

6

Schriften aus der Fakultät Wirtschaftsinformatik und Angewandte
Informatik der Otto-Friedrich-Universität Bamberg

Entwicklung und Überprüfung von Kausalhypothesen

Gestaltungsoptionen für einen Analyseprozess zur Fundierung
betrieblicher Ziel- und Kennzahlensysteme durch
Kausalhypothesen am Beispiel des Performance-Managements

von Thomas Voit



UNIVERSITY OF
BAMBERG
PRESS

**Schriften aus der Fakultät
Wirtschaftsinformatik und Angewandte Informatik
der Otto-Friedrich-Universität Bamberg**

**Schriften aus der Fakultät
Wirtschaftsinformatik und Angewandte Informatik
der Otto-Friedrich-Universität Bamberg**

Band 6



University of Bamberg Press 2010

Entwicklung und Überprüfung von Kausalhypothesen

Gestaltungsoptionen für einen Analyseprozess
zur Fundierung betrieblicher Ziel- und Kennzahlensysteme
durch Kausalhypothesen am Beispiel des Performance-
Managements

von Thomas Voit



University of Bamberg Press 2010

Bibliographische Information der Deutschen Nationalbibliothek
Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der
Deutschen Nationalbibliographie; detaillierte bibliographische
Informationen sind im Internet über <http://dnb.ddb.de/> abrufbar

Diese Arbeit hat der Fakultät Wirtschaftsinformatik und Angewandte Informatik der
Otto-Friedrich-Universität als Dissertation vorgelegen

1. Gutachter: Prof. Dr. Elmar J. Sinz

2. Gutachter: Prof. Dr. Otto K. Ferstl

Tag der mündlichen Prüfung: 21. Juli 2010

Dieses Werk ist als freie Onlineversion über den Hochschulschriften-
Server (OPUS; <http://www.opus-bayern.de/uni-bamberg/>) der
Universitätsbibliothek Bamberg erreichbar. Kopien und Ausdrücke
dürfen nur zum privaten und sonstigen eigenen Gebrauch
angefertigt werden.

Herstellung und Druck: Digital Print Group, Nürnberg
Umschlaggestaltung: Dezernat Kommunikation und Alumni

© University of Bamberg Press Bamberg 2010

<http://www.uni-bamberg.de/ubp/>

ISSN: 1867-7401

ISBN: 978-3-923507-94-8 (Druckausgabe)

eISBN: 978-3-923507-95-5 (Online-Ausgabe)

URN: urn:nbn:de:bvb:473-opus-2946

Geleitwort

Das Denken in Ursache-Wirkungs-Zusammenhängen ist unverzichtbare Voraussetzung für zielgerichtetes Planen und Entscheiden. Im Bereich der Betriebswirtschaftslehre finden Ursache-Wirkungs-Zusammenhänge u. a. im Bereich des Performance-Managements Anwendung. Neben finanziellen Kennzahlen werden dort auch nicht-finanzielle Kennzahlen aus der Leistungssphäre des Unternehmens eingesetzt, die über Kausalbeziehungen in das Kennzahlensystem eingebunden werden.

Kausalbeziehungen werden in der Praxis häufig eher intuitiv als Ursache-Wirkungs-Vermutungen aufgestellt. Ohne Überprüfung der Ursache-Wirkungs-Zusammenhänge besteht aber die Gefahr von Fehlentscheidungen, ohne systematische Entwicklung der Kausalbeziehungen bleiben wichtige Zusammenhänge möglicherweise unentdeckt. Vor diesem Hintergrund untersucht Thomas Voit in seiner Dissertation (1) wie die Defizite bestehender Performance-Management-Konzepte durch einen systematischeren Umgang mit Kausalinformationen behoben werden können und (2) wie sich Kausalhypothesen für das Performance-Management evidenzbasiert entwickeln und überprüfen lassen. Hierzu entwickelt er (1) einen generischen Performance-Management-Prozess, der Kausalinformationen als Mittel zur ganzheitlichen Gestaltung und Lenkung der betrieblichen Performance nutzt, sowie (2) Gestaltungsoptionen für einen Analyseprozess, der entscheidungsrelevante Kausalinformationen bereitstellt.

Während Performance-Management primär eine betriebswirtschaftliche Aufgabe darstellt, betrifft die Bereitstellung einer Methodik für die zugrunde liegende Kausalanalyse eine Kernaufgabe der Wirtschaftsinformatik, nämlich die Modellierung betrieblicher Informationssysteme sowie die modellgestützte Analyse im Rahmen der Aufgaben eines Führungsinformationssystems. Die Kausalanalyse bildet somit die Grundlage für das Performance-Management, kann aber aus methodischer Sicht auch davon unabhängig betrachtet werden.

Mit seiner Dissertation erweitert Thomas Voit die Theorie und Methodik zur Gewinnung von Kausalhypothesen. Neben den traditionellen Ansatz der Datenanalyse stellt er komplementär den Ansatz der modellzentrierten Analyse, wel-

cher den Blick auf die Kausalität der Ereignisse und ihrer Beziehungen ergänzt um den Blick auf die ereignistragenden Objekte und ihre Objektbeziehungen. Diese Objektebene bildet die kausale Infrastruktur für die Ereignisebene. Implizites Wissen der Analytiker, welches häufig eher bruchstückhaft auf der Basis von Assoziation und Intuition für den Analyseprozess genutzt wurde, kann auf diese Weise expliziert, systematisiert, strukturiert und geprüft werden.

Hier liegt der innovative Kern der Dissertation, deren Ergebnisse weit über das Gebiet Performance-Management hinaus von Bedeutung sind. Thomas Voit trägt mit seiner Arbeit zu einer substanziellen Erweiterung des Theorie- und Methodenrepertoires der modellgestützten Wirtschaftsinformatik bei. Es wäre zu wünschen, dass möglichst viele Unternehmen den Ansatz aufgreifen und für die Gewinnung von Kausalhypothesen zugunsten einer Erhöhung der Entscheidungsqualität nutzen würden.

Elmar J. Sinz

Vorwort

Wie sich die Tautropfen in einem Spinnennetz verfangen, so haben sich in gleicher Weise die Ideen meiner Arbeit in einem Netz verfangen, das andere schon vor mir geknüpft haben. Daher möchte ich all den Personen danken, die mir mit ihren Hinweisen, Ratschlägen und ihrem Wissen ein Netz aufgespannt haben, in dem sich meine eigenen Ideen verfangen konnten.

Zu besonderem Dank bin ich meinem Doktorvater, Herrn Professor Dr. Sinz, verpflichtet. Er hat mir aufgrund seiner hervorragenden Betreuung erst die Möglichkeit, den Mut und die Zeit gegeben, eigene Ideen zu entwickeln und an diesen so lange festzuhalten, bis sie methodisch wie konzeptionell ausreichend begründet waren. So konnten in den zahlreichen und stets anregenden Gesprächen die Früchte meiner Arbeit unter besten Bedingungen nachreifen.

Herrn Professor Dr. Ferstl danke ich für die Übernahme des Zweitgutachtens. Er hat mir in seinen Vorlesungen als Erstes die Idee der Kausalmodellierung vermittelt. Er war für mich ein wichtiger Gesprächspartner, der mich mit seinem Interesse an meiner Arbeit und seinen Fragen immer wieder dazu ermunterte, meinen Modellierungsansatz auch an alltäglichen Ursache-Wirkungs-Problemen auszuprobieren. Dies hat mir zu neuen Einsichten und Ergebnissen verholfen.

Dass diese Arbeit eine Brücke zwischen der Betriebswirtschaftslehre und der Informatik schlägt, ist auch Herrn Professor Dr. Becker zu verdanken. Er hat mich nicht nur für die Fragestellungen des Performance-Managements sensibilisiert, sondern auch dazu motiviert, diese im Rahmen einer Promotion sowie vom Standpunkt der Wirtschaftsinformatik aus zu beantworten. Hierfür und für seine Mitgliedschaft in der Promotionskommission danke ich ihm.

Grundlegend für diese Arbeit waren Peter Neckel und Bernd Knobloch. Sie haben mich mit ihrer Begeisterung für Data-Mining angesteckt und waren mit ihrem reichhaltigen Wissen, aber auch durch die Präzision, mit der sie ihrer eigenen wissenschaftlichen Arbeit nachgehen, gleichermaßen Vorbild wie auch wichtige Impuls- und Ratgeber.

Zu Dank bin ich auch Herrn Walter und Herrn Hanning verpflichtet, die mir die Gelegenheit und das professionelle Umfeld boten, um die Anwendbarkeit

meiner Ideen in der Unternehmenspraxis testen zu können. Ihr kritisches Feedback ist dafür verantwortlich, dass ich bei der Ausarbeitung meiner Ideen weder den Anwendungszweck noch den praktischen Nutzen aus den Augen verloren habe.

Werner Zirkel bin ich verbunden, weil er mich während der gesamten Zeit als konstruktiver und interessierter Dialogpartner begleitet hat. Aus der Resonanz, die ich in den Gesprächen mit ihm gefunden habe, konnte ich gerade in schwierigen Phasen nicht nur Kraft, sondern auch neue Ideen schöpfen.

Rainer Schennach ist das Kunststück gelungen, mir selbst aus der Distanz das nötige Maß an fachlicher Hilfestellung zur Überarbeitung meines Manuskripts zu geben. Für die Lektüre, die Korrekturhinweise und die langen Telefongespräche danke ich ihm.

Für die unermüdliche und mit großer Sorgfalt durchgeführte Korrektur meines Manuskripts danke ich Dietmar Marquardt. Zu wissen, dass es jemanden gibt, dessen sprachlichen und orthografischen Hinweisen man blind vertrauen kann, ist vor allem in der hektischen Schlussphase ungemein befreiend. Dies hat mir den notwendigen Freiraum verschafft, mich bis zuletzt auf die Inhalte meiner Arbeit konzentrieren zu können.

Meiner Schwester Daniela danke ich ebenfalls für die geduldige Lektüre, mit der sie bis zuletzt mein Manuskript auf Verständlichkeit und Plausibilität geprüft hat. Ihre wertvollen Anmerkungen haben mir geholfen, die Lesbarkeit meines Manuskripts zu erhöhen.

Bei meinen Eltern bedanke ich mich für das vorbehaltlose Vertrauen, das sie in mich und meine Arbeit von Beginn an gesetzt haben. Ihr Zuspruch und ihr Engagement haben mir stets die Sicherheit und Zuversicht gegeben, ohne die ich diesen Weg wohl weder begonnen noch zu Ende geführt hätte.

Zuletzt danke ich meiner Frau Ruth, dass sie jede noch so unfertige Rohfassung als Erste gelesen und korrigiert hat. Aber vor allem danke ich ihr, dass sie mich immer wieder aufs Neue an die vielen Dinge erinnert hat, für die es sich lohnt, endlich fertig zu werden.

Thomas Voit

Inhaltsverzeichnis

Tabellenverzeichnis.....	VI
Abbildungsverzeichnis.....	VII
Abkürzungsverzeichnis.....	XII
1 Einleitung.....	1
1.1 Problemstellung.....	1
1.2 Zielsetzung.....	5
1.3 Aufbau der Arbeit.....	6
2 Grundlagen und Defizite bestehender Performance-Konzepte.....	9
2.1 Grundlagen bestehender Konzepte zum Performance-Management.....	10
2.1.1 Der Begriff der betrieblichen Performance.....	10
2.1.2 Performance-Management als Erweiterung des Performance-Measurements.....	12
2.2 Defizite bestehender Konzepte zum Performance-Management.....	16
2.2.1 Defizite in der praktischen Umsetzung.....	16
2.2.2 Defizite in der konzeptionellen Fundierung.....	23
3 Entwicklung eines ganzheitlichen Performance-Management-Konzepts.....	27
3.1 Systemtheoretischer Bezugsrahmen für das Performance-Management.....	27
3.1.1 Systemtheoretische Grundlagen.....	28
3.1.1.1 Systemtheorie und Kybernetik.....	29
3.1.1.2 Modellbasierte Regelung komplexer Systeme.....	33
3.1.1.3 Der betriebliche Aufgabenbegriff.....	35
3.1.1.4 Unternehmensarchitektur.....	37

3.1.2	Performance-Management als betriebliche Aufgabe	41
3.1.3	Architekturmodell für das Performance-Management	46
3.1.4	Kybernetisches Regelkreismodell für das Performance-Management	52
3.2	Generisches Prozessmodell für das Performance-Management	56
3.2.1	Grundlagen von Prozessen	56
3.2.2	Prozessstruktur	58
3.2.2.1	Teilprozess der Performance-Gestaltung	60
3.2.2.2	Teilprozess der Performance-Lenkung	62
3.2.3	Prozessablauf	68
4	Einsatz von Kausalhypothesen im Performance-Management	73
4.1	Kausalhypothesen und ihre Bedeutung für das Performance-Management	73
4.1.1	Kausalhypothesen	74
4.1.2	Zweck-Mittel-Beziehungen	76
4.1.3	Kausale Kennzahlbeziehungen	79
4.2	Einsatzmöglichkeiten von Kausalhypothesen im Performance-Management-Prozess	81
4.2.1	Einsatzmöglichkeiten in der Planungsphase	81
4.2.1.1	Planung der Unternehmensarchitektur	81
4.2.1.2	Planung des Performance-Measure-Systems	83
4.2.2	Einsatzmöglichkeiten in der Lenkungsphase	88
4.2.2.1	Kontrolle der Performance	88
4.2.2.2	Steuerung der Performance	90
5	Grundlagen der Entwicklung und Überprüfung von Kausalhypothesen	93
5.1	Entwicklung der Gestaltungsoptionen	93
5.1.1	Anforderungen an Kausalinformationen	94
5.1.2	Implikationen für die Gestaltung des Analyseprozesses	96
5.1.3	Konzeptionelle Grundlagen von Kausalinformationen	99
5.1.3.1	Wesensmerkmale kausaler Zusammenhänge	100
5.1.3.2	Betrachtungsebenen kausaler Zusammenhänge	101
5.1.4	Methodische Grundlagen des Analyseprozesses	105
5.1.4.1	Entwicklung und Überprüfung von Kausalhypothesen	106
5.1.4.2	Modell- und datenzentrierte Kausalanalyse	110

5.2	Kausalanalytisches Architekturmodell.....	115
5.2.1	Typbezogene Kausalarchitektur.....	116
5.2.1.1	Objekttypen und -beziehungen der Objektebene.....	117
5.2.1.2	Ereignistypen und Kausalbeziehungen der Ereignisebene.....	125
5.2.2	Instanzenbezogene Kausalarchitektur.....	132
5.2.2.1	Objektdateien der Objektebene.....	133
5.2.2.2	Ereignisdateien der Ereignisebene.....	134
5.3	Datenzentrierte Analyseverfahren.....	136
5.3.1	Datengetriebene Analyseverfahren.....	137
5.3.1.1	Segmentierung.....	140
5.3.1.2	Abweichungsanalyse.....	143
5.3.1.3	Assoziationsanalyse.....	147
5.3.1.4	Prognose und Klassifikation.....	150
5.3.2	Hypothesengetriebene Analyseverfahren.....	153
5.3.2.1	Online-Analytical-Processing.....	155
5.3.2.2	Data-Warehouse.....	158
6	Gestaltungsoptionen für einen Analyseprozess zur Entwicklung und Überprüfung von Kausalhypothesen.....	161
6.1	Modellzentrierte Entwicklung von Kausalhypothesen.....	161
6.1.1	Zieltransformation.....	162
6.1.2	Modellkonstruktion.....	164
6.1.3	Verfahrensanwendung.....	170
6.1.4	Lösungstransformation.....	175
6.2	Datenzentrierte Entwicklung von Kausalhypothesen.....	178
6.2.1	Zieltransformation.....	179
6.2.2	Modellkonstruktion.....	184
6.2.3	Verfahrensanwendung.....	186
6.2.4	Lösungstransformation.....	195
6.3	Modellzentrierte Überprüfung von Kausalhypothesen.....	198
6.3.1	Zieltransformation.....	199
6.3.2	Modellkonstruktion.....	200
6.3.3	Verfahrensanwendung.....	203
6.3.4	Lösungstransformation.....	204
6.4	Datenzentrierte Überprüfung von Kausalhypothesen.....	205
6.4.1	Zieltransformation.....	207

6.4.2	Modellkonstruktion.....	211
6.4.3	Verfahrensanwendung.....	214
6.4.4	Lösungstransformation.....	220
6.5	Kombination der Gestaltungsoptionen zu einem integrierten Analyseprozess.....	223
6.5.1	Sequenzielle Anwendung der Gestaltungsoptionen.....	224
6.5.2	Verschachtelte Anwendung der Gestaltungsoptionen.....	228
7	Entwicklung und Überprüfung von Kausalhypothesen für das Performance-Management eines Sportartikelherstellers.....	233
7.1	Problemstellung des Performance-Managements.....	234
7.1.1	Untersuchungsobjekt des Performance-Managements.....	234
7.1.1.1	Kundenauftragsprozess.....	234
7.1.1.2	Kreditprüfung.....	235
7.1.2	Untersuchungsziel des Performance-Managements.....	238
7.2	Durchführung des Analyseprozesses.....	240
7.2.1	Modellzentrierte Entwicklung von Kausalhypothesen.....	241
7.2.1.1	Zieltransformation.....	241
7.2.1.2	Modellkonstruktion.....	242
7.2.1.3	Verfahrensanwendung.....	248
7.2.1.4	Lösungstransformation.....	257
7.2.2	Datenzentrierte Entwicklung von Kausalhypothesen.....	263
7.2.2.1	Zieltransformation.....	263
7.2.2.2	Modellkonstruktion.....	267
7.2.2.3	Verfahrensanwendung.....	274
7.2.2.4	Lösungstransformation.....	279
7.2.3	Datenzentrierte Überprüfung von Kausalhypothesen.....	286
7.2.3.1	Zieltransformation.....	287
7.2.3.2	Modellkonstruktion.....	288
7.2.3.3	Verfahrensanwendung.....	289
7.2.3.4	Lösungstransformation.....	293
7.2.4	Modellzentrierte Überprüfung von Kausalhypothesen.....	294
7.2.4.1	Zieltransformation.....	295
7.2.4.2	Modellkonstruktion.....	296
7.2.4.3	Verfahrensanwendung.....	299
7.2.4.4	Lösungstransformation.....	307

8 Zusammenfassung und Schlussbetrachtung	311
8.1 Zusammenfassung der Ergebnisse.....	311
8.2 Schlussbetrachtung und Ausblick.....	315
Literaturverzeichnis.....	319

Tabellenverzeichnis

Tabelle 1:	Analysefälle für die Analyse von Ereignisbeziehungen.....	189
Tabelle 2:	Analysefälle für die Analyse von Ereignis-Objekt-Beziehungen.....	192
Tabelle 3:	Analysefälle für die Analyse von Objekt-Ereignis-Beziehungen.....	193
Tabelle 4:	Analysefälle für die Analyse von Objektbeziehungen.....	194
Tabelle 5:	Beispiel zur Berechnung der Kapitalbindungskosten.....	242
Tabelle 6:	Analysemerkmale der datenzentrierten Entwicklung von Kausalhypothesen.....	268
Tabelle 7:	Charakteristische Merkmalsausprägungen der Segmentzentren für $k = 4$ sortiert nach Signifikanz der Merkmalsunterschiede.....	280

