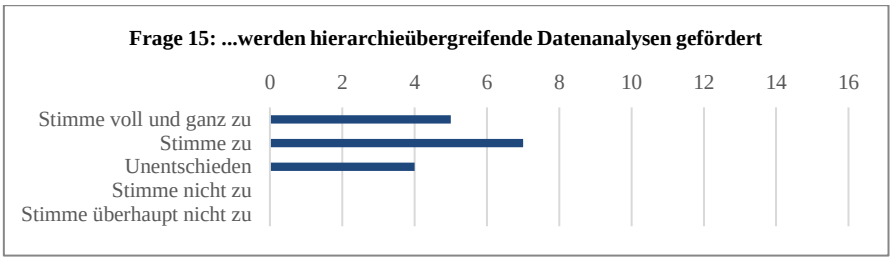
Frage 15: ...werden hierarchieübergreifende Datenanalysen gefördert
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

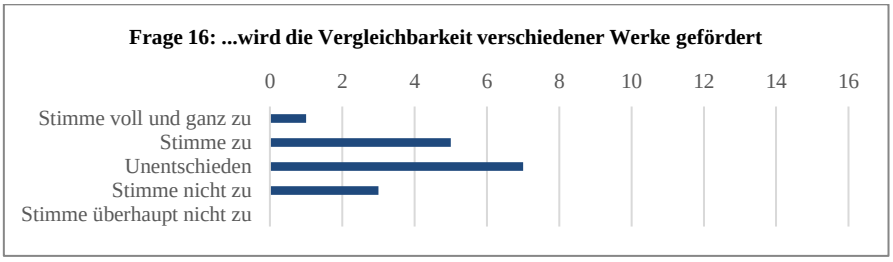
Frage 16: ...wird die Vergleichbarkeit verschiedener Werke gefördert
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

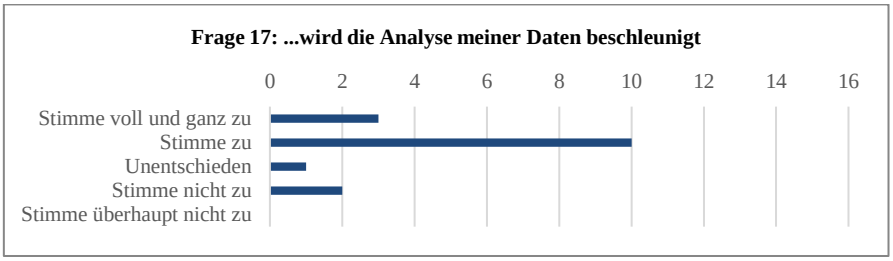
Frage 17: ...wird die Analyse meiner Daten beschleunigt
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

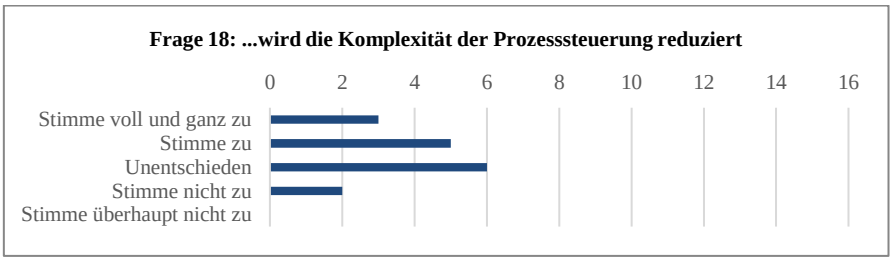
Frage 18: ...wird die Komplexität der Prozesssteuerung reduziert
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