Abbildungsverzeichnis

Abbildung 1:	Beispiel eines Kausalmodells [PrGo91, S. 236]	3
Abbildung 2:	Inhaltlicher Aufbau der Dissertation	7
Abbildung 3:	Defizite in der praktischen Umsetzung des Performance-Managements	18
Abbildung 4:	Zusammenhang zwischen den Defiziten der praktischen Umsetzung und der konzeptionellen Fundierung von Performance-Konzepten	26
Abbildung 5:	Methodisches Vorgehen zur Entwicklung des ganzheitlichen Performance-Management-Konzepts	28
Abbildung 6:	Fragestellungen des Grenz-, Interaktions- und Relevanzproblems	30
Abbildung 7:	Subsystembildung und Aggregation	32
Abbildung 8:	Regelkreismodelle (in Anlehnung an [FeSi08, S. 28 und 81])	34
Abbildung 9:	Aufgaben-Innensicht (in Anlehnung an [FeSi08, S. 102])	36
Abbildung 10:	Zusammenhang zwischen Blickwinkel, Modellebenen und Sichten	38
Abbildung 11:	Generischer Architekturrahmen [Sinz02, S. 1056]	39
Abbildung 12:	Unternehmensarchitektur der SOM-Methodik [FeSi08, S. 193]	40
Abbildung 13:	Gestaltung und Lenkung (in Anlehnung an [Blei95, S. 96])	42
Abbildung 14:	Performance-Management als betriebliche Aufgabe aus der Außersicht	44
Abbildung 15:	Performance-Management als betriebliches Objekt	45
Abbildung 16:	Konzeptionelles Defizit des Architekturmodells von Rummler und Brache (in Anlehnung an [Klin00, S. 179])	48
Abbildung 17:	Performance-Management-Architekturmodell	50
Abbildung 18:	Performance-Gestaltung als Regelkreismodell	53
Abbildung 19:	Performance-Lenkung als Regelkreismodell	54

Abbildung 20: Performance-Management als kybernetisches Regelkreismodell	55
Abbildung 21: Teilprozesse, Phasen und Aktivitäten des Performance-Management-Prozessmodells	59
Abbildung 22: Deming-Zyklus (in Anlehnung an [Demi02, S. 88])	69
Abbildung 23: Einfacher Phasenzyklus des Performance-Managements	69
Abbildung 24: Gestaltungs- und Lenkungszyklen des Performance-Managements	71
Abbildung 25: Zusammenhang zwischen Zweck-Mittel-Beziehungen, kausalen Kennzahlbeziehungen und Kausalhypothesen	73
Abbildung 26: Abgrenzung von Zweck-Mittel- und kausalen Kennzahlbeziehungen	85
Abbildung 27: Einsatz von Kausalhypothesen zur Begründung von Zweck-Mittel- und kausalen Kennzahlbeziehungen	86
Abbildung 28: Methodisches Vorgehen zur Entwicklung der Gestaltungsoptionen	94
Abbildung 29: Anforderungen an Kausalinformationen	95
Abbildung 30: Anforderungen an die Gestaltung des Analyseprozesses	99
Abbildung 31: Typ- und Instanzsicht kausaler Ereignisbeziehungen	102
Abbildung 32: Zusammenhang zwischen Objekt- und Ereignistypen sowie zwischen Objekt- und Ereignisinstanzen	104
Abbildung 33: Abhängigkeiten zwischen den Betrachtungsebenen	105
Abbildung 34: Konzept der Untersuchungssituation nach Ferstl	106
Abbildung 35: Untersuchungsziele der Hypothesenentwicklung	108
Abbildung 36: Modellgestützte Untersuchung (in Anlehnung an [Fers79, S. 80])	111
Abbildung 37: Gestaltungsoptionen des Analyseprozesses	114
Abbildung 38: Kausalanalytisches Architekturmodell	116
Abbildung 39: Teilmodellsysteme der typbezogenen Kausalarchitektur	117
Abbildung 40: Beispiele für verschiedene Arten von Interaktionsbeziehungen	118
Abbildung 41: Beispiel einer Typ- und Aggregationsebenenhierarchie	120
Abbildung 42: Möglichkeiten zur Bildung von Subobjekttypen	123
Abbildung 43: Meta-Modell der Objektebene	124
Abbildung 44: Beispiel einer typbezogenen Kausalarchitektur	129
Abbildung 45: Integriertes Meta-Modell der typbezogenen Kausalarchitektur	131

Abbildung 46:	Datenmuster und Aufgabentypen des Data-Minings.....	139
Abbildung 47:	Beispiel eines Analysepfads der Top-Down-Navigation.....	145
Abbildung 48:	Charakteristischer Werteverlauf von Zeitreihenabweichungen	146
Abbildung 49:	Beispiel zur Berechnung der Gütemaße einer Assoziationsbeziehung.....	149
Abbildung 50:	Beispiel eines Entscheidungsbaums	152
Abbildung 51:	Beispiel eines dreidimensionalen Hyperwürfels (in Anlehnung an [Balz00, S. 241]).....	156
Abbildung 52:	Data-Warehouse-Systemarchitektur (in Anlehnung an [BöUl00, S. 17]).....	160
Abbildung 53:	Prozessschritte der Zieltransformation	163
Abbildung 54:	Prozessschritte der Modellkonstruktion	165
Abbildung 55:	Beispiel zur Präzisierung eines Interaktionsereignisses.....	166
Abbildung 56:	Modellkonstruktion auf Basis von Objektbeziehungen.....	168
Abbildung 57:	Prozessschritte der Verfahrensanwendung.....	170
Abbildung 58:	Plausibilisierung einer Kausalhypothese durch Hinzufügen einer alternativen Infrastrukturbeziehung.....	173
Abbildung 59:	Plausibilisierung einer Kausalhypothese durch die Präzisierung der kausalen Infrastruktur.....	174
Abbildung 60:	Plausibilisierung einer Kausalhypothese durch Einschränkung oder Erweiterung des kausalen Geltungsbereichs.....	175
Abbildung 61:	Prozessschritt der Lösungstransformation.....	176
Abbildung 62:	Prozessschritte der Zieltransformation.....	180
Abbildung 63:	Generische Zielsetzungen der datenzentrierten Entwicklung einer Kausalhypothese.....	181
Abbildung 64:	Prozessschritte der Modellkonstruktion	184
Abbildung 65:	Datenqualitätsprobleme und Möglichkeiten ihrer Behebung (in Anlehnung an [Knob00, S. 32]).....	186
Abbildung 66:	Prozessschritte der Verfahrensanwendung.....	187
Abbildung 67:	Prozessschritt der Lösungstransformation.....	196
Abbildung 68:	Prozessschritte der Zieltransformation.....	200
Abbildung 69:	Prozessschritte der Modellkonstruktion	201
Abbildung 70:	Prozessschritte der Verfahrensanwendung.....	203
Abbildung 71:	Prozessschritt der Lösungstransformation.....	204
Abbildung 72:	Prozessschritte der Zieltransformation.....	207

Abbildung 73: Generische Zielsetzungen der datenzentrierten Überprüfung einer Kausalhypothese.....	208
Abbildung 74: Prozessschritte der Modellkonstruktion	212
Abbildung 75: Prozessschritte der Verfahrensanwendung	215
Abbildung 76: Prozessschritt der Lösungstransformation	221
Abbildung 77: Grundlegende Kombinationsmöglichkeiten von Gestaltungsoptionen.....	223
Abbildung 78: Idealtypischer Verlauf des Analyseprozesses	225
Abbildung 79: Spiralförmiger Analyseverlauf mit Wechsel des Modellsystems.....	226
Abbildung 80: Modell- und datenzentrierter Analysezyklus	228
Abbildung 81: Kombination des modell- und datenzentrierten Analysezyklus.....	231
Abbildung 82: Zielkonflikte im Kundenauftragsprozess	239
Abbildung 83: Verlauf des Analyseprozesses und seiner Analysezyklen	240
Abbildung 84: Präzisierung des Ausgangsereignisses „Reduzierung der Kapitalbindungskosten“.....	243
Abbildung 85: Initiales Ereignis- und Objektmodell nach der Ereignispräzisierung	245
Abbildung 86: Objektmodell des Kundenauftragsprozesses	246
Abbildung 87: Zusammenhang der Teilmodellsysteme.....	249
Abbildung 88: Kausalhypothesen zur Reduzierung der Kapitalbindungskosten (Teilmodellsystem a).....	250
Abbildung 89: Kausalhypothesen zur Reduzierung der zu prüfenden Kundenaufträge (Teilmodellsystem b).....	252
Abbildung 90: Kausalhypothesen zur Reduzierung der überschrittenen Kreditsumme (Teilmodellsystem c).....	254
Abbildung 91: Kausalhypothesen zur Reduzierung der Umsatzeinbußen (Teilmodellsystem d)	256
Abbildung 92: Neue Kausalhypothese als Bindeglied zwischen zwei Kausalsträngen.....	258
Abbildung 93: Neue Kausalhypothese bezüglich der Höhe des gesetzten Kreditlimits	259
Abbildung 94: Neue Kausalhypothese bezüglich der Wartezeit bis zur Stornierung.....	260
Abbildung 95: Präzisierung von Kausalhypothesen durch das Einfügen neuer Infrastrukturbeziehungen.....	261

Abbildung 96: Handlungsspielraum zur Kennzahlenbildung und Begründung kausaler Kennzahlbeziehungen als Kriterium für die Nützlichkeit	263
Abbildung 97: Ursachen und Wirkungen von Auftragsstornierungen	265
Abbildung 98: Modellziel und beispielhaftes Analyseergebnis der datenzentrierten Entwicklung von Kausalhypothesen.....	266
Abbildung 99: Visuelle Datenexploration mittels Analyse der Häufigkeitsverteilungen.....	272
Abbildung 100: Segmenteinteilungen mit Parametrisierung k = 2, 3, 4 und 5.....	275
Abbildung 101: Normierte Merkmalsausprägungen und -unterschiede der Segmentzentren für k = 4.....	277
Abbildung 102: Entscheidungsbaum zur Charakterisierung von lager- und kreditstornierten Aufträgen.....	279
Abbildung 103: Ereignis- und Objektdifferenzierung als Ergebnis der Segmentierung.....	282
Abbildung 104: Kausalhypothesen der datenzentrierten Hypothesenentwicklung.....	284
Abbildung 105: Untersuchte Kausalhypothesen der datenzentrierten Überprüfung.....	288
Abbildung 106: Identifizierte Ereignisinstanzen zur Überprüfung der Auswirkungen von Kundenaufträgen ohne Kreditprüfung auf die Forderungsausfälle.....	291
Abbildung 107: Identifizierte Ereignisinstanzen zur Überprüfung der Auswirkungen manueller Auftragsfreigaben auf die Forderungsausfälle.....	292
Abbildung 108: Zu überprüfende Kausalhypothesen der datenzentrierten Entwicklung.....	296
Abbildung 109: Präzisierung von Ereignissen und Kausalhypothesen.....	297
Abbildung 110: Objektmodell der modellzentrierten Hypothesenprüfung.....	298
Abbildung 111: Hypothesenabhängige Erweiterung und Präzisierung des Objektmodells.....	300
Abbildung 112: Modifiziertes Kausal- und Objektmodell (Modellausschnitt eins).....	302
Abbildung 113: Modifiziertes Kausal- und Objektmodell (Modellausschnitt zwei).....	304

Abkürzungsverzeichnis

ETL	Extraktion, Transformation, Laden
KDD	Knowledge Discovery in Databases
OLAP	Online-Analytical-Processing
OLTP	Online-Transaction-Processing
PMS	Performance-Measure-System
SOM	Semantisches Objektmodell
SQL	Structured-Query-Language
ZVEI	Zentralverband der elektrochemischen Industrie

1 Einleitung

„Wenn man konzentriert genug nachdachte, konnte man die Antwort auf alles finden - davon war er überzeugt gewesen. Zum Beispiel der Wind. Dieses Phänomen hatte ihn immer verwirrt, bis er eines Tages den Grund dafür begriff: Wind entstand, weil sich die Bäume schützelten.“ [Prat08, S. 72]

Unser Denken ist seit jeher von dem Versuch bestimmt, Ursache und Wirkung gedanklich zu trennen, um beides anschließend wieder miteinander zu verknüpfen. Wir orientieren uns an unseren Ursache-Wirkungs-Vermutungen und richten unsere Entscheidungen, Handlungen und Erwartungen daran aus - oft ohne zu wissen, ob diese Vermutungen zutreffen. Das einleitende Zitat zeigt aber anschaulich, wie leicht sich Ursache und Wirkung verwechseln lassen, wenn man aus einer isolierten Beobachtung die falsche Schlussfolgerung zieht. Und dennoch sind wir von Kindheit an darin geübt, auf Basis unserer Erfahrungen neue Kausalhypothesen aufzustellen, den Ursachen von Problemen auf den Grund zu gehen und die Wirksamkeit unserer Handlungsalternativen zu beurteilen. Dies gilt nicht nur für alltägliche, sondern auch für betriebswirtschaftliche Planungs- und Entscheidungsprozesse. Aber weshalb bedarf es dann einer wissenschaftlichen Arbeit über die Entwicklung und Überprüfung von Kausalhypothesen?

1.1 Problemstellung

Dass das Denken in Ursache-Wirkungs-Zusammenhängen die Voraussetzung für zielgerichtetes Planen und Entscheiden ist (vgl. [Bert73, S. 12], [Hein77, S. 25]), gilt zu Recht als Allgemeinplatz. Nur wer im Vorfeld seiner Handlungen über deren Wirkungen nachdenkt, kann die Handlungsalternative danach auswählen, ob sie den gewünschten Zielzustand herbeiführt (vgl. [Hein76, S. 21], [UlHi79, S. 179], [Pear00, S. 65]). Welche Probleme aber das Denken in Kausalzusammenhängen zuweilen bereitet, zeigt sich spätestens dann, wenn man etwas weiter als gewohnt denkt und versucht, diese Zusammenhänge zu artikulieren.

Das zeigt sich zum Beispiel anhand der Kennzahlen, die das Berichtswesen eines Unternehmens bereitstellt. Diese Kennzahlen werden zwar in Form von Tabellen oder Grafiken zusammengestellt, aber es bleibt dem Berichtsempfänger überlassen, sich die Abhängigkeiten zwischen den Kennzahlen dazuzudenken. Solange es sich bei den Kennzahlen um die bekannten Finanzkennzahlen zur Umsatz-, Kosten- und Gewinnentwicklung handelt, mag es noch gelingen, Kennzahlbeziehungen der folgenden Art herzustellen: je geringer die Kosten und je höher der Umsatz, desto größer der Gewinn. Schwierig wird es erst dann, wenn man die ausgetretenen Pfade der monetären Kennzahlen verlässt und versucht, diese mit den nicht-finanziellen Messgrößen der Leistungssphäre zu verknüpfen. Dann stellt man sich womöglich Fragen wie diese:

- Was bedeutet es für die Liquidität eines Unternehmens, wenn sich die Durchlaufzeit eines Produktionsprozesses aufgrund von Qualitätsproblemen von sieben auf zehn Tage erhöht?
- Wird sich die geplante Preiserhöhung bei Biogemüse auch auf den Umsatz mit fair gehandeltem Kaffee auswirken?

Es ist keineswegs neu, dass Unternehmen über die kausalen Beziehungen zwischen der Leistungs- und Finanzsphäre nachdenken. Neu ist aber, dass heute die Antworten auf solche Fragen - das sind die Kausalhypothesen - offener diskutiert und hinterfragt werden (vgl. [PeSc02, S. 49]). Zu verdanken ist dies den Performance-Management-Konzepten wie zum Beispiel der *Balanced Scorecard*. Diese fordern, nicht nur Finanzkennzahlen, sondern auch nicht-finanzielle Kennzahlen aus der Leistungssphäre in das Kennzahlensystem aufzunehmen. Die Bedeutung, die dieser neuen Form von Kennzahlensystemen zukommt, ist vergleichbar mit der Funktion der ersten lexikalischen Wortlisten, mit denen die Sumerer vor über 4500 Jahren den Grundstein für die Entwicklung der babylonischen Keilschrift legten:

„Diese Verzeichnisse ermöglichten nun ganz neue geistige Aktivitäten, denn sie ermuntern ja zu Vergleichen und deshalb auch zu Kritik. Und da die Begriffe in solchen Bestandslisten all der Zusammenhänge enthoben waren, die ihnen in der gesprochenen Sprache einen Sinn verliehen, verwandelten sie sich gewissermaßen zugleich in Abstraktionen. Deshalb konnten sie nun auf nie gekannte Weise klassifiziert und sortiert werden oder Anlass zu Fragen geben, die in einer rein mündlichen Kultur nie gestellt wurden“ [Wats05, S. 152-153].

Genauso wie die Wortlisten dazu anregten, die Beziehungen zwischen den Wörtern zu diskutieren, wird der Blick nun auf die Beziehungen *zwischen* den Kennzahlen gelenkt. Da nicht-finanzielle Kennzahlen nicht mehr über definitionslogi-

sche Beziehungen zu errechnen sind, wie etwa Umsatz-, Gewinn- und Kostengrößen, können nicht-finanzielle Kennzahlen nur über Kausalbeziehungen in das Kennzahlensystem eingebunden werden. Dies animiert das Management dazu, die kausalen Abhängigkeiten zwischen den Kennzahlen zu diskutieren, aber auch ihre Ursache-Wirkungs-Vermutungen angesichts der gemessenen Kennzahlenausprägungen wieder infrage zu stellen (vgl. [OIRW99, S. 210-211]).

Doch was den Unternehmen heute ebenso fehlt, wie damals den Sumerern bei der Entwicklung ihrer Schrift, ist eine Art Grammatik, die es erlaubt, diese Kausalbeziehungen systematisch zu entwickeln und auf Gültigkeit zu überprüfen. Kausalhypothesen werden stattdessen meist assoziativ und auf Basis von Intuition entwickelt (vgl. [Resc05, S. 63]). Man verlässt sich auf vage Vermutungen und hypothetische Zusammenhänge, ohne diese in regelmäßigen Abständen zu überprüfen (vgl. [Oehl06, S. 249]). Treten dann die beabsichtigten Wirkungen der beschlossenen Maßnahmen nicht ein, können falsche Ursache-Wirkungs-Annahmen eine bereits akute Krise zusätzlich verschärfen und den Handlungsspielraum des Unternehmens weiter einschränken. Ein weiteres Problem assoziativ gewonnener Kausalmodelle ist, dass sie nicht selten etwas unbeholfen und überfrachtet wirken. Dies illustriert das Kausalmodell in Abbildung 1 anschaulich.

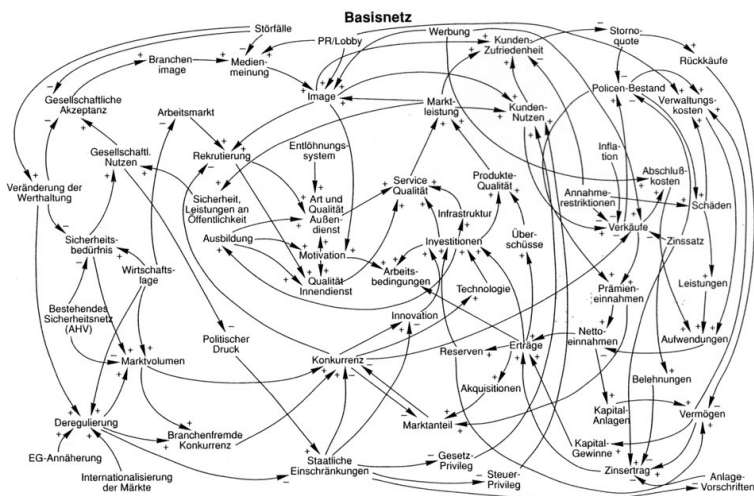


Abbildung 1: Beispiel eines Kausalmodells [PrGo91, S. 236]

Ein solches Kausalmodell mag zwar das Ergebnis einer anregenden Diskussion sein, kann aber auch den gegenteiligen Effekt erzielen, getreu dem Motto: „Wenn alles voneinander abhängt, dann ist es müßig, sich allzu viel Gedanken über Ursache und Wirkung zu machen.“ Dieser Fatalismus führt in der Regel dazu, dass die Unternehmen den Einsatz kausaler Kennzahlbeziehungen nur auf strategisch bedeutsame Wirkungszusammenhänge beschränken und die resultierenden Kausalmodelle lediglich als Mittel zur Strategiebeschreibung und -vermittlung verwenden (vgl. [Horv04, S. 59]). Dieses Vorgehen wird aber der Komplexität der betrieblichen Realität nicht gerecht, vor allem wenn man Kausalhypothesen nur als Teil linearer Ursache-Wirkungs-Ketten betrachtet und Rückkopplungen sowie multikausale Einflussbeziehungen vernachlässigt (vgl. [KrMü93, S. 100], [Wall01, S. 72]). Dadurch kann nur ein bruchstückhafter Einblick in die tatsächliche Wirkungsmechanik der Generierung betrieblicher Performance gewonnen werden. Viele Vorteile, die mit einer fundierten Kenntnis von Ursache und Wirkung verbunden sind, bleiben ungenutzt - wertvolles Gestaltungs- und Lenkungspotenzial wird verschenkt (vgl. [EaWa00, S. 143]).

Es stellt sich daher die Frage, wie den Unternehmen im Performance-Management ein anderer, systematischerer Umgang mit Ursache-Wirkungs-Beziehungen gelingen kann. Auf welchen Wegen können Kausalhypothesen entwickelt und überprüft werden?

Einen Weg scheint der Einsatz von Informationstechnologie, speziell die Datenanalyse, vorzuzeichnen. Tatsächlich ist es so, dass den Unternehmen heute dank einer integrierten Systemlandschaft und der Möglichkeit zur kostengünstigen Datenspeicherung so viele Daten wie noch nie zuvor für eine Datenanalyse zur Verfügung stehen. Allerdings dreht sich der Einsatz der Informationstechnologie im Performance-Management noch immer primär um die Frage, wie sich die Kennzahlendaten effizient erheben, speichern und in Form elektronischer Berichte, Dashboards oder Management-Cockpits bereitstellen lassen. Die Möglichkeit, Kausalhypothesen mittels moderner Analyseverfahren zu überprüfen - ja sogar zu entdecken - bleibt ungenutzt. Dies gilt speziell für Data-Mining-Verfahren, mit denen sich die umfangreichen Datenbestände eines Unternehmens automatisiert nach auffälligen Datenmustern durchsuchen und zur Entwicklung neuer Hypothesen nutzen lassen. Das Unterstützungspotenzial, das den Data-Mining-Verfahren speziell bei der Entdeckung von Kausalzusammenhängen zuzusprechen ist, wird in der Literatur zum Performance-Management bislang kaum bzw. nur am Rande erwähnt (vgl. [Brun99, S. 211], [Oehl00, S. 400-401], [KaNo01, S. 310-313], [PiMe03, S. 130-131], [Coki04, S. 255-256]).

Dies mag zum einen daran liegen, dass ein Management-Cockpit, das Kennzahlenwerte wahlweise als Tachometer oder als Ampel anzeigt, noch immer das gewichtigere Verkaufsargument für eine Software zum Performance-Management zu sein scheint. Zum anderen setzt eine datengestützte Kausalanalyse aber auch statistisches Methoden- und Domänenwissen voraus, das selten innerhalb *einer* Abteilung vorhanden sein wird. Aber wie können dem Performance-Management dennoch verlässliche Kausalinformationen bereitgestellt werden? Wie lässt sich die Aufgabe des Performance-Managements auf der einen Seite und die Aufgabe der evidenzgestützten Kausalanalyse auf der anderen Seite ausgestalten?

1.2 Zielsetzung

Gegenstand der Betriebswirtschaftslehre sind Entscheidungsprozesse, die dem Führungssystem betriebswirtschaftlicher Organisationen zuzuordnen sind (vgl. [Kirs79, S. 111]). Ein Hauptanliegen der Betriebswirtschaftslehre besteht darin, „diese Entscheidungsprozesse zu unterstützen und zu ihrer ‚Verbesserung‘ beizutragen“ [Kirs79, S. 110]. In diesem Sinne zeichnet sich das Performance-Management dadurch aus, diese Entscheidungsprozesse durch Kennzahlen - insbesondere durch den Einbezug nicht-finanzieller Kennzahlen - zu unterstützen. Welche Probleme dies in der Praxis bereitet, wurde bereits im vorherigen Abschnitt kurz skizziert. Als angewandte Forschungsdisziplin erhebt die Betriebswirtschaft aber den Anspruch, „einen Beitrag zur Lösung praktischer Probleme zu leisten. (...) Ihre Lösung ist um so fruchtbarer und aussichtsreicher, je mehr die Betriebswirtschaftslehre auch auf die Erkenntnisse anderer Wissenschaften zurückgreift“ [Hein77, S. 268].

Dieser Überzeugung folgend greift diese Arbeit auf Erkenntnisse der Wirtschaftsinformatik zurück, um folgende Fragen zu beantworten:

- **Frage 1:** Wie können die Defizite bestehender Performance-Management-Konzepte durch einen systematischeren Umgang mit Kausalinformationen behoben werden?
- **Frage 2:** Wie lassen sich Kausalhypothesen für das Performance-Management evidenzbasiert entwickeln und überprüfen?

Die Wirtschaftsinformatik beschäftigt sich mit dem Aufbau und der Funktionsweise von Informationssystemen (vgl. [FeSi08, S. 1]). Kennzeichen von Informationssystemen ist, dass sie Informationen verarbeiten und, sofern sie nicht selbst Teil des betrieblichen Leistungssystems sind, dessen Leistungserstellung planen,

steuern und kontrollieren (vgl. [FeSi08, S. 2]). In dieser Arbeit wird das Performance-Management als ein informationsverarbeitendes System zur Planung, Steuerung und Kontrolle der Leistungserstellung betrachtet. Als solches benötigt und verarbeitet es Kausalinformationen, die in Form von Kausalhypothesen zu entwickeln und zu überprüfen sind. Ebenso wie das Performance-Management ist somit auch die Entwicklung und Überprüfung von Kausalhypothesen eine Aufgabe des zum Lenkungssystem gehörenden Informationssystems. Hierbei wird allerdings Folgendes unterstellt: Die Kausalanalyse ist keine originäre Teilaufgabe des Performance-Managements, sondern kann davon unabhängig durchgeführt werden. Dieser Aufgabentrennung entsprechend verfolgt diese Arbeit zwei Ziele, die als Antwort auf die beiden Ausgangsfragen zu verstehen sind:

- **Ziel 1:** Entwicklung eines generischen Performance-Management-Prozesses, der Kausalinformationen als Mittel zur ganzheitlichen Gestaltung und Lenkung der betrieblichen Performance nutzt
- **Ziel 2:** Entwicklung von Gestaltungsoptionen für einen Analyseprozess, der entscheidungsrelevante Kausalinformationen bereitstellt

Hierbei ist zu beachten, dass das Performance-Management nur eine mögliche Anwendungsdomäne für die Entwicklung und Überprüfung von Kausalhypothesen darstellt. Der Analyseprozess ist deshalb so auszugestalten, dass er auch Entscheidungsprozesse in anderen Domänen mit Kausalinformationen versorgen kann. Dies trägt dem Umstand Rechnung, dass Kausalinformationen auch in anderen Disziplinen, wie zum Beispiel der Soziologie oder der Biologie, von Bedeutung sind. Mit welchem methodischen Vorgehen diese Zielsetzung verfolgt wird und wie die folgenden Kapitel inhaltlich aufeinander aufbauen, wird im folgenden Abschnitt erläutert.

1.3 Aufbau der Arbeit

Gemäß der beiden Zielsetzungen gliedert sich die Arbeit in zwei Teile: Während sich die Kapitel 2, 3 und 4 dem Performance-Management widmen und die erste Zielsetzung verfolgen, widmen sich die Kapitel 5, 6 und 7 den Gestaltungsoptionen des Analyseprozesses und deren Anwendung (siehe Abbildung 2).

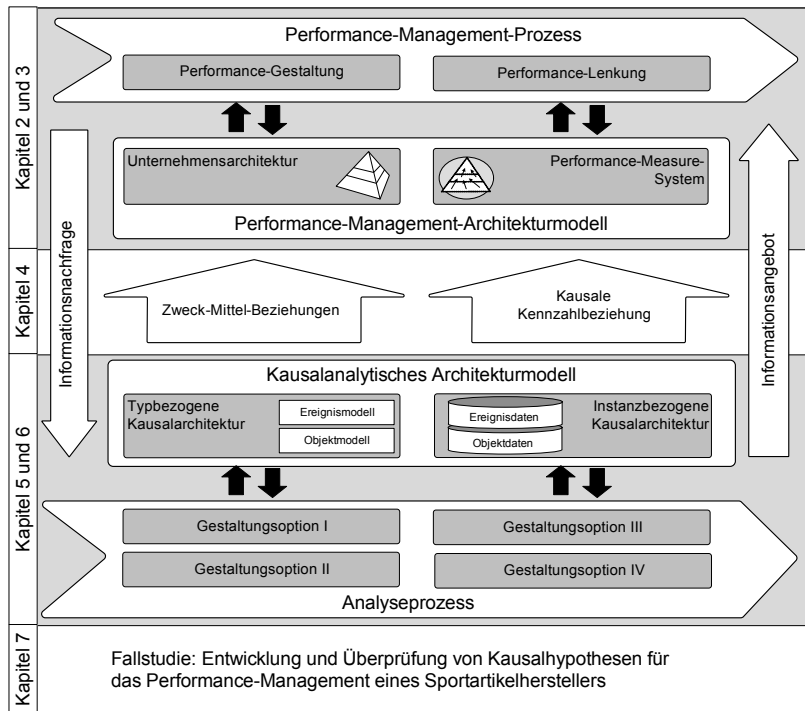


Abbildung 2: Inhaltlicher Aufbau der Dissertation

Nach dem einleitenden Kapitel 1 geht Kapitel 2 zunächst auf die Grundlagen und Defizite bestehender Performance-Konzepte ein. Hier steht die Frage im Mittelpunkt, warum es vielen Unternehmen nicht gelingt, die theoretischen Performance-Konzepte in die Praxis umzusetzen und welche konzeptionellen Defizite sich hierfür als Grund anführen lassen.

Diese Defizite des Performance-Managements sind in Kapitel 3 der Anlass, ein ganzheitliches Performance-Management-Konzept zu entwickeln, das die konzeptionellen Defizite überwindet. Zu diesem Zweck wird ein systemtheoretischer Bezugsrahmen entwickelt, der unter anderem aus einem Architekturmodell besteht, mit dem sich die Performance eines Unternehmens gestalten und lenken lässt. Anschließend wird für das Performance-Management ein generisches Prozessmodell entwickelt, das die Phasen und Aktivitäten der Performance-Gestaltung und -Lenkung beschreibt.

Kapitel 4 zeigt anhand dieses Prozessmodells, wie das Performance-Management Kausalhypothesen zur Begründung von Zweck-Mittel-Beziehungen und kausalen Kennzahlbeziehungen nutzen kann. Kapitel 4 schlägt somit die Brücke zum zweiten Teil, der sich der Entwicklung und Überprüfung dieser Kausalhypothesen widmet.

Kapitel 5 erarbeitet zunächst die konzeptionellen und methodischen Grundlagen der Kausalanalyse. Während die konzeptionellen Grundlagen die Frage beantworten, was eine Kausalinformation ist und durch welche Merkmale sich ein Ursache-Wirkungs-Zusammenhang auszeichnet, gehen die methodischen Grundlagen der Frage nach, wie sich diese Zusammenhänge entwickeln und überprüfen lassen. Analog zum Architekturmodell des Performance-Managements erhält auch der Analyseprozess ein Architekturmodell, auf dem er operiert. Das kausalanalytische Architekturmodell ähnelt in seiner Funktion einer Grammatik, indem es sich sowohl zur Beschreibung als auch zur Gestaltung kausaler Strukturen und Infrastrukturen eignet. Kapitel 5 schließt mit einem Überblick über datenzentrierte Analyseverfahren, die sich in hypothesen- und datengetriebene Verfahren unterteilen.

Kapitel 6 stellt insgesamt vier verschiedene Gestaltungsoptionen für den Analyseprozess vor. Jede Gestaltungsoption ist als prozessuales Lösungsverfahren für die Entwicklung und die Überprüfung von Kausalhypothesen konzipiert. Die vier Gestaltungsoptionen lassen sich auf unterschiedliche Weise zu einem integrierten Analyseprozess aneinanderfügen. Welche Kombinationsmöglichkeiten sich hierbei ergeben, wird am Ende von Kapitel 6 beschrieben.

Eine Sonderstellung nimmt Kapitel 7 ein, das die Anwendung der vier Gestaltungsoptionen empirisch überprüft. Hierzu wurde in einem Unternehmen der Sportartikelbranche ein Fallstudienprojekt durchgeführt. In dem Projekt wurden Kausalhypothesen für das Performance-Management des Kundenauftragprozesses sowohl entwickelt als auch überprüft.

2 Grundlagen und Defizite bestehender Performance-Konzepte

„What is it that fills a sport arena and excites stock brokers? What is it, likewise, that is of concern to the dean of a faculty as well as to the manager of a profit center? It is, in each case, performance - performance that permeates contemporary societies, breathes its spirit into them in a diffuse but penetrating way, and imprints its mark upon them.“ [Corv95, S. 1]

Wann immer das Wort Performance in den letzten Jahren dazu verwendet wurde, einem neuen Konzept einen Namen zu geben, gelang damit scheinbar Widersprüchliches: Egal ob von *Business Performance Management*, *Strategic Performance Management*, *Corporate Performance Management*, *Performance Appraisal*, *Performance Evaluation* oder *Process Performance Management* die Rede war, allein durch den Zusatz Performance sicherte man sich Aufmerksamkeit ohne den Preis zahlen zu müssen, inhaltlich konkret zu werden. Tauchte das Wort Performance auf, verlieh es sowohl dem Autor und Referenten als auch deren Lesern und Zuhörern eine Aura der Weltläufigkeit, gepaart mit dem Gefühl, auf der Höhe der Zeit zu sein.

So mag die eingangs zitierte Passage von Corvellec an das erinnern, was Hans Christian Andersen in seinem Märchen „Des Kaisers neue Kleider“ beschreibt. Dennoch wäre es falsch anzunehmen, alle Performance-Konzepte wären aus demselben substanzlosen Garn gewebt wie des Kaisers neue Kleider. Ziel dieses Kapitels ist es, den Stoff vorzustellen, aus dem das „Kleid“ namens Performance-Management gewebt ist. Abschnitt 2.1 erläutert daher zunächst die Grundlagen bestehender Performance-Management-Konzepte. Warum aber dieses Kleid vielen Unternehmen noch immer nicht richtig passt und an welchen Stellen noch Löcher zu stopfen sind, zeigt Abschnitt 2.2, der die Defizite bestehender Performance-Management-Konzepte vorstellt.

2.1 Grundlagen bestehender Konzepte zum Performance-Management

Ebenso, wie die Qualität der verwendeten Baumwolle die Qualität des gewebten Kleides bestimmt, hängt die Qualität des Performance-Managements von dem verwendeten Performance-Begriff ab. Der Abschnitt 2.1.1 geht daher zunächst auf den Begriff der betrieblichen Performance ein, bevor Abschnitt 2.1.2 zeigt, was unter dem Konzept des Performance-Managements zu verstehen ist.

2.1.1 Der Begriff der betrieblichen Performance

„Performance is not an easy subject.“ [Meye02, S. 51]

Der Performance-Begriff wird in der Literatur oft nur unzureichend bestimmt und konkretisiert (vgl. [MeZu89, S. 65]). Häufig verweisen die Autoren zunächst auf die unterschiedlichen Konnotationen, die in englischsprachigen Wörterbüchern unter dem Stichwort „Performance“ aufgeführt werden (vgl. [Corv95, S. 11], [LeEu02, S. 67-68], [Meye02, S. 55], [Wett02, S. 15], [KüWe03, S. 44]). Im Anschluss daran greifen sie dann eine Wortbedeutung heraus und verwenden diese als Basis ihrer eigenen Performance-Definition. Der Performance-Begriff weist daher im betrieblichen Kontext eine ähnlich hohe Bedeutungsvielfalt wie im alltäglichen Sprachgebrauch auf. Lebas und Euske charakterisieren Performance daher treffend als „suitcase word“, in das der Leser stets die Bedeutung „hineinpacken“ muss, die ihm der jeweilige Gebrauchskontext vorgibt (vgl. [LeEu02, S. 87]).

Trotz dieser Bedeutungsvielfalt hat unter deutschsprachigen Autoren die Performance-Definition von Hoffmann weite Verbreitung gefunden (vgl. [Erdm03, S. 95], [Pise04, S. 109], [MeWi04, S. 1]). Hoffmann setzt den englischen Performance-Begriff mit dem deutschen Begriff Leistung gleich und bezeichnet beide Begriffe als den „bewertete[n] Beitrag zur Erreichung der Ziele einer Organisation“ [Hoff00, S. 8]. In der englischsprachigen Literatur entspricht dieser Auffassung bereits die Definition von Meyer und Zucker, die Performance als „measuring attainment of official objectives“ [MeZu89, S. 67] angeben.

Eine Übersetzung von „Performance“ mit dem deutschen Begriff der Leistung wird jedoch von einigen Autoren explizit abgelehnt. Sie sind der Ansicht, dass der deutsche Leistungsbegriff in seiner betriebswirtschaftlichen Bedeutung zu

eng gefasst sei (vgl. [Ried00, S. 16], [KüWe03, S. 9]). Zum einen, weil er sich nicht deutlich genug vom Leistungsbegriff des Rechnungswesens abhebt (vgl. [KüWe03, S. 9]), zum anderen, weil er sich primär aus der Produktionstheorie ableitet und daher meist nur als „Ergebnis der betrieblichen Tätigkeit“ [Ried00, S. 16] verstanden wird.

Diesem engen Verständnis betrieblicher Leistung steht jedoch die weiter gefasste Leistungsdefinition von Mellerowicz gegenüber, wonach Leistung nicht nur das Ergebnis der Betriebsaufgabe, sondern auch deren Erfüllung umfasst (vgl. [Mell63, S. 188]). Eine solche ergebnis- und aktionsorientierte Leistungsdefinition deckt sich mit der von Corvellec vertretenen Auffassung, wonach sich Performance simultan auf die Aktion und das Ergebnis bezieht (vgl. [Corv95, S. 28]), dessen Erfolg sich anhand eines festzulegenden Erwartungswertes bemisst.

Die Verbindung zwischen Aktion und Ergebnis stellt auch Neely her, indem er Performance als Resultat effizienter und effektiver Aktionen betrachtet, die das Unternehmen in der Vergangenheit unternommen hat (vgl. [Neel98, S. 5]), oder wie es Lebas und Euske ausdrücken: „we define performance as doing today what will lead to *measured* value outcome tomorrow“ [LeEu02, S. 68]. Diese aktions- und ergebnisorientierte Performance-Auffassung steht mit der zielorientierten Definition im Einklang, da sich sowohl für das Ergebnis als auch für die betriebliche Tätigkeit ein bewerteter Beitrag zur Zielerreichung bestimmen lässt.

Küing und Wettstein vertreten wiederum die Ansicht, dass die betriebliche Performance auf den „Grad der Zufriedenheit der relevanten Anspruchsgruppen“ [KüWe03, S. 45] zurückführen sei. Relevante Anspruchsgruppen können Investoren, Kreditgeber, der Gesetzgeber sowie die Mitarbeiter, Lieferanten und Kunden sein (vgl. [AtWW97, S. 27], [Müll98, S. 34-35], [Schm97, S. 633]). Oder wie es Freeman definiert: „A stakeholder in an organization is (by definition) any group or individual who can affect or is affected by the achievement of the organizations's objectives“ [Free84, S. 46]. Somit lässt sich auch diese an den Stakeholderinteressen orientierte Auffassung mit der zielorientierten Definition verbinden, falls man die Aufgabe der Zielplanung darin sieht, die Interessen der als relevant erachteten Anspruchsgruppen in unternehmerische Ziele zu übersetzen. Erst wenn diese Übersetzungsarbeit im Rahmen der Zielplanung geleistet wurde, ist sichergestellt, dass der bewertete Beitrag zur Zielerreichung auch zur Zufriedenheit der relevanten Stakeholder beiträgt.

Dies entspricht auch dem dieser Arbeit zugrunde liegenden Begriff betrieblicher Performance: Performance ist der Aktionen und deren Ergebnissen beizu-

messende Beitrag zur Erreichung der Unternehmensziele, mit denen die Zufriedenheit der als relevant erachteten Anspruchsgruppen sichergestellt werden soll.