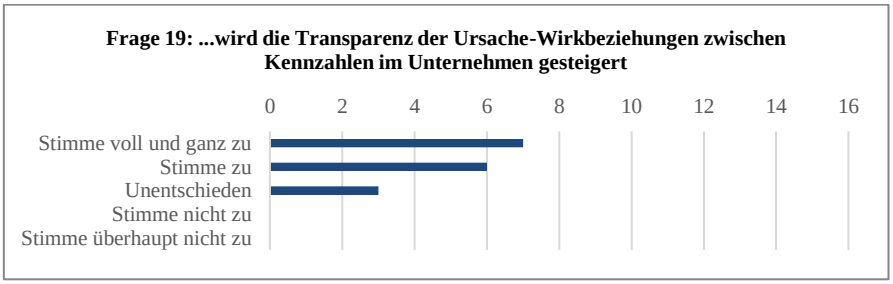
Frage 19: ...wird die Transparenz der Ursache-Wirkbeziehungen zwischen Kennzahlen im Unternehmen gesteigert
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

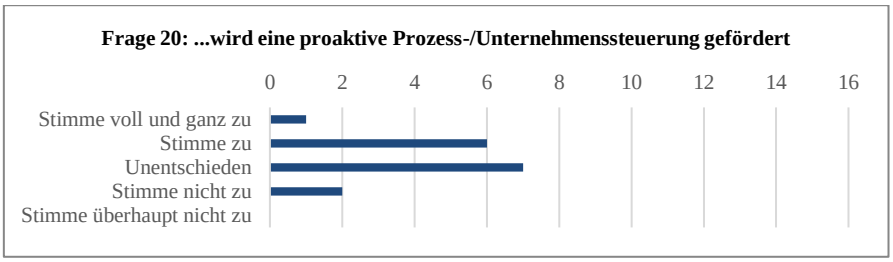
Frage 20: ...wird eine proaktive Prozess-/Unternehmenssteuerung gefördert
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

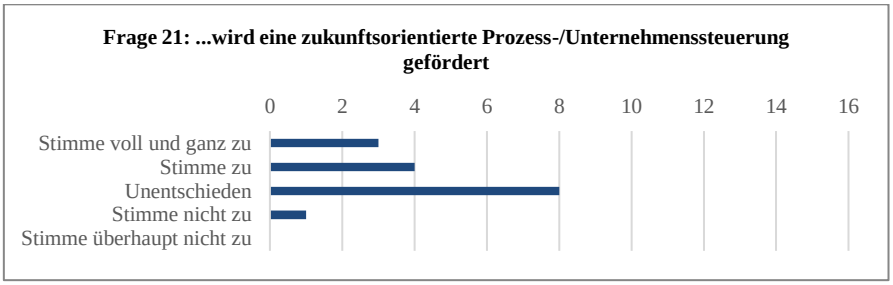
Frage 21: ...wird eine zukunftsorientierte Prozess-/Unternehmenssteuerung gefördert
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

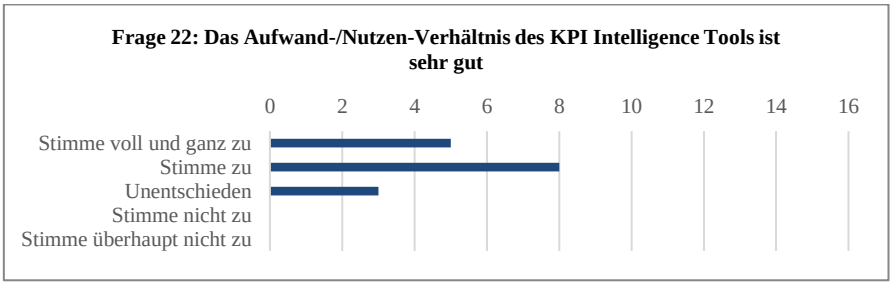
Frage 22: Das Aufwand-/Nutzen-Verhältnis des KPI Intelligence Tools ist sehr gut
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