2.1.2 Performance-Management als Erweiterung des Performance-Measurements

„Measurement is fundamental to our way of life. We measure everything. (...) When we were babies, the doctor measured our height and weight to be sure that we were healthy. When we started school, our teachers measured us to understand our weaknesses and help us progress.“
[Harr91, S. 167-168]

Den Worten von James Harrington folgend, stellt die Idee des regelmäßigen Messens etwas sehr Grundlegendes in unserem Leben dar. Dies gilt auch für das Management, zu dessen Aufgabe seit jeher gehört, „Leistungsgrößen zu bestimmen, diese zu messen und zu bewerten“ [Pise04, S. 111]. Eigentlich gibt dies bereits den Grundgedanken des Performance-Measurements wieder, das dem umfassenderen Performance-Management als Teilkonzept zugrunde gelegt werden kann (vgl. [Bred95b, S. 186], [Hoff00, S. 299]). Obwohl beide Begriffe in der Literatur zuweilen synonym verwendet werden, sollen sie in dieser Arbeit voneinander abgegrenzt werden. Hierzu werden im Folgenden die historischen Wurzeln beider Konzepte freigelegt und gezeigt, dass das Performance-Management als eine konzeptionelle Erweiterung des Performance-Measurements zu sehen ist.

Als Vorläufer des Performance-Measurements lassen sich die traditionellen Steuerungs- und Kennzahlensysteme angeben (vgl. [Glad02, S. 7]), deren Aufgabe darin besteht, „Sachverhalte in übersichtlicher Art und Weise darzustellen und die Entscheidungsträger (...) durch Informationsverdichtung und Zusammenfassung mit hinreichender Genauigkeit und Aktualität zu informieren“ [Glei01, S. 6]. Mitte der 80er Jahre setzte sich die Ansicht durch, dass die traditionellen Kennzahlensysteme dieser Aufgabe nicht mehr gerecht werden, weshalb als Folge neue Ansätze zur Leistungsmessung entwickelt wurden (vgl. [GIKi02, S. 89], [Horv02, S. 587]). Hauptkritikpunkt war die zu starke Ausrichtung auf finanzielle Messgrößen, da diese zu zahlreichen Steuerungsdefiziten führen (vgl. [Glad02, S. 5]), die die Existenz eines Unternehmens in einem turbulenten Wettbewerbsumfeld nachhaltig gefährden. Im Folgenden werden die vier Hauptdefizite finanzieller Kennzahlensysteme erläutert, die zur Entwicklung der ersten Performance-Measurement Ansätze führten: der unzureichende Sach-

ziel-, Zukunfts- und Strategiebezug sowie die geringe Aussagekraft monetärer Messgrößen.

In ihrem 1987 veröffentlichten Buch „Relevance lost - the rise and fall of management accounting“ wiesen Johnson und Kaplan auf diese Defizite explizit hin (vgl. [JoKa87, S. 253-263]). Ihrer Auffassung nach werden finanzielle Kennzahlen der wachsenden Bedeutung technologischer Innovationen und immaterieller Vermögenswerte nicht mehr gerecht, da sie deren Beitrag zum Unternehmenserfolg nicht adäquat abbilden können (vgl. [JoKa87, S. 253-257]). Monetäre Messgrößen vernachlässigen die Sachziel dimension (vgl. [Horv02, S. 582]) und „klammern (...) nichtfinanzielle Unternehmensziele wie Umweltschutz, Gemeinwirtschaftlichkeit oder die Mitarbeiterwohlfahrt explizit aus“ [Glei01, S. 6]. Finanzkennzahlen sind unter diesen Gesichtspunkten bestenfalls obsolet - meist jedoch schädlich, da von ihnen keine Impulse für zukünftige Investitionen in neue Technologien und Märkte ausgehen (vgl. [Eccl91, S. 28]).

Der fehlende Zukunftsbezug reiner Finanzdaten resultiert aus der Tatsache, dass diese per se vergangenheitsorientiert sind (vgl. [Brun99, S. 12], [Glei01, S. 8], [KüWe03, S. 11]) und „man nur das misst, was sich bereits finanziell (positiv oder negativ) niedergeschlagen hat“ [Küng00, S. 830]. Sich ausschließlich auf finanzielle Informationen zu verlassen, bedeutet daher, über die Schulter zurück in die Vergangenheit zu schauen (vgl. [Wade01, S. 6]) und kritische Entwicklungen erst mit zeitlicher Verzögerung wahrzunehmen (vgl. [Klin99, S. 2]).

Aufgrund ihres fehlenden Sachziel- und Zukunftsbezugs bieten traditionelle Kennzahlensysteme nur Anreize für ein gewinnmaximierendes und ausschließlich auf die Erreichung kurzfristiger Finanzziele ausgerichtetes Handeln (vgl. [BMW+00, S. 2], [Glei01, S. 7], [KüWe03, S. 11]). Strategische Maßnahmen, deren Ziel der Aufbau langfristiger Erfolgspotenziale ist, geraten auf diese Weise leicht aus dem Blickfeld des Managements.

Ein weiterer Grund, weshalb man ein Unternehmen nicht ausschließlich mit finanziellen Messgrößen abbilden und steuern sollte, liegt in deren geringer Aussagekraft. Zum einen ist hierfür der oft zu hohe Aggregationsgrad verantwortlich, was die Interpretation der Kennzahlen und die Ableitung konkreter Handlungsempfehlungen erschwert (vgl. [Klin99, S. 2], [Glei01, S. 8]). Zum anderen sind finanzielle Spitzenkennzahlen anfällig für bilanzpolitische Manipulationen, da ihnen oftmals unterschiedliche Berechnungsgrundlagen zugrunde gelegt werden können (vgl. [Eccl91, S. 41], [KüKr99, S. 3], [Glei01, S. 7], [KüWe03, S. 10]).

Die vier genannten Steuerungsdefizite - der fehlende Sachziel-, Zukunfts- und Strategiebezug sowie die geringe Aussagekraft der Finanzgrößen - sind dafür verantwortlich, dass traditionelle Kennzahlensysteme - insbesondere in einem dynamischen Markt- und Wettbewerbsumfeld - keine wirksamen Steuerungs- und Kontrollinstrumente darstellen (vgl. [Glei01, S. 7], [Pise04, S. 109]).

Die Entwicklung der ersten Performance-Measurement Ansätze resultiert allerdings nicht nur aus dem Wunsch der Unternehmen, ihr betriebsinternes Geschehen transparenter abzubilden, um „eine zeitnahe Erfolgskontrolle und Unternehmenssteuerung“ [Frös02, S. 1] zu gewährleisten. Die Kernidee des Performance-Measurements, ein Unternehmen über die monetären Kennzahlen hinaus auch mithilfe von nicht-monetären Kenngrößen abzubilden, resultiert aus zwei sich überlagernden Interessen: dem ursprünglich unternehmensintern motivierten Interesse an neuen Steuerungskonzepten sowie der Forderung unternehmensexterner Anspruchsgruppen, dass Unternehmen auch nicht-monetäre Informationen publizieren.

Die Internationalisierung der Kapitalmärkte zwang die Unternehmen, ihr Berichtssystem den veränderten Informationsansprüchen externer Kapitalgeber und Investoren anzupassen und ihr Ziel der Gewinnmaximierung dem Ziel der Unternehmenswertmaximierung unterzuordnen (vgl. [Klin99, S. 1], [GSGK02, S. 337]). Externe Kapitalgeber und Investoren erbringen aufgrund ihrer engen Verflechtung mit den Unternehmen einen wichtigen Beitrag zur betrieblichen Wertschöpfung. Mit dem Wissen um die geringe Aussagekraft der Finanzdaten fordern jene im Gegenzug auch vermehrt Informationen ein, die über die vierteljährliche Berichterstattung der monetären Eckdaten hinausgehen und nicht-monetäre Kenngrößen als wesentlichen Bestandteil mit einschließen (vgl. [Klin97, S. 642], [GSGK02, S. 344]).

Damit das Performance-Measurement nicht nur einseitig den Informationswünschen der Shareholder gerecht wird, ist eine Integration sämtlicher Stakeholderansprüche zu empfehlen (vgl. [Horv02, S. 587]). Da die Erfolgsgrößen eines Unternehmens maßgeblich von den Interessen der Stakeholder bestimmt werden (vgl. [Klin99, S. 7]), sollten auch deren Erwartungen von Anfang an bei der Zielformulierung und der Entwicklung der Performance-Messgrößen berücksichtigt werden (vgl. [Küng00, S. 834]).

Die meisten Performance-Measurement-Ansätze entwickelten sich Ende der 80er und Anfang der 90er Jahre in anglo-amerikanischen Beratungsunternehmen (vgl. [Klin99, S. 3]). Dieser praxisgetriebenen Entwicklung ist es geschul-

det, dass der Begriff des Performance-Measurements bis heute uneinheitlich definiert und verwendet wird (vgl. [Glei01, S. 13], [Erdm03, S. 59]). Stellte Neely im Jahr 1995 noch fest: „Performance Measurement is a topic which is often discussed but rarely defined“ [NeGP95, S. 1], scheint es sich sieben Jahre später, 2002, gerade umgekehrt zu verhalten. Denn Neely sah in der großen Zahl der unterschiedlichen Definitionen die Ursache für die schleppende Weiterentwicklung des Performance-Measurement: „Everyone writing about the topic has his/her own preferred references and freely cites them. While this diversity is appealing, it also hinders development, because it makes it almost impossible for generations of researchers to build upon the work of others“ [Neel02, S. xii].

Obwohl in der deutschsprachigen Literatur ebenfalls unterschiedliche Definitionen zum Performance-Measurement anzutreffen sind, greifen viele Autoren auf eine Definition von Gleich zurück (vgl. [Horv02, S. 587], [Baum02, S. 19], [Erdm03, S. 63]):

„Darunter wird der Aufbau und Einsatz meist mehrerer quantifizierbarer Maßgrößen verschiedenster Dimensionen (z.B. Kosten, Zeit, Qualität, Innovationsfähigkeit, Kundenzufriedenheit) verstanden, die zur Beurteilung der Effektivität und Effizienz der Leistung und Leistungspotenziale unterschiedlicher Objekte im Unternehmen (Organisationseinheiten unterschiedlichster Größe, Mitarbeiter, Prozesse) herangezogen werden.“ [Glei97, S. 115]

Indem Gleich nicht nur den Einsatz, sondern auch den *Aufbau* der Messgrößen als Bestandteil des Performance-Measurements auffasst, verdeutlicht er, dass Performance-Measurement „mehr als nur die Ansammlung von verschiedenen Kennzahlen ist“ [Pise04, S. 118]. Neben dem originären Zweck des Performance-Measurements, Informationen über den Grad der Zielerreichung zu liefern (vgl. [SaBH02, S. 1254]), unterstützt nämlich bereits die Entwicklung geeigneter Messgrößen die Sach- und Formalzielplanung und hilft, die Unternehmensstrategien zu operationalisieren (vgl. [Glei01, S. 13 u. 23]). Um „die Brücke zwischen Strategie und der operativen täglichen Arbeit zu schlagen“ [Baum02, S. 18], müssen nicht-finanzielle Messgrößen auf „allen erfolgs- und leistungsrelevanten Unternehmensebenen“ [Horv02, S. 587] berücksichtigt werden. Da die Bedeutung und Dominanz finanzieller Kenngrößen entlang der Hierarchieebenen einer Unternehmung tendenziell abnimmt (vgl. [Klin99, S. 20]), kann man erst dann von einer vertikalen Integration von Führung und Ausführung sprechen, wenn die Leistungsindikatoren der unteren Ebenen konsequent mit den Finanzkennzahlen der oberen Ebenen verknüpft werden. Hierauf gründet sich die Forderung von Neely et al., dass das Performance-Measurement einen Manager bei der Übersetzung seiner Strategien in konkrete Aktionen unterstützen sollte (vgl.

[NMR + 03, S. 133]). Das Performance-Measurement ist daher nicht nur ein verbessertes Kennzahlensystem, sondern zusätzlich „ein Instrument zur Verbindung von strategischer und operativer Steuerung“ [Glad02, S. 5].

Genau dies weist den Weg zum Performance-Management. Die Unternehmensperformance lässt sich nämlich nicht allein durch den Aufbau und Einsatz quantitativer Messgrößen verbessern. Es bedarf stets konkreter Maßnahmen, um die Performance eines Unternehmens auf Dauer aufrechtzuerhalten bzw. nachhaltig zu steigern. „Performance is not simply measured, it is proactively created“ [Leba94, S. 39]. Diese trivial anmutende Einsicht liegt dem Konzept des Performance-Managements zugrunde, welches sich im Gegensatz zum Performance-Measurement nicht auf das Messen der Performance beschränkt, sondern „das ‚Managen‘ und damit die Planung, Steuerung und Kontrolle der Performance“ [Brun99, S. 11] als Ganzes in den Vordergrund rückt.

Obwohl das Performance-Management weitaus mehr als die Messung der Unternehmensperformance umfasst, können beide Konzepte nicht unabhängig voneinander definiert werden. Prozessual betrachtet ist das Performance-Measurement ein Teilprozess des Performance-Managements (vgl. [Ried00, S. 25]). Indem das Performance-Measurement „die Konsequenzen von performancebezogenen Entscheidungen aufzeigt“ [Hoff00, S. 31], soll es die notwendige Transparenz liefern, um weitere Maßnahmen zur Performance-Verbesserung zu planen und zu initiieren. Indem das Performance-Management auf die vom Performance-Measurement bereitgestellten Informationen zurückgreift, sorgt es für einen geschlossenen Führungskreislauf (vgl. [KüWe03, S. 43]).

2.2 Defizite bestehender Konzepte zum Performance-Management

Nachdem im vorherigen Abschnitt die Grundidee des Performance-Managements vorgestellt wurde, zeigen die beiden folgenden Abschnitte, woran die konsequente Umsetzung dieser Idee in der Praxis scheitert (siehe Abschnitt 2.2.1) und auf welche konzeptionellen Defizite sich dieses Scheitern zurückführen lässt (siehe Abschnitt 2.2.2).

2.2.1 Defizite in der praktischen Umsetzung

Obwohl die ersten Performance-Konzepte aus den späten 80er und frühen 90er Jahren datieren (vgl. [Glei01, S. 11], [Horv02, S. 587]), bereitet ihre praktische Umsetzung vielen Unternehmen selbst heute noch erhebliche Schwierigkeiten.

Dies betrifft vor allem den Umgang mit nicht-finanziellen Messgrößen. „Viele Unternehmen versäumen es, die richtigen nicht-finanziellen Indikatoren zu identifizieren, zu analysieren und schließlich nach den gewonnenen Erkenntnissen zu handeln“ [ItLa04, S. 71]. Santos et al. teilen die Gründe, weshalb bislang so viele Initiativen zur Performance-Verbesserung gescheitert sind, in zwei Gruppen ein: „the first refers to the design and implementation of performance measurement systems; the second refers to the analysis of the information resulting from measurement“ [SaBH02, S. 1248]. Dieser Einteilung folgend werden zunächst die Problemfelder beim Aufbau eines mehrdimensionalen Kennzahlensystems vorgestellt, bevor anschließend die Defizite bei der Interpretation der Messgrößen erläutert werden, die sich wiederum negativ auf die Umsetzung von Maßnahmen auswirken. Abbildung 3 fasst die im Folgenden vorgestellten Defizite zusammen.

1999 wurden von der Unternehmensberatung Arthur Andersen insgesamt 70 Unternehmen, vornehmlich aus Deutschland und der Schweiz, nach ihren Erfahrungen mit Konzepten des Performance-Managements befragt (vgl. [Brun99, S. 13]). Obwohl über 60% der Unternehmen sowohl finanzielle als auch nicht-finanzielle Kennzahlen verwenden (vgl. [Brun99, S. 15]), beklagten die meisten Führungskräfte eine zu starke Ausrichtung ihrer Berichtssysteme auf Finanzkennzahlen (vgl. [Brun99, S. 13]) und dass es ihnen vor allem an zuverlässigen Informationen über unternehmenskritische Prozesse fehle (vgl. [Brun99, S. 15]). Finanzkennzahlen gilt noch immer das weitaus größte Interesse und nicht-finanzielle Indikatoren werden allenfalls am Rande beachtet. Dieses Bild betätigte sowohl die umfangreiche Studie von Weber und Sandt (vgl. [WeSa01, S. 15]) als auch die von Küng und Wettstein durchgeführte Befragung Schweizer Großunternehmen (vgl. [KüWe03, S. 37]). In diesem Punkt hat sich seit 1996 scheinbar nichts geändert, als bereits Lingle und Schiemann in ihrer in den USA durchgeführten Studie zum gleichen Ergebnis kamen: Die Mehrzahl der Manager erkennt zwar die Bedeutung und den Wert nicht-finanzieller Indikatoren, es gelingt ihnen aber dennoch nicht, diese in ein aussagekräftiges Messsystem zu integrieren (vgl. [LiSc96, S., 57], [Pise04, S. 116]; siehe Abbildung 3: 1a).

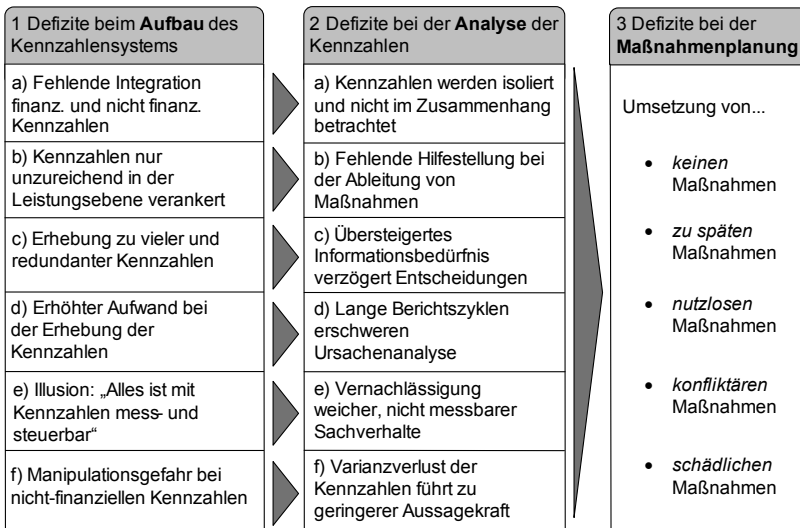


Abbildung 3: Defizite in der praktischen Umsetzung des Performance-Managements

Als Grund hierfür führen Küng und Wettstein an, dass nicht-finanzielle Indikatoren stets in der Leistungssphäre eines Unternehmens zu verankern sind, damit ihr Einfluss auf das finanzielle Ergebnis abgebildet werden kann (siehe Abbildung 3: 1b). Da sich diese Einflussfaktoren aber von Unternehmen zu Unternehmen unterscheiden, lassen sich nicht-finanzielle Messgrößen nicht standardisiert vorgegeben und ihre Kennzahlensysteme sind - im Gegensatz zu den etablierten Finanzkennzahlen - für jedes Unternehmen individuell zu entwickeln (vgl. [Kups79, S. 91], [KüWe03, S. 73]). „Je nachdem, ob es sich um eine Autowerkstätte, einen Flugzeughersteller, eine Schule, ein Spital oder um eine Anwaltskanzlei handelt, müssen diese Kennzahlen anders definiert werden, damit sie sinnvoll eingesetzt werden können“ [KüWe03, S. 74]. Diesen Aufwand scheuen noch immer viele Unternehmen und verlassen sich stattdessen noch immer auf die Informationen, die ihnen die standardisierten Finanzkennzahlen liefern.

Obwohl die Entwicklung geeigneter nicht-finanzieller Messgrößen sehr zeit- und kostenaufwändig ist, verwenden wiederum andere Unternehmen zu viele Kennzahlen, indem sie versuchen, „jede Lücke im Kennzahlensystem zu schließen. Das Ergebnis ist eine Fülle nebensächlicher, trivialer oder irrelevanter Messgrößen“ [ItLa04, S. 75] (siehe Abbildung 3: 1c). Es wird offensichtlich ver-

gessen, dass es weder möglich noch zweckmäßig ist, alle relevanten Leistungsparameter eines Unternehmens in das Kennzahlensystem aufzunehmen (vgl. [Klin99, S. 5], [Ried00, S. 79], [Paul04, S. 111]). Diese Entwicklung ist bedenklich: Zum einen, weil sich der Gewinn vieler Unternehmen nicht selten umgekehrt proportional zur Anzahl ihrer Kennzahlen entwickelt (vgl. [Paul04, S. 109]), zum anderen, weil man dann gleich vor dem nächsten Problem steht: Die Messgrößen müssen mit Inhalt gefüllt werden (vgl. [Meye02, S. 55]).

Eine im Jahr 2000 von Bourne et al. durchgeführte Fallstudie zeigt, dass das Erheben der Performance-Daten oft das größte Hindernis darstellt und dass hierbei gerade die Ausgestaltung der IT-Systeme über den Erfolg der Performance-Messung entscheiden kann (vgl. [BMW+00, S. 8]). Ein von Piser untersuchtes Unternehmen gab sogar an, dass der Versuch, das Performance-Konzept der *Balanced Scorecard* einzusetzen, nach drei erfolglosen Data-Warehouse-Projekten abgebrochen wurde (vgl. [Pise04, S. 177-178]). Gerade im nicht-finanziellen Bereich können die Prozesse zur Informationsbeschaffung und -aufbereitung eine regelrechte „Kostenexplosion“ verursachen (vgl. [JoFi00, S. 275], [GSGK02, S. 342]). Neely et al. weisen deshalb darauf hin, dass bezüglich der Anzahl der Performance-Measures der so genannte Pareto-Punkt nicht überschritten werden darf, da eine zu umfangreiche Datenerhebung („over-measurement“) unnötigen Aufwand verursacht (siehe Abbildung 31: 1d) und letztendlich nur zu einer unproduktiven Fein-Regelung des Mitarbeiterverhaltens führen würde (vgl. [NMR+03, S. 133]).

Einer solchen Fein-Regelung liegt die Vorstellung zugrunde, alles sei mit Kennzahlen mess- und steuerbar (siehe Abbildung 3: 1e). Diese Vorstellung entpuppt sich allerdings als Illusion (vgl. [Beck92, S. 132]). An diese Illusion knüpfen die Anbieter von IT-Lösungen zum Performance-Management an, indem sie die Führungskräfte dazu verleiten, sämtliche Informationen zu nutzen, die ihnen dank einer integrierten IT-Sytemlandschaft heute zur Verfügung stehen (vgl. [Ecc191, S. 38]). Welche Indikatoren und Kennzahlen aber zu erheben sind, sollte nicht auf Basis des Informationsangebots, sondern auf Basis des Informationsbedarfs entschieden werden. Erst in einem zweiten Schritt ist zu überprüfen, ob die verfügbaren Datenquellen in der Lage sind, diesen Bedarf zu decken (vgl. [KüWe03, S. 103]). Eine umgekehrte Reihenfolge würde bedeuten, „nicht diejenigen Aspekte zu messen, welche zum Führen eines Unternehmens notwendig sind, sondern das zu messen, was leicht zugänglich ist“ [KüWe03, S. 103].

Messgrößen, die konsequent auf Basis des Informationsbedarfs festgelegt wurden, sind aber in der Regel nur schwer zugänglich (vgl. [Oehl06, S. 251]).

Von den vorhandenen IT-Systemen werden sie oft nicht automatisch erfasst und müssen stattdessen manuell erhoben werden. Dies erhöht die Gefahr einer gezielten Manipulation, der speziell nicht-finanzielle Kennzahlen ausgesetzt sind (siehe Abbildung 3: 1f). Denn anders als die Bilanz- und Jahresabschlussgrößen, die nach gesetzlichen Berechnungsvorschriften erhoben werden, fehlen den nicht-finanziellen Kennzahlen solch verbindliche Regeln (vgl. [ItLa04, S. 73]). Der Anreiz für eine Datenmanipulation dürfte besonders bei denjenigen Mitarbeitern ausgeprägt sein, deren variable Vergütung direkt an die Ausprägung bestimmter Messgrößen geknüpft ist (vgl. [Paul04, S. 110]). Ein befragtes Industrieunternehmen gab sogar an, aufgrund der Manipulationsmöglichkeiten und den daraus resultierenden Interpretationsschwierigkeiten gänzlich auf die Einführung eines Performance-Measurement-Systems zu verzichten (vgl. [Pise04, S. 178]).

Hat man die Kennzahlen definiert und die Performance-Daten beschafft, müssen diese analysiert und interpretiert werden, um schließlich Maßnahmen zur Verbesserung der Performance abzuleiten. Doch auch hier offenbaren sich Defizite. Obwohl neutrale Kennzahleninformationen einer subjektiven Leistungsbeurteilung vorbeugen sollen (vgl. [Paul04, S. 109]), werden von den Führungskräften dennoch individuell unterschiedliche Schlussfolgerungen aus den Messwerten gezogen. Um dem entgegenzuwirken, bedarf es in erster Linie allgemein gültiger Reporting-Standards. Kennzahlen verlieren an Aussagekraft und Zuverlässigkeit - und infolgedessen auch an Akzeptanz -, wenn sie nicht überall im Unternehmen in gleicher Art und Weise gemessen und angewandt werden (vgl. [ItLa04, S. 77]). Küng und Wettstein sehen diese Gefahr bei einer IT-gestützten Analyse der Messgrößen, falls einheitliche Regeln und Prozeduren zur Datenanalyse fehlen, zum Beispiel indem bei ad hoc gestellten OLAP-Anfragen¹ unterschiedliche Filter und Analysemethoden zulässig sind. Dies führt zwangsläufig zu unterschiedlichen Analyseergebnissen und Interpretationen (vgl. [KüWe03, S. 132]).

Obwohl eine IT-gestützte Datenerhebung und -analyse die Auswertung der Messgrößen sinnvoll unterstützt, erfordert deren Interpretation in erster Linie menschlichen Sachverstand und nicht selten ein hohes Maß an Kreativität (vgl. [KüWe03, S. 157]). Um die Performance eines Unternehmens zu messen und adäquat zu beurteilen, bedarf es zudem eines verbindlichen Vergleichsmaßstabs zur Orientierung. „There must always be a comparison to qualify the performance“ [LeEu02, S. 76]. Speziell bei der Interpretation nicht-finanzieller Messgrö-

¹ OLAP steht für Online-Analytical-Processing und wird in Abschnitt 5.3.2.1 vorgestellt.

Ben ist zu bedenken, dass diese als Indikatoren lediglich einen ersten Hinweis auf Probleme oder kritische Sachverhalte liefern. Performance-Indikatoren sollten nie mit dem verwechselt werden, was sie eigentlich messen sollen, aber eben nur unzureichend, weil bruchstückhaft, abbilden (vgl. [Glad02, S. 5], [LeEu02, S. 75]). Um die Daten ausgewogen zu interpretieren und zu analysieren, sind einzelne Kennzahlen nicht isoliert, sondern stets in ihrem Zusammenhang mit anderen Kennzahlen zu betrachten (siehe Abbildung 3: 2a).

Dass gerade der Übergang von der Performance-Messung in die Maßnahmenplanung und -umsetzung schwierig und langwierig ist (vgl. [Hach02, S. 1394]), liegt auch daran, dass es den Anwendern an Hilfestellung bei der Entscheidung fehlt, „ob der Messwert eines Leistungstreibers strategische Aktionen bis hin zur Neudefinition der Strategie bedarf, oder ob nur operative Gegenmaßnahmen durchgeführt werden müssen“ [Pise04, S. 4] (siehe Abbildung 3: 2b). Eine solche Hilfestellung können nicht-finanzielle Messgrößen leisten, wenn sie in der operativen Leistungsebene verankert sind und ihr Einfluss auf die finanziellen Ergebnisgrößen nachvollzogen werden kann.

Lange Berichtszyklen sorgen dafür, dass Maßnahmen zu spät oder womöglich gar nicht ergriffen werden: zum einen, weil sich die Ursachen der Performance-Abweichungen nur noch schwer identifizieren lassen, zum anderen, weil die Motivation zum Ergreifen von Maßnahmen fehlt - schließlich dauert es auch lange, bis sich der Erfolg der Maßnahmen beurteilen lässt (vgl. [KüKr01, S. 58]). Doch auch kurze Berichtszyklen können nicht verhindern, dass sich viele Entscheidungsträger gerne umfassend und detailliert informieren wollen, um sich und ihre Entscheidungen abzusichern (siehe Abbildung 3: 2c). Dies kann dazu führen, „dass der beste Zeitpunkt zum Handeln verpasst wird und die ergriffenen Maßnahmen dann nicht mehr optimal greifen und der erzielbare Handlungsnutzen stark zusammengesmolzen ist“ [GlGC97, S. 26].

Eine schlüssige, schnelle und unproblematische Interpretation der Kennzahlen ist auch dann nicht möglich, wenn man zu viele Kennzahlen gleichzeitig im Auge behalten muss. Werden die Leistungsdaten, die man zur Entscheidungsfindung heranzieht, nicht gezielt ausgewählt und empfangergerecht aufbereitet, droht der so genannte „Information Overload“ (vgl. [WeKM01, S. 50]). Und weil nicht nur die Bewältigung dieser Informationsflut, sondern auch das Erheben der Kennzahlen aufwändig ist, reagieren darauf viele Unternehmen mit einer Verlängerung ihrer Berichtszyklen (vgl. [KüKr01, S. 58], [WeSa01, S. 16]; siehe Abbildung 3: 2d). Dadurch wird aber der zeitliche Vorsprung wieder aufgehoben.

ben, durch den sich nicht-finanzielle Messgrößen gegenüber vergangenheitsorientierten Finanzkennzahlen auszeichnen.

Zu warnen ist auch vor einem Automatismus der Art „Schlechte Kennzahl gleich weniger Leistung gleich weniger Geld für den Manager“ [Paul04, S. 112]. Für eine abschließende Leistungsbeurteilung sind auch die so genannten „weichen“ Sachverhalte zu berücksichtigen, die von den „harten“ Kennzahlen nicht erfasst werden (vgl. [Paul04, S. 110]; siehe Abbildung 3: 2e).

Ein weiteres Problem bei der Interpretation der Messgrößen ist der Varianzverlust, der sich mit der Zeit einstellt (siehe Abbildung 3: 2f). Für Meyer liegt diesem Verlust das so genannte „use-it-and-lose-it“-Prinzip zugrunde: „Almost all measures lose variance and hence the capacity to discriminate good from bad performance as they are used. (...) [T]he longer a measure is used and the more intensely it is applied, the less information it yields and the more urgent it becomes to find new measures“ [Meye02, S. 57]. Obwohl den Messergebnissen zufolge eine scheinbar akzeptable Performance erreicht wurde, ist der tatsächlich erreichte Zielzustand unbefriedigend. Die Gründe, weshalb eine Kennzahl an Aussagekraft verliert, können im Einzelfall sehr unterschiedlich sein, etwa weil eine Größe nicht mehr das abbildet, was sie ursprünglich messen sollte, oder weil die Kennzahl den Mitarbeitern einen Anreiz zu dysfunktionalem Verhalten bietet (vgl. [Aust96, S. 15], [Klin99, S. 145-146]). Dysfunktionales Mitarbeiterverhalten sorgt dafür, dass sich eine real schlechte Performance nicht in den Performance-Kennzahlen widerspiegelt und dadurch der tatsächliche Grad der Zielerreichung verschleiert wird (vgl. [Aust96, S. 10], [Klin99, S. 145-146], [Pise04, S. 185]). Negative Performance-Entwicklungen können nicht rechtzeitig erkannt und Gegenmaßnahmen erst verspätet eingeleitet werden. Daher sollte regelmäßig kritisch hinterfragt werden, ob die verwendeten Kennzahlen und Indikatoren dem Unternehmen auch zukünftig von Nutzen sein werden (vgl. [Koch08, S. 3]). Speziell für nicht-finanzielle Kennzahlen gilt, dass Anpassungen eher die Regel als die Ausnahme sein sollten. So ist beispielsweise zu bedenken, dass sowohl neue Ziele und Strategien als auch eine veränderte Aufbau- und Ablaufstruktur eine Anpassung des bis dato verwendeten Berichts- und Informationssystems erfordern können (vgl. [GlGC97, S. 155], [MeWK04, S. 4053]).

2.2.2 Defizite in der konzeptionellen Fundierung

Wie im vorherigen Abschnitt deutlich wird, lassen sich für einige Defizite der praktischen Umsetzung bereits Ansatzpunkte zur Verbesserung finden und konkrete Handlungsempfehlungen aussprechen. Einige der angeführten Defizite beruhen allerdings nicht auf „handwerklichen“ Fehlern, die den Unternehmen bei der Implementierung ihrer Performance-Konzepte unterlaufen, sondern auf Defiziten in der konzeptionellen Fundierung. Jedes Performance-Konzept, ob *Balanced Scorecard*, *Performance Pyramid* oder *Performance Prism*, besitzt seine eigenen Stärken und Vorzüge (vgl. [Baum02, S. 17]), die es von anderen Konzepten unterscheidet. Bei der Auswahl eines Performance-Management-Konzepts sollten deshalb auch die konzeptionellen Schwächen der betrachteten Konzepte bekannt sein. Im Folgenden werden nur die konzeptionellen Defizite vorgestellt, die bislang von keinem der bestehenden Performance-Konzepte zufrieden stellend behoben wurden.

Um den Übergang von der Performance-Messung in die Maßnahmenplanung zu erleichtern, muss bei der Auswahl der Messgrößen darauf geachtet werden, dass diese „mit den jeweiligen Objektzielen und -strategien korrelieren (...) und schnelle Rückschlüsse auf Handlungswirkungen erlauben“ [Horv02, S. 588]. Laut einer Studie von Ittner und Larcker gelingt es den meisten Unternehmen nicht, genau die Bereiche in der Leistungssphäre zu identifizieren, die für die Umsetzung einer Strategie von Bedeutung sind (vgl. [ItLa04, S. 71]). Dies mag zum Teil daran liegen, dass viele Anwender keinen Bezug zwischen ihren Kennzahlen und der verfolgten Strategie herstellen (vgl. [CDF+00, S. 96], [Paul04, S. 109]). Entscheidend ist jedoch, dass zum Beispiel das Performance-Konzept der *Balanced Scorecard* oder der *Performance Pyramid* über kein adäquates Modellsystem zur Verankerung ihrer Messgrößen in der betrieblichen Leistungssphäre verfügen. Diese Ansätze erlauben lediglich eine gewisse Strukturierung der Kennzahlen und Indikatoren (vgl. [Hoff00, S. 50]). Ihr Begriffssystem sieht es zwar vor, dass die Messgrößen und Ziele eines Unternehmens in mehrdimensionale Zielkategorien eingeordnet werden (vgl. [Glei01, S. 68]), eine explizite Auseinandersetzung mit der betrieblichen Leistungssphäre wird allenfalls implizit vorausgesetzt, aber nicht unterstützt (vgl. die Kritik an der *Balanced Scorecard* von Booz Allen & Hamilton bei [Klin99, S. 74]). Hier fehlt es an einem konzeptionellen Bezugsrahmen, der es erlaubt, Ziele und Kennzahlen sys-

tematisch mit ihren jeweiligen Ziel- und Messobjekten der Leistungssphäre zu verknüpfen.

Ein solcher Bezugsrahmen würde die Voraussetzung für eine *vertikale Integration* des Performance-Managements schaffen. Wenn Ziele, Messgrößen und Messobjekte konsistent miteinander verknüpft wären, ließen sich auch die nicht-finanziellen Messwerte leichter interpretieren. Performance-Abweichungen könnte man sowohl in ihrem organisatorischen als auch strategischen Zusammenhang wahrnehmen. Die Unternehmensperformance würde dadurch ausgewogener beurteilt werden und Maßnahmen zur Verbesserung der Performance ließen sich zielgerichtet planen. Denn indem die Messgrößen die Zielerreichung messen, verweisen sie über ihre Messobjekte auch gleichzeitig auf die Leistungsbereiche, die wiederum konkrete Anknüpfungspunkte für die Maßnahmenplanung bieten.

Dies setzt jedoch voraus, dass sich der Zusammenhang zwischen Zielen, Messgrößen und Messobjekten bis auf die unteren Ebenen der operativen Leistungssphäre nachvollziehen lässt. Bei der Einführung einer *Balanced Scorecard* stellt aber gerade die Disaggregation der Messgrößen eine der größten Herausforderungen dar (vgl. [KüWe03, S. 34]). Dies liegt vor allem daran, dass sich nicht-finanzielle Indikatoren meist nicht über mehrere Hierarchieebenen hinweg rechnerisch aufspalten lassen, wie dies mit Finanzkennzahlen prinzipiell möglich ist (vgl. [Pise04, S. 112]). Aus diesem Grund sind in der Regel auf jeder Hierarchieebene eines Unternehmens neue nicht-finanzielle Messgrößen zu identifizieren.

Als Ersatz für diese fehlende Aggregationsmöglichkeit bietet es sich an, die nicht-finanziellen Messgrößen mithilfe von Ursache-Wirkungs-Beziehungen zu verbinden (vgl. [LoCD00, S. 349],[Wies00, S. 123-147], [Oehl06, S. 247]). Sind diese Kausalbeziehungen geknüpft, kann über diese Verbindungsstränge nachvollzogen werden, wie sich die operative Performance aus den Leistungsbereichen heraus auf die finanzielle Performance der monetären Kennzahlen auswirkt. Da die Kennzahlen den Grad der Zielerreichung messen sollen (siehe Abschnitt 2.1.1), lassen sich parallel zu den Kennzahlbeziehungen auch die zugehörigen Ziele verknüpfen. Dies geschieht auf Basis von Zweck-Mittel-Beziehungen. Eine solche Beziehung liegt vor, wenn die Zielerreichung eines untergeordneten Ziels „Mittel zur Erreichung des übergeordneten Ziels (Mittel zum Zweck)“ [Wild82, S. 59] ist.¹

¹ Mit Zweck-Mittel-Beziehungen setzt sich speziell Abschnitt 4.1.2 auseinander.

Die Idee kausal begründeter Ziel- und Kennzahlbeziehungen wird von bestehenden Performance-Management-Ansätzen zwar aufgegriffen und von einzelnen Autoren auch ausdrücklich empfohlen, aber wie die zugrunde liegenden Kausalzusammenhänge in der Praxis zu entwickeln sind, bleibt unklar (vgl. [Schö04, S. 48]). Daher überrascht es nicht, dass mehrere Studien zum gleichen Ergebnis kommen: Es gelingt nur sehr wenigen Unternehmen, ihre Messgrößen kausal so zu verknüpfen, dass sie sich zur Prognose zukünftiger Zielwertabweichungen nutzen lassen (vgl. [KüKr01, S. 60], [WeSa01, S. 21], [BePi04, S. 448], [ItLa04, S. 74]). Neely et al. bezeichnen diese zukünftigen Performance-Management-Konzepte, die einen systematischen Umgang mit Kausalzusammenhängen ermöglichen, als Konzepte der dritten Generation (vgl. [NMR + 03, S. 132]).

Bei der Umsetzung des Performance-Managements besteht die größte Herausforderung in der „Durchgängigkeit der Ansätze von der aggregierten Unternehmensebene über die Abteilungs- und Prozessebene bis hin zur Verknüpfung mit den individuellen Mitarbeiterzielen“ [Brun99, S. 19]. Ein Grund, weshalb sich Kausalmodelle noch nicht in dem Maße durchgesetzt haben, ist sicherlich in der hohen Komplexität zu suchen, die mit der Erfassung und Modellierung von Kausalhypothesen und Kennzahlbeziehungen einhergeht. Denn je tiefer man in die Leistungssphäre vordringt, desto detaillierter und komplexer wird das Ursache-Wirkungs-Geflecht (vgl. [BrFr05, S. 118]). Viele Unternehmen beschränken sich daher meist auf die Darstellung strategisch bedeutsamer Ursache-Wirkungs-Zusammenhänge und nutzen Kausalmodelle allenfalls zur Strategiebeschreibung und -vermittlung (vgl. [Horv04, S. 59], [Schö04, S. 49-50]).¹ Andererseits sollte man sich aber auch von dem Gedanken verabschieden, ein Unternehmen vollständig in einem einzigen Kausalmodell abzubilden. Neely et al. weisen deshalb darauf hin, dass bei der Nutzung kausaler Kennzahlbeziehungen stets abgewogen werden muss zwischen komplexer Realitätsbeschreibung und praktischer Entscheidungsunterstützung (vgl. [NMR + 03, S. 133]).