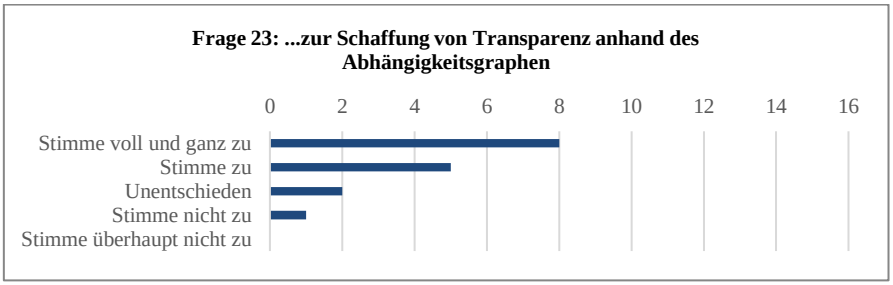
Frage 23: ...zur Schaffung von Transparenz anhand des Abhängigkeitsgraphen
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

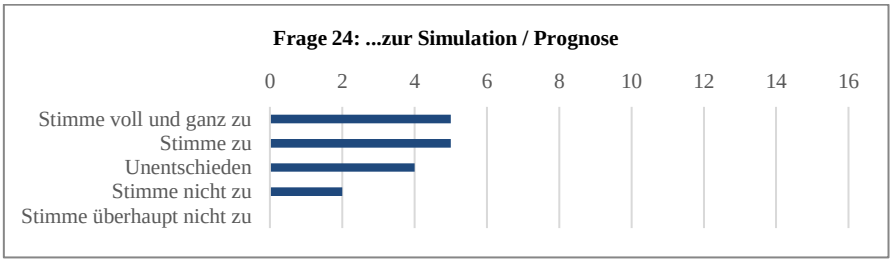
Frage 24: ...zur Simulation / Prognose
0 2 4 6 8 10 12 14 16
Stimme voll und ganz zu
Stimme zu
Unentschieden
Stimme nicht zu
Stimme überhaupt nicht zu

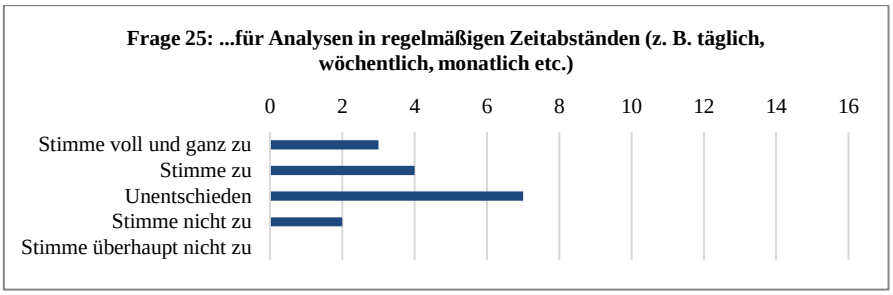

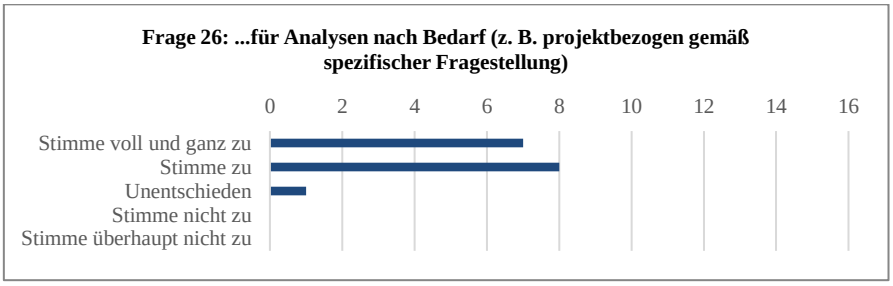

Abb. 0-6: Auswertung Anwenderumfrage

Curriculum Vitae

Persönliche Daten

Name: Daniel Marian Alexander Burdensky
Geburtsdatum / -ort: 07.12.1989, Berlin
Staatsangehörigkeit: Deutsch
Familienstand: Verheiratet