Um dennoch von kausalen Kennzahlbeziehungen profitieren zu können, bedarf es zum einen komplexitätsreduzierender Modellierungstechniken (vgl. [Wall01, S. 74]), mit denen sich komplexe Ursache-Wirkungs-Zusammenhänge auf unterschiedlichen Modell- und Aggregationsebenen beschreiben lassen.

¹ Anscheinend werden Hinweise der folgenden Art tatsächlich ernst genommen: „Insgesamt ist die Anwendung des Kausalitätsprinzips keine Hexerei und viel einfacher, als oft beschrieben wird. Wichtig ist hierbei, dass es nicht um richtige oder falsche Ursache-Wirkungs-Zusammenhänge geht, sondern um ein einheitliches Verständnis im Unternehmen über den Weg zur Zielerreichung“ [Kump01, S. 165].

Gomez und Probst schlagen beispielsweise eine Art Auflösungskegel vor (vgl. [GoPr99, S. 82]), der auf dem Konzept der Aggregation und Subsystembildung beruht.¹ Zum anderen sind heuristische Verfahrens- und Vorgehensweisen erforderlich, an denen man sich bei der Kausalmodellierung orientieren kann.

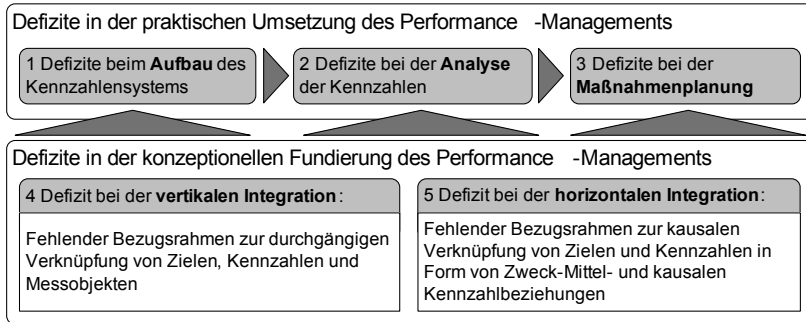


Abbildung 4: Zusammenhang zwischen den Defiziten der praktischen Umsetzung und der konzeptionellen Fundierung von Performance-Konzepten

Ergänzend zur *vertikalen Integration* von Zielen, Kennzahlen und Messobjekten, wird als *horizontale Integration* die Verknüpfung von Zielen und Kennzahlen in Form von Zweck-Mittel- und kausalen Kennzahlbeziehungen bezeichnet. Um die Defizite der operativen Umsetzung zu vermeiden, benötigt das Performance-Management einen konzeptionellen Bezugsrahmen, der eine horizontale und vertikale Integration der Ziele, Kennzahlen und Messobjekte ermöglicht. Diesen Zusammenhang zeigt Abbildung 4.

An diese konzeptionellen Defizite knüpfen die weiteren Kapitel wie folgt an: In Kapitel 3 wird ein Performance-Management-Konzept vorgestellt, das einen konzeptionellen Bezugsrahmen zur vertikalen und horizontalen Integration bietet. Kapitel 4 zeigt, wie das Performance-Management Kausalhypothesen zur horizontalen Integration nutzen kann. In Kapitel 5 und 6 steht schließlich die Frage im Mittelpunkt, wie ein Analyseprozess zu gestalten ist, der dem Performance-Management die benötigten Kausalinformationen bereitstellt.

¹ Die Aggregation und Subsystembildung wird in Abschnitt 3.1.1.1 als grundlegendes Konzept der Systemtheorie vorgestellt.

3 Entwicklung eines ganzheitlichen Performance-Management-Konzepts

Ziel dieses Kapitels ist es, ein ganzheitliches Performance-Management-Konzept zu entwickeln. Ganzheitlich ist dieses Konzept insofern, weil es ein vertikal *und* horizontal integriertes Performance-Management ermöglichen soll. Um die in Abschnitt 2.2.2 vorgestellten Defizite bestehender Performance-Konzepte zu überwinden, bedarf es einer ausreichenden konzeptionellen Fundierung. Hierzu wird in Abschnitt 3.1 zunächst ein systemtheoretischer Bezugsrahmen für das Performance-Management entwickelt. Aus diesem wird anschließend in Abschnitt 3.2 ein generisches Prozessmodell für das Performance-Management abgeleitet. Die darin enthaltenen Prozessschritte bieten dem Analyseprozess die Anknüpfungspunkte zur Entwicklung und Überprüfung von Kausalhypothesen, mit denen sich die Zweck-Mittel- und kausalen Kennzahlbeziehungen begründen lassen. Wo und wie der Performance-Management-Prozess Kausalinformationen zur horizontalen Integration nutzen kann, wird anschließend in Kapitel 4 vorgestellt.

3.1 Systemtheoretischer Bezugsrahmen für das Performance-Management

In diesem Abschnitt wird ein konzeptioneller Bezugsrahmen für das Performance-Management entwickelt, der sich grundlegender Konzepte der Systemtheorie bedient. Nachdem diese in Abschnitt 3.1.1 vorgestellt wurden, lässt sich das Performance-Management in Abschnitt 3.1.2 zunächst als betriebliche Aufgabe beschreiben und in Teilaufgaben zerlegen. Anschließend wird in Abschnitt 3.1.3 ein Architekturmodell für das Performance-Management konstruiert, das den Teilaufgaben als Aufgabenobjekt dient. Dieses Architekturmodell ermöglicht dem Performance-Management die horizontale und vertikale Integration seiner Ziele, Kennzahlen und Messobjekte. Das in Abschnitt 3.1.4 entwickelte Regelkreismodell geht schließlich auf das Lösungsverfahren der Performance-Management-Aufgabe ein. Es verdeutlicht, auf welche Weise die Teilaufgaben sowohl

untereinander als auch mit den Teilmodellsystemen des Architekturmodells interagieren. Abbildung 3 zeigt, wie die Prozessstruktur und der Ablauf des generischen Prozessmodells aus dem systemtheoretischen Bezugsrahmen entwickelt werden.

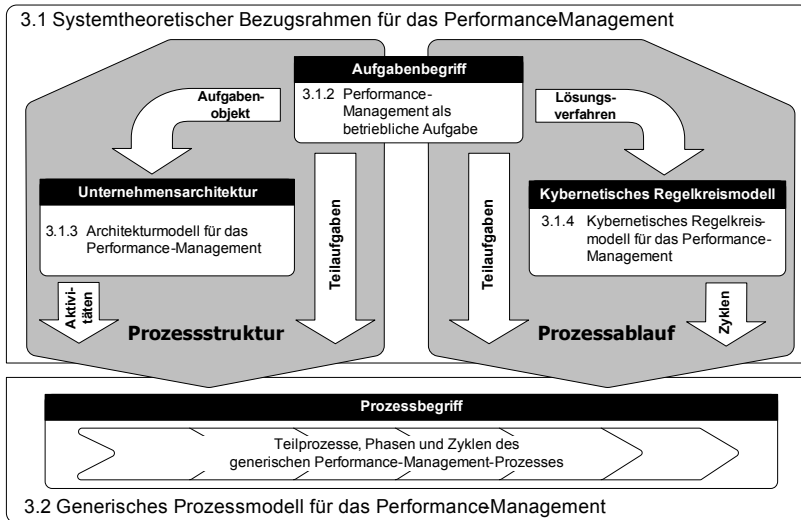


Abbildung 5: Methodisches Vorgehen zur Entwicklung des ganzheitlichen Performance-Management-Konzepts

Auf Basis dieses Bezugsrahmens werden in Abschnitt 3.2 Prozessstruktur und -ablauf des generischen Prozessmodells festgelegt. Die Prozessstruktur ergibt sich zum einen aus den Teilaufgaben des Performance-Managements, die die Teilprozesse definieren, zum anderen aus den Elementen des Architekturmodells, die die einzelnen Prozessaktivitäten festlegen. Der Prozessablauf leitet sich aus dem kybernetischen Regelkreismodell ab, das den zyklischen Ablauf der Teilaufgaben beschreibt.

3.1.1 Systemtheoretische Grundlagen

Um das Performance-Management aus Sicht der Systemtheorie zu beschreiben, werden drei grundlegende Konzepte verwendet:

- die modellbasierte Regelung komplexer Systeme
- der betriebliche Aufgabenbegriff

- die Unternehmensarchitektur

Diese drei Konzepte sind in der Systemtheorie und Kybernetik verhaftet, da sie deren systemische und kybernetische Sicht auf die Welt übernehmen, um ihr jeweils eigenes Begriffssystem zu entwickeln. Wodurch sich diese systemische und kybernetische Weltsicht auszeichnet, verdeutlicht der folgende Abschnitt.

3.1.1.1 Systemtheorie und Kybernetik

Systemtheorie und Kybernetik wurden Anfang der 40er Jahre entwickelt. Ein System kann allgemein als eine Menge von Objekten aufgefasst werden, die über Beziehungen miteinander in Verbindung stehen (vgl. [HaFa56, S. 18], [FeSi08, S. 13]). Die Systemtheorie ist die „Lehre vom Aufbau und der Klassifikation von Systemen“ [Ulri01, S. 244]. Diese Definition ist bewusst abstrakt gehalten, da ihr die Idee zugrunde liegt, dass systemische Prinzipien und Gesetzmäßigkeiten in sämtlichen Wissenschaftsgebieten gelten und dass diese fachübergreifend und losgelöst von der Art der jeweiligen Systemelemente und Beziehungen diskutiert werden können (vgl. [Ulri01, S. 364]). Intention der Systemtheorie ist es, die engen Grenzen der wissenschaftlichen Teilgebiete zu überwinden sowie die in den einzelnen Disziplinen gewonnenen Erkenntnisse mithilfe einer gemeinsamen Sprache zu formulieren, um sie dadurch miteinander vergleichen zu können (vgl. [Niem77, S. 1], [Ulri01, S. 42]).

Ein wesentliches Merkmal der Systemtheorie ist das „Denken in Ganzheiten“ [Ulri01, S. 46] (vgl. [Krie71, S. 15], [Blei95, S. 33]). Dieses Denken basiert auf der trivialen Grundannahme, dass „viele mit vielem verknüpft ist und zahlreiche Abhängigkeiten bestehen“ [Ulri01, S. 45]. Aus diesem Grund werden nicht nur die Verflechtungen im Inneren des Systems, sondern auch dessen Interaktion mit dem in der Systemumwelt eingebetteten Supersystem von Beginn an betrachtet (vgl. [Will93, S. 56], [Ulri01, S. 28]).

Bevor sich der Blick der Untersuchung auf die Systemobjekte und Funktionsmechanismen im Systeminneren richtet, müssen zunächst Diskurs- und Umwelt voneinander abgegrenzt werden. Die Diskurswelt „stellt den zu betrachteten relevanten Ausschnitt der (...) Realität dar, der zweckorientiert abgegrenzt wird. Der nicht zur Diskurswelt gehörige Teil der Realität wird als Umwelt bezeichnet“ [FeSi08, S. 5]. Die Umwelt wird von der Systemtheorie nicht mehr als passive und ausschließlich reaktive Umwelt gesehen, sondern als eine aktive Einflussgröße mit Eigendynamik (vgl. [BaTh04, S. 62]). Aufgrund der oft engen Verflochtenheit von Diskurswelt- und Umweltobjekten können Diskurswelt und

Umwelt faktisch nicht voneinander getrennt werden (vgl. [Klir69, S. 36]). Ihre Trennung lässt sich nur anhand einer gedanklichen Trennlinie und zum Zweck der Komplexitätsbewältigung¹ vollziehen (vgl. [Luhm73, S. 175-176], [BaTh04, S. 56]). Was als Diskurswelt- und was als Umweltobjekt erfasst wird, liegt somit im Ermessen des Betrachters und wird vor allem durch den Aspekt der Zweck- bzw. Zieldienlichkeit bestimmt (vgl. [Krie71, S. 24], [Niem77, S. 55], [BaTh04, S. 56]).

An dieser Stelle wird deutlich, dass sich der Systemansatz durch ein pragmatisches Vorgehen bei der Problemlösung auszeichnet, da er die Komplexität seines Untersuchungsbereichs zwar akzeptiert, diese aber durch die Abgrenzung des Systems von seiner Umwelt reduziert (vgl. [Will93, S. 56], [StSc93, S. 125] [Horv02, S. 101]). Dies impliziert allerdings, dass man sich von der Vorstellung löst, den Untersuchungsbereich in seiner Gesamtheit begreiflich machen zu können (vgl. [Niem77, S. 1], [Ulri01, S. 26-27]). Diese mit der Abgrenzung von Diskurs- und Umwelt verbundenen Schwierigkeiten subsumieren sich unter dem Begriff des *Grenzproblems* (vgl. [Beck90, S. 297]; siehe Abbildung 6).

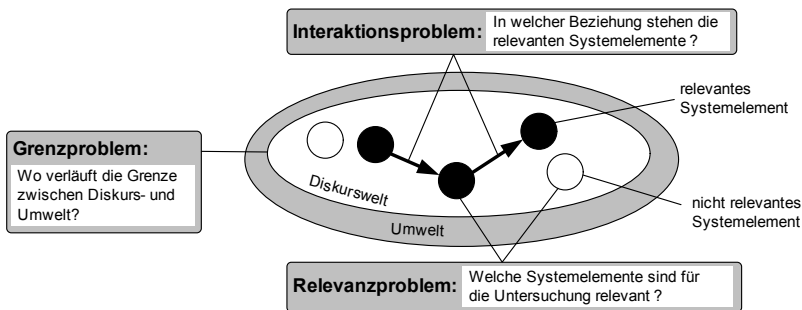


Abbildung 6: Fragestellungen des Grenz-, Interaktions- und Relevanzproblems

Ebenso wenig wie sich Diskurswelt und Umwelt a priori auseinanderdividieren lassen, verwischt aus systemtheoretischer Perspektive auch der Unterschied zwischen Ursache und Wirkung. Aufgrund der Annahme einer komplexen Systemvernetzung steht ein monokausales Denken im Gegensatz zu einer systemischen Weltansicht (vgl. [Blei95, S. 33], [Ulri01, S. 45], [BaTh04, S. 51]). Fehlerhaftes Verhalten wird nicht gezielt auf eine oder einige wenige Ursachen zurückge-

¹ Komplexität bezeichnet die Systemeigenschaft, „in einer gegebenen Zeitspanne eine grosse Anzahl von verschiedenen Zuständen annehmen zu können“ [Blei95, S. 19].

führt. „Der Systemdenker vermutet den Fehler im System, in unzweckmäßigen Verknüpfungen“ [Ulri01, S. 45]. Die Frage, auf welche Weise die einzelnen Systemobjekte miteinander interagieren und in Beziehung stehen, wird als *Interaktionsproblem* bezeichnet (vgl. [Beck90, S. 298]).

Der Lösung des Interaktionsproblems zeitlich vorgelagert ist die Entscheidung, welche Systemobjekte man fokussieren möchte. Da die Anzahl potenziell möglicher Interaktionen exponentiell mit der Summe der betrachteten Systemobjekte zunimmt, sind diese zu minimieren und ausschließlich aufgrund ihrer Relevanz im Hinblick auf den Untersuchungszweck auszuwählen. Diese als *Relevanzproblem* (vgl. [Beck90, S. 297]) bezeichnete Suche nach einem geeigneten Selektions- und Auswahlmechanismus bildet neben dem Grenz- und Interaktionsproblem den dritten Problembereich einer systemischen Untersuchung. Abbildung 6 fasst die drei Problembereiche und ihre jeweiligen Fragestellungen zusammen.

Zur Lösung der drei Problembereiche bietet der Systemansatz die Möglichkeit zur Aggregation und Subsystembildung. Je nach Untersuchungsschwerpunkt kann das System an einer Stelle sehr detailliert, an einer anderen Stelle abstrahierend und verkürzt beschrieben werden. Systeme lassen sich daher auf verschiedenen Abstraktionsebenen betrachten (vgl. [Ulri01, S. 51]). Ulrich vergleicht dies mit der Eigenschaft eines Zoom-Objektivs: „[W]as uns im Moment als zentraler Gegenstand oder Handlungsablauf, als zu erfassende oder zu gestaltende Ganzheit interessiert, erscheint uns als System“ [Ulri01, S. 244]. Auf jeder Betrachtungsebene können völlig neue Eigenschaften, Gesetzmäßigkeiten und Verknüpfungen zu Tage treten (vgl. [BaTh04, S. 55])). Daher muss überall dort auf eine Detailanalyse verzichtet werden, wo eine weitere Bildung von Subsystemen nicht mehr notwendig und wesentlich erscheint (vgl. [Ulri01, S. 51]). Da das vernetzte Systemdenken unserem eigentlich gewohnten, linearen Denken widerspricht, fällt die konsequente Anwendung dieser Denkweise nicht leicht (vgl. [Ulri01, S. 244]). Abbildung 7 skizziert die Aggregation und Subsystembildung exemplarisch für zwei Abstraktionsebenen.




Abbildung 7: Subsystembildung und Aggregation

Eine Teildisziplin der Systemtheorie ist die Kybernetik, die sich mit einer bestimmten Klasse von Systemen und deren Problemen auseinandersetzt, nämlich dem Aufbau und dem Verhalten zielorientierter dynamischer Systeme (vgl. [Krie71, S. 28]). Anfang der 40er Jahre erkannte Norbert Wiener, dass sich viele Probleme auf eine gemeinsame Frage zurückführen lassen, nämlich die Frage nach der Lenkung, d.h. dem „Unter-Kontrolle-Halten von Zuständen“ [Ulri01, S. 255]. Die Kybernetik hat daher ebenso wie die Systemtheorie den Charakter einer Querwissenschaft, da sie versucht, Analogien bezüglich gemeinsamer Lenkungs- und Kontrollprinzipien zwischen verschiedenen Disziplinen zu finden und aufzuzeigen (vgl. [Ulri01, S. 226]).

Da mit der Kybernetik die Dynamik von Systemen in den Fokus rückt, steht als zentrale Frage im Mittelpunkt, wie und weshalb sich im Zeitverlauf ein Systemzustand aus einem anderen Zustand entwickelt (vgl. [Schw02, S. 147]). Bei der Beantwortung dieser Frage stieß Norbert Wiener auf das Konzept der Rückkopplung, das er als das elementare Grundprinzip sämtlicher biologischer und maschineller Lenkungsvorgänge erkannte (vgl. [Ulri01, S. 365-366]). Auf dieses Prinzip wird speziell im folgenden Abschnitt 3.1.1.2 näher eingegangen.

Systemtheorie und Kybernetik eignen sich sowohl für die Analyse und Beschreibung als auch für die Gestaltung und Lenkung¹ komplexer Systeme (vgl. [Krie71, S. 15]). Dies gilt insbesondere für den betrieblichen Anwendungsbereich, wo Unternehmen im Lichte des Systemansatzes als „fein-granular verteilte, offene und vernetzte betriebliche Systeme“ [Sinz04, S. 316] erscheinen. Da sich jedoch mit jeder Aggregation oder Subsystembildung unterschiedliche Aspekte fokussieren lassen, scheint der Systemansatz „am ehesten in der Lage zu

¹ Eine genaue Definition von Gestaltung und Lenkung folgt in Abschnitt 3.1.2.

sein, die Komplexität und Anpassung von Organisationen realitätsnah darzustellen und Gestaltungsmöglichkeiten aufzuzeigen" [Horv02, S. 98].

Der folgende Abschnitt zeigt, wie sich die Komplexität von Systemen durch eine Modellabbildung reduzieren und mithilfe des kybernetischen Prinzips der Rückkopplung beherrschen lässt.

3.1.1.2 Modellbasierte Regelung komplexer Systeme

Ein Modell ist die zielorientierte Systemabbildung eines anderen Systems (vgl. [FeSi08, S. 22]). Durch eine Systemabbildung können die Komponenten und Beziehungen des ursprünglichen Systems auf das für die jeweilige Untersuchung erforderliche Mindestmaß eingeschränkt werden (vgl. [Niem77, S. 57], [FeSi08, S. 31]). Als eine Art problemorientierter Selektionsmechanismus (vgl. [Ulri01, S. 369]) übernimmt das Modellsystem die Rolle eines Wahrnehmungsfilters, „der dem Beobachter hilft, aus dem Strom möglicher Informationen über eine Problemsituation die wesentlichen herauszukristallisieren“ [Gome81, S. 22].

Hierbei muss beachtet werden, dass Modelle nicht die Realität selbst widerspiegeln, sondern stets einer bestimmten Perzeption der Realität unterliegen (vgl. [Pyle03, S. 174]). Dies bedeutet, dass jede Modellkonstruktion auf einer subjektiven Wahl beruht, die der Modellierer im Hinblick auf die gegebene Problemstellung zu treffen hat. Das Modellsystem ist daher stets „das Resultat der Bestimmungsleistung eines Beobachters. Welche Aspekte oder Variablen seines Untersuchungsgegenstandes der Beobachter auswählt, hängt ganz von seiner Perspektive ab“ [Gome81, S. 20].¹ Die Einnahme eines bestimmten Blickwinkels unterstützt den Modellierer bei der Lösung des Relevanz-, Grenz- und Interaktionsproblems, da sich bestimmte Aspekte der Realität gezielter erfassen lassen.

Stimmt man den Blickwinkel, aus dem man ein System betrachtet, auf das Begriffssystem ab, das der Modellierer zur Konstruktion seines Modellsystems nutzt, erhält man einen Modellierungsansatz (vgl. [FeSi08, S. 130]). Ein Modellierungsansatz trägt als eine Art äußerer Gestaltungsrahmen zur Komplexitätsreduktion bei, indem er eine Metapher und ein Metamodell bereitstellt. Die Metapher lenkt den Blick des Modellierers auf diejenigen Aspekte, die von dem gewählten Blickwinkel aus als wesentlich erscheinen. „Ein Metamodell definiert die verfügbaren Arten von Modellbausteinen, die Arten von Beziehungen zwischen Modellbausteinen, die Regeln für die Verknüpfung von Modellbausteinen

¹ Jedem Modellsystem liegt somit eine eigene Weltsicht zugrunde (vgl. [Pyle03, S. 11]), oder wie es Weinberg ausdrückt: „A System is a way of looking at the world“ [Wein75, S. 52].

(...) sowie die Bedeutung (Semantik) der Modellbausteine und Beziehungen“ [FeSi08, S. 131].

Modelle eignen sich nicht nur zur Abbildung komplexer Systeme, sondern auch zu deren Steuerung und Regelung (vgl. [FeSi08, S. 31]). Abbildung 8a stellt das Prinzip einer rückgekoppelten Steuerung und Regelung dar (vgl. [Niem77, S. 159-132], [FeSi08, S. 28]). Der Output des zu steuernden und zu regelnden Systems, das als Regelstrecke bezeichnet wird, liegt in der Regelgröße X vor. Diese Regelgröße wird vom Regler abgegriffen und mit seiner Führungsgröße W verglichen, die ihm als externe Zielgröße den gewünschten Systemoutput der Regelstrecke vorgibt. Weichen Regelgröße X und Führungsgröße W voneinander ab, versucht der Regler mit der Stellgröße Y die Regelstrecke direkt zu beeinflussen, um die Abweichung zu beheben. Die Regelstrecke ist zusätzlich einer Störgröße Z ausgesetzt, „deren Einfluss auf die Regelstrecke mithilfe der Stellgröße Y kompensiert werden soll“ [FeSi08, S. 28].

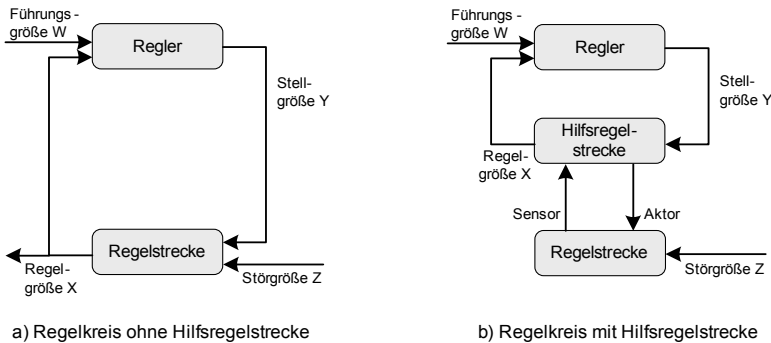


Abbildung 8: Regelkreismodelle (in Anlehnung an [FeSi08, S. 28 und 81])

In Abbildung 8b ist das einfache Regelkreismodell um eine Hilfsregelstrecke erweitert. Statt direkt auf der Regelstrecke zu operieren, wird es dem Regler nun ermöglicht, die Regelstrecke indirekt, d.h. über die Hilfsregelstrecke zu steuern und zu regeln. Die Hilfsregelstrecke ist ein Modell der Regelstrecke, das sich nur auf die steuerungs- und regelungsrelevanten Aspekte der Regelstrecke konzentriert (vgl. [FeSi08, S. 31]). Damit die Hilfsregelstrecke die Struktur und das Verhalten des ursprünglichen Systems (Regelstrecke) stets korrekt wiedergibt, ist ein ständiger Abgleich zwischen der Regelstrecke und ihrem Modell notwendig. Aktoren sorgen dafür, dass Änderungen im Modell auf die Regelstrecke übertra-

gen werden, Sensoren registrieren jede Veränderung der Regelstrecke und sorgen für eine entsprechende Modellanpassung.

Die Steuerung und Regelung von Systemen wird in diesem Kontext als Lenkung bezeichnet (vgl. [Ulri84, S. 65-66]). Das Prinzip der Lenkung findet sich auch in dem Konzept der betrieblichen Aufgabe wieder, das im folgenden Abschnitt vorgestellt wird.

3.1.1.3 Der betriebliche Aufgabenbegriff

Der Aufgabenbegriff erlaubt eine systematische und strukturierte Beschreibung zweckbezogenen Handelns. In der betriebswirtschaftlichen Organisationslehre wurde der betriebliche Aufgabenbegriff von Erich Kosiol eingeführt und zur Gestaltung der betrieblichen Aufbauorganisation verwendet (vgl. [Kosi76, S. 185]). Der Aufgabenbegriff ermöglicht es, gedanklich zwischen der Beschreibung bzw. der Analyse betrieblicher Aufgaben und ihrer Verrichtung durch Aufgabenträger zu trennen (vgl. [Kosi76, S. 63]).

Im Folgenden wird allerdings nicht der Aufgabenbegriff von Kosiol, sondern eine darauf aufbauende Aufgabendefinition von Ferstl und Sinz verwendet. Diese lehnt sich zwar eng an die von Kosiol eingeführte Begriffssystematik an, entwickelt diese allerdings konzeptionell weiter. Indem Ferstl und Sinz zwischen einer Aufgabenbeschreibung aus Außen- und Innensicht differenzieren (vgl. [FeSi08, S. 96-97]), lässt sich zum einen die Komplexität bei der Erfassung und Beschreibung betrieblicher Aufgaben reduzieren, zum anderen entstehen dadurch zusätzliche Freiheitsgrade hinsichtlich der Bestimmung der Aufgabenträger und somit bei der Wahl des Automatisierungsgrads der Aufgabe (vgl. [FeSi08, S. 199-200]).

Die Außensicht charakterisiert eine Aufgabe unabhängig von der Art des Aufgabenträgers durch das von ihr bearbeitete Aufgabenobjekt, die Sach- und Formalziele sowie durch Vor- und Nachereignisse (vgl. [FeSi08, S. 96]). „Sachziele bestimmen Art und Zweck der Leistungserstellung (...). Formalziele bestimmen Art und Umfang der Sachzielerreichung“ [FeSi08, S. 65]. Die Aufgabendurchführung wird durch ein oder mehrere Vorereignisse ausgelöst und erzeugt selbst ein oder mehrere Nachereignisse.

Für die Innensicht einer Aufgabe, wie sie Abbildung 9 darstellt, werden das Lösungsverfahren der Aufgabe beschrieben und die Formalziele in Bezug auf die Art des Aufgabenträgers näher spezifiziert (vgl. [FeSi08, S. 101]). Das Lösungsverfahren unterteilt sich in eine Aktionensteuerung und die Aktionen selbst.

Nachdem die Aktionen durch die Aktionensteuerung ausgelöst wurden, bearbeiten sie das Aufgabenobjekt entweder als Glied einer Steuerkette, wobei auf eine explizite Rückmeldung der Aktionenergebnisse verzichtet wird, oder, wie in Abbildung 9 dargestellt, als Regelstrecke, die die Aktionensteuerung über die Ergebnisse der Aktionendurchführung informiert (vgl. [FeSi08, S. 101]).

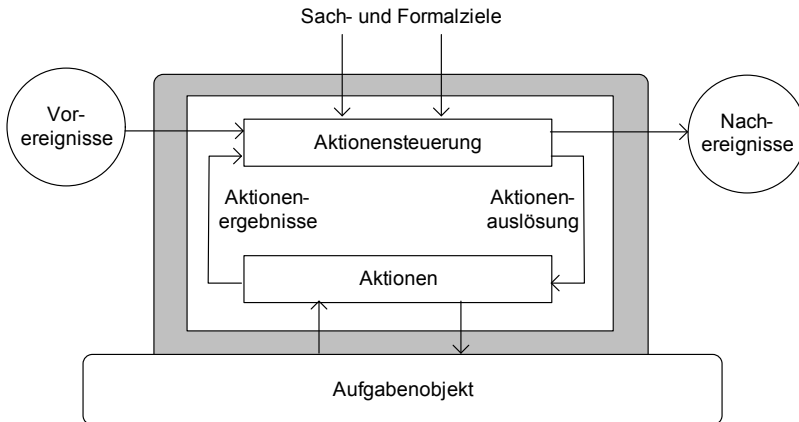


Abbildung 9: Aufgaben-Innensicht (in Anlehnung an [FeSi08, S. 102])

Im Rahmen einer Aufgabenanalyse können die Aufgaben sukzessive in Teilaufgaben zerlegt werden. Dadurch lässt sich das betriebliche Handeln auf der für die jeweilige Untersuchung zweckmäßigen Aggregationsebene beschreiben. Die Aufgaben und Teilaufgaben bilden dann über mehrere Ebenen hinweg einen hierarchisch strukturierten Aufgabenkomplex (vgl. [Kosi76, S. 42]). Eine Aufgabe kann anhand von fünf Gliederungsprinzipien in Teilaufgaben zerlegt werden: nach den Verrichtungen, den Objekten, den Sachmitteln, dem Rang, der Phase und der Zweckbeziehung (vgl. [Kosi76, S. 49]). Da sich eine Aufgabe aber nur anhand ihrer Verrichtungen oder ihrer Aufgabenobjekte beliebig oft hintereinander zerlegen lässt (vgl. [Kosi76, S. 65]), sind für die betriebliche Aufgabenanalyse und Organisationsgestaltung gerade diese beiden Prinzipien von Bedeutung (vgl. [FeSi08, S. 72-73]). Das Verrichtungsprinzip sieht für eine Aufgabe die Zerlegung der Aufgabenziele und des Lösungsverfahrens vor, wohingegen das Objektprinzip Aufgaben nach der Art ihrer Aufgabenobjekte trennt (vgl. [Kosi76, S. 49-53], [FeSi08, S. 72-73]).

Im Rahmen einer Aufgabensynthese können mehrere Teilaufgaben zu einem gemeinsamen betrieblichen Objekt zusammengefasst werden.¹ Ein betriebliches Objekt kapselt eine Menge von Aufgaben, „die zusammengehörige Sach- und Formalziele verfolgen und die auf einem gemeinsamen Aufgabenobjekt durchgeführt werden“ [FeSi08, S. 200]. Je nachdem, ob man die Aufgaben nach dem Verrichtungs- oder dem Objektprinzip zerlegt, können Aufgaben mit gleichartigen Arbeitsabläufen oder Aufgabenobjekten zusammengefasst werden (vgl. [FeSi08, S. 72-73]). Innerhalb eines betrieblichen Objekts liegen die Vor- und Nachereignisse als objektinterne Ereignisse vor und koppeln die objektinternen Aufgaben (vgl. [FeSi08, S. 201]).

Mit diesem elaborierten Aufgabenbegriff lässt sich bereits ein Teilausschnitt der betrieblichen Realität als Aufgabe modellieren (vgl. [FeSi08, S. 103]). Im folgenden Abschnitt wird jedoch mit dem Konzept der Unternehmensarchitektur ein modelltheoretisches Rahmenwerk vorgestellt, innerhalb dessen eine weitaus umfassendere Modellierung des betrieblichen Realsystems möglich ist.

3.1.1.4 Unternehmensarchitektur

Eine Architektur umfasst „den Bauplan eines Objektsystems im Sinne einer Spezifikation seiner Komponenten und ihrer Beziehungen unter allen relevanten Blickwinkeln sowie die Konstruktionsregeln für die Erstellung des Bauplans“ [FeSi08, S. 192]. Da sich jedes formale und reale System auf eine Architektur zurückführen lässt, gilt dies auch für Unternehmen, deren Bauplan anhand einer Unternehmensarchitektur beschrieben werden kann (vgl. [Sinz04, S. 315]). Je nachdem, ob für ein Unternehmen der Ist-Zustand abgebildet oder der Soll-Zustand spezifiziert werden soll, liegen Unternehmensarchitekturen entweder als Beschreibungs- oder Gestaltungsmodelle vor (vgl. [Sinz04, S. 315]).

Die Betrachtung eines Unternehmens aus verschiedenen Blickwinkeln ermöglicht es, die mit der Analyse und Gestaltung von Unternehmensarchitekturen verbundene Komplexität zu reduzieren (vgl. [Sinz02, S. 1056]). Hierbei begründet jeder Blickwinkel eine eigene Modellebene (vgl. [FeSi08, S. 192]). Auf jeder Modellebene wird das Unternehmen im Hinblick auf eine bestimmte Zielsetzung vollständig abgebildet (vgl. [Sinz02, S. 1057]). Erst wenn die verschiedenen Teilmodellsysteme der Modellebenen miteinander in Beziehung

¹ Der Begriff des betrieblichen Objekts leitet sich aus der Objektorientierung ab und nutzt die objektorientierte Metapher zur Bildung objektorientierter Aufgabenstrukturen (vgl. [FeSi08, S. 200]).

gesetzt werden, entsteht das umfassende betriebliche Modellsystem, das im Folgenden unter dem Begriff der Unternehmensarchitektur subsumiert wird.

Neben einer Gliederung in Modellebenen lässt sich die Modellkomplexität einer Unternehmensarchitektur durch die Bildung von Sichten besser bewältigen. Eine Sicht hebt bestimmte Systemelemente einer Modellebene hervor und blendet andere Elemente bewusst aus. Eine Sicht beschreibt ein System daher stets unvollständig (vgl. [Sinz02, S. 1057]). Abbildung 10 illustriert den Zusammenhang zwischen Blickwinkel, Modellebenen und Sichten am Beispiel eines Kegels.

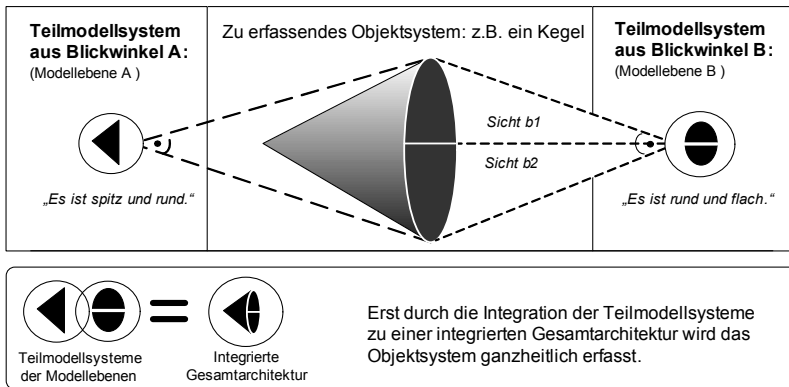


Abbildung 10: Zusammenhang zwischen Blickwinkel, Modellebenen und Sichten

Die Wahl des Blickwinkels bestimmt, welche Eigenschaften des Kegels erfasst bzw. nicht erfasst werden können. So erscheint der Kegel aus dem Blickwinkel des Teilmodellsystems A als spitz und rund, während er sich im Teilmodellsystem B als rund und flach abzeichnet. Erst wenn man das Objektsystem aus verschiedenen Blickwinkeln betrachtet und die Teilmodellsysteme als Modellebenen einer integrierten Gesamtarchitektur auffasst, ist der Kegel als solcher zu erkennen. Durch die Bildung von Sichten, was in dem Beispiel einer Verengung des Blickwinkels entspricht, wird ein bestimmter Ausschnitt des Objektsystems fokussiert (siehe Abbildung 10: Sicht b1 und b2). Allerdings ändert auch eine Fokussierung nichts an der Tatsache, dass sich bestimmte Objekteigenschaften aus dem gewählten Blickwinkel heraus nicht erfassen lassen.

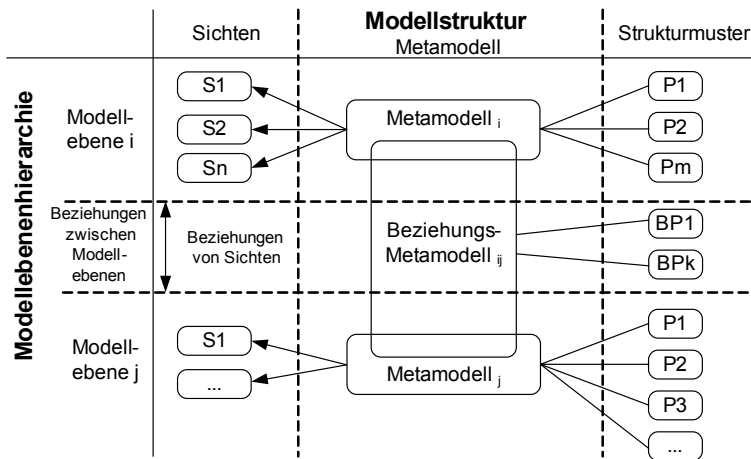


Abbildung 11: Generischer Architekturrahmen [Sinz02, S. 1056]

Wie die Modellebenen, Teilmodellsysteme und Sichten in eine integrierte Gesamtarchitektur überführt werden können, lässt sich anhand des generischen Architekturrahmens zeigen (siehe Abbildung 11). Dieser enthält neben den Regeln zur Konstruktion der Teilmodellsysteme und Sichten (Metamodell) auch Angaben über die Beziehungen zwischen den Modellebenen (Beziehungs-Metamodell). Jede Modellebene verfügt über ein eigenes Metamodell, wobei die Sichten einer Modellebene als Projektionen auf das Metamodell definiert sind (vgl. [Sinz02, S. 1057]). Die Konstruktionsregeln der Metamodelle lassen sich optional durch die Angabe von Strukturmustern („heuristisches Modellierungswissen“) ergänzen (vgl. [Sinz02, S. 1057]).

Ein Beispiel für eine Architektur, die dem Aufbau des generischen Architekturrahmens folgt, ist die Unternehmensarchitektur, wie sie die Modellierungsmethodik des Semantischen Objektmodells (SOM) verwendet (siehe Abbildung 12; vgl. [FeSi08, S. 192-229]).