Hobbies: Fußball, Fitness, Lesen

Ausbildung

07/2016 – 12/2022	**Universität Leipzig,** Institut für Wirtschaftsinformatik Doktorand (Note: magna cum laude)
10/2013 – 06/2016	**Technische Universität Berlin** Masterstudium Wirtschaftsingenieurwesen, Abschluss: Master of Science (Note: Sehr Gut - 1,5)
09/2014 – 02/2015	**Universidade do Porto**, Porto, Portugal Auslandssemester
10/2010 – 04/2014	**Technische Universität Berlin** Bachelorstudium Wirtschaftsingenieurwesen, Abschluss: Bachelor of Science (Note: Gut – 2,4)
07/2013 – 10/2013	**Tongji University**, Shanghai, China Studienaufenthalt Bachelorarbeit, (Note: Sehr Gut - 1,3)

Veröffentlichungen / Vorträge

Burdensky, D. (2019). KPI Intelligence – Entscheidungsunterstützung durch die quantitative Analyse von Kennzahlenrelationen bei der BMW Group. Vortrag TDWI Konferenz 2019, München.

Burdensky, D. (2019). KPI Intelligence – Next-Level BI mittels Data Analytics bei der BMW Group. Vortrag TDWI Roundtable, Leipzig

Burdensky, D. (2018). KPI Intelligence. Analysis of interdependencies between key metrics based on historic data. BMW Group ProMotion Dialogtag.

Burdensky, D.; Kneissl, B.; Alt, R. (2018). Deskriptive Analyse von Kennzahlen-relationen, in: Tagungsband Multikonferenz Wirtschaftsinformatik 2018. Band 1, S. 59-70.

Fremdsprachen

Englisch: Verhandlungssicher, Cambridge Certificate in Advanced English, C1
Portugiesisch, Französisch, Latein: Grundlagenkenntnisse

Praktische Tätigkeiten

Seit 06/2021	**BMW AG**, Operative Künstliche Intelligenz, München Verantwortlicher für den Rollout von KI-Lösungen in der Produktion der Fahrzeugwerke Leipzig und Berlin
Seit 09/2017	**Grundbesitzverwaltung Burdensky**, Berlin Gesellschafter
06/2019 – 05-2021	**BMW AG**, Digitalisierung, Data Analytics, München Data Analyst für die Fahrzeugproduktion
07/2016 – 05/2019	**BMW AG**, Group IT, Leipzig ProMotion-Programm
12/2015 – 05/2016	**BMW AG**, Qualitätsmanagement Teile, München Masterarbeit
04/2015 – 08/2015	**Trommsdorff + Drüner**, Innovation + Marketing Consultants GmbH, Berlin Werkstudent im Bereich Innovationen
08/2012 – 09/2012	**LR Intralogistik GmbH**, Wörth an der Isar Praktikant in der Qualitätssicherung
08/2010 – 12/2010	**Siemens AG**, Business Unit Medium Voltage, Berlin Werkstudent im Bereich Business Administration, Einkauf und Logistik Praktikant in der Logistik
07/2009 – 03/2010	**Bundeswehr** Gebirgsjägerbataillon 231, Bad Reichenhall

Sonstige Tätigkeiten / Auszeichnungen

02/2020	Data Analyst for Enterprise, Udacity
11/2016	DIN-Preis „Junge Wissenschaft“, Deutsches Institut für Normung
06/2015 & 06/2014	Quality Manager Black Belt & Six Sigma Green Belt, Institut für Qualitätswissenschaft der TU Berlin
09/2014 – 02/2015	Erasmus+-Stipendium der Europäischen Kommission
03/2014 – 08/2017	Förderprogramm VDI ELEVATE
11/2013 – 11/2015	Aktives Mitglied der Studenten und Jungingenieure des VDI der TU Berlin
08/2013 – 10/2013	PROMOS-Stipendium des Deutschen Akademischen Austauschdienstes
03/2012 – 03/2013	Ehrenamt im Buddy Programm des Akademischen Auslandsamtes der TU Berlin
08/2011 – 09/2011	International Summer University on Energy 2011, Falera, Schweiz, Helmholtz-Zentrum Berlin für Materialien und Energie GmbH