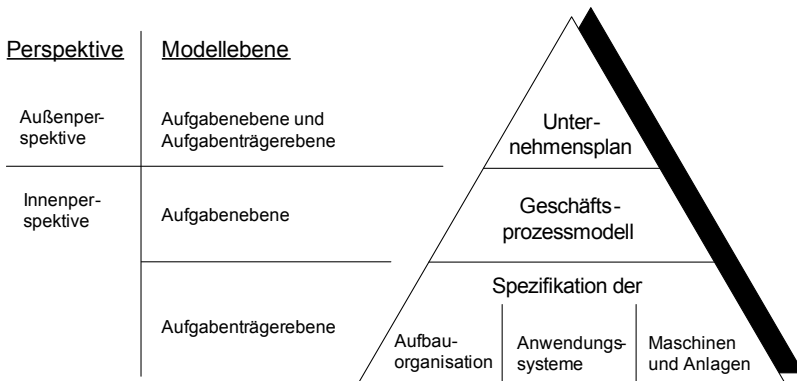


Abbildung 12: Unternehmensarchitektur der SOM-Methodik [FeSi08, S. 193]

Die Unternehmensarchitektur der SOM-Methodik unterscheidet drei Modell-ebenen, die ein Unternehmen aus verschiedenen Blickwinkeln betrachten. Der Blickwinkel einer Modellebene hängt davon ab, ob die Aufgaben und Aufgabenträger eines Unternehmens aus einer Außen- oder Innenperspektive beschrieben werden (vgl. [FeSi08, S. 193]). In Analogie zu dem in Abschnitt 3.1.1.3 skizzierten Aufgabenbegriff beschreibt der Unternehmensplan das Unternehmen aus einer Außenperspektive. Er beschreibt die globale Unternehmensaufgabe, indem sowohl das nach Sach- und Formalzielen aufgegliederte Zielsystem als auch die Unternehmensstrategien beschrieben werden. Hierbei nimmt der Unternehmensplan auch Bezug zu den benötigten Ressourcen der Aufgabenträgerebene (vgl. [FeSi08, S. 193]). Auf der zweiten Modellebene betrachtet man die Aufgaben eines Unternehmens aus der Innenperspektive, indem „die Geschäftsprozesse als Lösungsverfahren zur Umsetzung des Unternehmensplans“ [Sinz04, S. 316] spezifiziert werden. Die Modellebene drei spezifiziert schließlich die „maschinellen und personellen Ressourcen zur Durchführung der Geschäftsprozesse“ [Sinz04, S. 316].¹ Die dritte Modellebene unterscheidet hierbei die Sichten der Aufbauorganisation, der Anwendungssysteme sowie der Maschinen und Anlagen.

Zusammenfassend lässt sich festhalten, dass eine Unternehmensarchitektur neben der Bildung von Sichten auch die Konstruktion von eigenständigen Teilmodellssystemen ermöglichen sollte. Deren Blickwinkel müssen überschneidungsfrei aufeinander abgestimmt sein, damit sich die Teilmodellssysteme als eigen-

¹ Zu den Grundlagen des Prozessbegriffs siehe Abschnitt 3.2.1.

ständige Modellebenen zu einer kohärenten Gesamtarchitektur ergänzen, die die Komplexität bei der Analyse und Gestaltung einer Unternehmensarchitektur auf ein Mindestmaß reduziert.

3.1.2 Performance-Management als betriebliche Aufgabe

Im Folgenden wird das in Abschnitt 2.1.2 vorgestellte Konzept des Performance-Managements als betriebliche Aufgabe beschrieben. Für diese Beschreibung wird die Begriffssystematik des in Abschnitt 3.1.1.3 vorgestellten Aufgabenbegriffs verwendet. Die Aufgabe des Performance-Managements wird zunächst aus der Außensicht beschrieben, d.h. anhand ihrer *Sach- und Formalziele*, der *Vor- und Nachereignisse* sowie anhand ihres *Aufgabenobjekts*. Anschließend erfolgt eine Beschreibung aus der Innensicht. Hierzu wird die Aufgabe in Teilaufgaben zerlegt, wodurch das *Lösungsverfahren* der Aufgabe bereits vorstrukturiert wird.

In der Literatur sind die Auffassungen über die Ziele des Performance-Managements ähnlich zahlreich und vielfältig, wie es die Definitionen des Performance-Begriffs selbst sind (siehe Abschnitt 2.1.1). Für eine systemische Aufgabenbeschreibung des Performance-Managements eignen sich diese Zieldefinitionen allerdings nur bedingt, da sie meist nur aus einer Aufzählung von Einzeltätigkeiten bestehen.¹ Was einer solchen Aufzählung aber fehlt, ist der klare sachlogische Zusammenhang zwischen den Tätigkeiten (vgl. [Ulri01, S. 66]), wie er für die Beschreibung der Aufgabe aus Innensicht und die Formulierung der aufeinander bezogenen Teilaufgaben benötigt wird. Um einen solchen inneren Zusammenhang sicherzustellen, wird das Sachziel der Performance-Management-Aufgabe nachstehend auf Basis des systemtheoretischen Managementbegriffs des St. Galler Management-Modells definiert.

Management umfasst demnach die Funktionen der Gestaltung, Lenkung und Entwicklung (vgl. [Blei95, S. 40], [Ulri01, S. 74]). *Gestalten* bedeutet, „eine Institution überhaupt zu schaffen und als handlungsfähige Ganzheit aufrechtzuerhalten“ [Ulri01, S. 66]. Hierbei schränkt das Management die zulässigen Aktivitätsfelder einer Organisation ein und gibt dieser einen institutionellen und organisatorischen Handlungsrahmen vor (vgl. [Blei95, S. 97]). Innerhalb dieses Handlungsrahmens ist die Organisation in der Lage, ihre eigenen Ziele zu bestimmen, zielgerichtete Aktionen eigenständig auszuwählen, durchzuführen und deren Umsetzung zu kontrollieren. Diesen Vorgang bezeichnet man als *Lenkung* (vgl.

¹ Zum Beispiel Riedl, der die Zielsetzung des Performance-Managements als „Bewertung, Sicherung und Verbesserung der Performance“ [Ried00, S. 26] umschreibt.

[Blei95, S. 40], [Ulri01, S. 68]). Lenken bedeutet, eine Organisation zielgerichtet zu beeinflussen und zu verwalten (vgl. [FeSi08, S. 34]), damit sie sich innerhalb des von der Gestaltung festgelegten Handlungsspielraums stetig weiterentwickelt. Die Aufgabe der Gestaltung ist es, die notwendigen Voraussetzungen für diese *Entwicklung* zu schaffen und dafür zu sorgen, dass die Organisation als System lenkfähig und in Bezug auf ihre Systemumwelt überlebensfähig bleibt (vgl. [Blei95, S. 40], [Ulri01, S. 68]). Zu diesem Zweck muss das System stets aufs Neue umgestaltet bzw. partiell neu geschaffen werden (vgl. [Ulri01, S. 66]). Die Funktionen der Gestaltung und Lenkung sind daher in einem dynamischen, evolutionären und somit nie endenden Entwicklungsprozess eingebettet (vgl. [Ulri01, S. 73]). Diesen Zusammenhang veranschaulicht Abbildung 13.

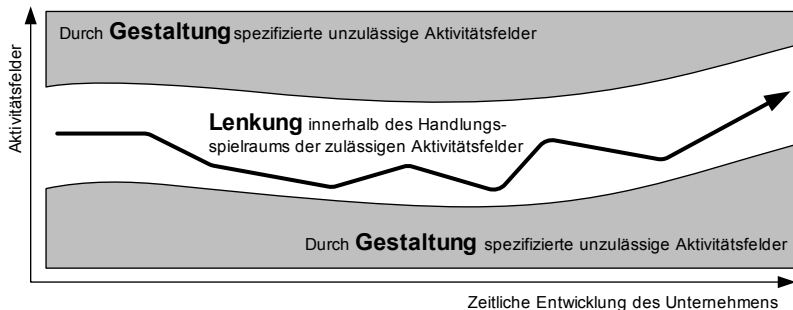


Abbildung 13: Gestaltung und Lenkung (in Anlehnung an [Blei95, S. 96])

Ausgehend von dieser Managementdefinition kann das Sachziel des Performance-Managements als Gestaltung und Lenkung der betrieblichen Performance aufgefasst werden. Hinsichtlich des in Abschnitt 2.1.1 eingeführten Begriffs der betrieblichen Performance - als bewerteter Beitrag zur Zielerreichung - verfolgt das Performance-Management das Ziel, diesen Beitrag einerseits aufrechtzuerhalten und zu optimieren (Lenkung), andererseits aber die Rahmenbedingungen und Voraussetzungen für seine Entstehung zu schaffen (Gestaltung).¹

Da die Unternehmensperformance letztlich aus dem Engagement der unterschiedlichen Stakeholder resultiert (vgl. [AtWW97, S. 26], [WeKM01, S. 51],

¹ Indem neben der Lenkung auch die *Gestaltung* der Performance dem Performance-Management zugeordnet wird, deckt sich die in dieser Arbeit vertretene Performance-Management-Auffassung mit der von Rummel und Brache (vgl. [RuBr95, S. 18]) oder Melcher et al. (vgl. [MeWK04, S. 4053]). Im Gegensatz dazu sehen andere Autoren, beispielsweise Riedl, im Performance-Management nur einen „steuerungsgrößenbasierten Führungsprozess“ [Ried00, S. 26], den man explizit von der Aufgabe der Unternehmensgestaltung abgrenzen müsse.

[KüWe03, S. 45]), müssen deren Ansprüche bei der Formulierung der Unternehmensziele berücksichtigt werden (vgl. [Horv02, S. 587], [Pise04, S. 109]). Unter dem systemtheoretischen Gesichtspunkt bedeutet dies, dass der Blick nicht nur auf die betriebliche Diskurswelt, sondern ebenso auf die relevanten Umweltobjekte, wie zum Beispiel auf die Interessen externer Kapitalgeber oder der Gesellschaft, gerichtet werden muss (siehe Abschnitt 3.1.1.1). Daher kann man das *Sachziel* des Performance-Managements als Gestaltung und Lenkung desjenigen Beitrags zur Zielerreichung auffassen, den eine Unternehmung vor dem Hintergrund divergierender Stakeholderinteressen erbringt (vgl. [KüWe03, S. 45]).

Obwohl es praktisch nicht möglich ist, dass ein Unternehmen allen Stakeholderinteressen gleichermaßen gerecht wird (vgl. [Bert73, S. 77], [Müll98, S. 40]), ist es dennoch ratsam, keine Anspruchsgruppe auf Dauer zu ignorieren und bei der Formulierung der Unternehmensziele zu vernachlässigen (vgl. [Müll98, S. 41]). Andernfalls würden diese Stakeholder keinen Beitrag mehr zur Erreichung dieser Ziele leisten, was die Unternehmensperformance schmälern würde (vgl. [Müll98, S. 38]).

Eine optimale Unternehmensperformance setzt voraus, dass der „erbrachte Beitrag zur Erreichung der jeweiligen Organisationsziele (...) sowohl effektiv als auch effizient ist“ [Erdm03, S. 96]. Folglich muss auch die Aufgabe des Performance-Managements ihr eigenes Sachziel effizient, d.h. „mit geringstem Mittelleinsatz“ [Glad02, S. 6], erfüllen. Diese Forderung entspricht dem *Formalziel* der Performance-Management-Aufgabe.

Neben dem Sach- und Formalziel gilt es bei der Aufgabenbeschreibung aus der Außensicht, auch die Frage nach dem *Aufgabenobjekt* zu klären. Da das Performance-Management den Anspruch erhebt, ein „unternehmensweites Managementsystem“ [Brun99, S. 1] zu sein (vgl. [Arms94, S. 5]), mit dem sich sowohl das Unternehmen als Ganzes als auch seine unterschiedlichen Subsysteme im Blick behalten lassen (vgl. [Ried00, S. 25], [Glei01, S. 22]), kann die Sicht auf das Unternehmen je nach Fokus variieren. Der Blick kann sich entweder auf einzelne Prozesse, Abteilungen, Geschäftseinheiten oder das Gesamtunternehmen richten (vgl. [Klin99, S. 21], [Hach02, S. 1385], [KüWe03, S. 50]). Dennoch stellt letztlich das Gesamtunternehmen das Aufgabenobjekt dar, dessen Performance als Ganzes zu gestalten und zu lenken ist. Denn statt nur lokale Performance-Optima zu erzielen, was ein wesentlicher Kritikpunkt an traditionellen Kennzahlensystemen war (vgl. [FrCo89, S. 52], [BMW+00, S. 2]), strebt das Performance-Management die Erreichung eines globalen Performance-Optimums an.

Sach- und Formalziel: Den vom Gesamtunternehmen und seiner Subsysteme geleisteten Beitrag zur Zielerreichung (Performance) unter Berücksichtigung divergierender Stakeholderansprüche mit geringstem Mitteleinsatz zu *gestalten* und zu *lenken*

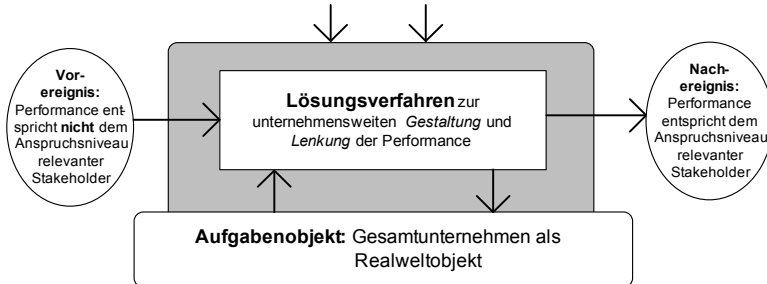


Abbildung 14: Performance-Management als betriebliche Aufgabe aus der Außensicht

Um die Aufgabenbeschreibung aus der Außensicht abzuschließen, ist das *Voreignis* anzugeben, durch welches die Aufgabe des Performance-Managements ausgelöst wird, bzw. das *Nachereignis* zu spezifizieren, das aus einer erfolgreichen Durchführung der Performance-Management-Aufgabe resultiert (siehe Abbildung 14). Mit Blick auf das oben definierte Sachziel wird die Aufgabe des Performance-Managements immer dann ausgelöst, wenn der Beitrag, den ein Unternehmen zur Zielerreichung leistet, nicht dem Anspruchsniveau derjenigen Stakeholder entspricht, deren Beitrag für den Fortbestand und die Wettbewerbsfähigkeit des Unternehmens wesentlich ist. Die Aufgabe hat ihr Sachziel erfüllt, wenn sich der vom Unternehmen geleistete Beitrag zur Zielerreichung mit dem Anspruchsniveau der relevanten Stakeholder deckt. Das Performance-Management gewinnt daher speziell in einem dynamischen Markt- und Wettbewerbsumfeld an Bedeutung, da sich gerade dort die Ansprüche der Kapitalgeber, Geschäftspartner oder der Gesellschaft als Ganzes rasch ändern können.

Mit der Betrachtung der Außensicht ist die Frage geklärt, *was* die Aufgabe des Performance-Managements *wann* erzielen soll. Eine Aufgabenbeschreibung aus Innensicht beantwortet hingegen die Frage, *wie* diese Aufgabe durchzuführen ist bzw. *wie* man das Aufgabenziel erreicht (vgl. [FeSi08, S. 97]). Zu diesem Zweck ist ein geeignetes *Lösungsverfahren* zu entwickeln und anzugeben (vgl. [FeSi08, S. 97]).

Die bei der Formulierung des Sachziels vorgenommene Differenzierung des Managementbegriffs in Gestaltung und Lenkung weist bereits auf eine Aufgabenzerlegung nach dem Verrichtungsprinzip hin (vgl. Abschnitt 3.1.1.3). Die Auf-

gabe des Performance-Managements spaltet sich folglich in je eine Aufgabe für die Gestaltung und die Lenkung der betrieblichen Performance auf. Da beide Teilaufgaben dasselbe Aufgabenobjekt bearbeiten, nämlich das Gesamtunternehmen als Realweltobjekt, lassen sie sich zu dem in Abbildung 15 skizzierten betrieblichen Objekt zusammenfassen.

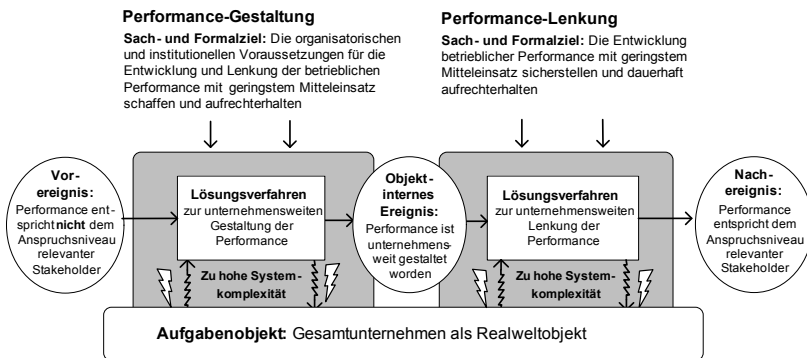


Abbildung 15: Performance-Management als betriebliches Objekt

Die Teilaufgabe der Performance-Gestaltung schafft die organisatorischen und strukturellen Voraussetzungen für eine nachhaltige Unternehmensperformance. Liegen diese Voraussetzungen als objektinternes Ereignis vor, stößt dies die Teilaufgabe der Performance-Lenkung an, die das angestrebte Performanceniveau mit den Interessen der relevanten Stakeholder abgleicht und versucht, dieses Niveau durch gezielte Steuerungs- und Kontrollaktionen dauerhaft zu erreichen bzw. aufrechtzuerhalten. Jede Abweichung zwischen dem Anspruchsniveau und der ermittelten Unternehmensperformance führt als Vorereignis zu neuen, gestaltenden Steuerungseingriffen in das betriebliche Realsystem und zu einer Umgestaltung des organisatorischen und strukturellen Handlungsrahmens. Als Nachereignis ist ein Performanceniveau erreicht, das mit dem Anspruchsniveau der Stakeholder übereinstimmt.

Die Gestaltung und Lenkung eines Gesamtunternehmens ist allerdings eine hoch komplexe Aufgabe. Die Komplexität der beiden Teilaufgaben resultiert maßgeblich aus der Komplexität ihres gemeinsamen Aufgabenobjekts - dem Unternehmen als Realweltobjekt. Auf diesen Zusammenhang weisen in Abbildung 15 die wellenförmigen Pfeile hin. Um die Komplexität der Performance-Management-Aufgabe zu verringern, muss zunächst die Komplexität des Auf-

gabenobjekts - des Unternehmens - beherrscht werden. Wie sich komplexe Systeme anhand eines Modellsystems abbilden und regeln lassen, wurde bereits in Abschnitt 3.1.1.2 skizziert. Im folgenden Abschnitt soll daher - anknüpfend an das in Abschnitt 3.1.1.4 eingeführte Konzept der Unternehmensarchitektur - ein Architekturmodell konzipiert werden, mit dem sich die Komplexität der Unternehmung speziell für die Aufgabe des Performance-Managements reduzieren lässt.

3.1.3 Architekturmodell für das Performance-Management

„Discovering the right model is without a doubt an art.“ [Pyle03, S. 163]

Wie bereits in Abschnitt 2.2.1 erläutert, gelingt es vielen Unternehmen nicht, den Zusammenhang zwischen ihren Zielen, den Messgrößen und den zugrunde liegenden Messobjekten durchgängig herzustellen, d.h. zu entscheiden, „welche Zielsetzungen angestrebt, welche Ressourcen dafür zugeteilt und wie konkret die Zielerreichung gemessen werden soll“ [Hoff00, S. 62]. Es werden zwar Ziele aus den Unternehmensstrategien abgeleitet und mit Messgrößen assoziiert, doch dies allein reicht nicht aus. Um sicherzustellen, dass die Messgrößen „mit den jeweiligen Objektzielen und -strategien korrelieren“ [Horv02, S. 588], muss geklärt werden, was man messen möchte und auf welche Objekte im Unternehmen sich die Messgrößen beziehen sollen. Hierfür ist ein tief reichendes Verständnis über das zugrunde liegende Wertschöpfungsgefüge nötig (vgl. [Simo99, S. 39]). Gerade beim Aufbau eines solchen Verständnisses ist die Reduktion und Beherrschung der in Abschnitt 3.1.2 beschriebenen Systemkomplexität eine wichtige Voraussetzung.

Aus diesem Grund wird auf Basis der in Abschnitt 3.1.1.4 vorgestellten Unternehmensarchitektur ein eigenes Architekturmodell für das Performance-Management entwickelt. Dieses Architekturmodell soll nicht nur eine durchgängige und konsistente Verknüpfung von Unternehmenszielen, Messgrößen und Messobjekten ermöglichen, sondern auch dazu beitragen, die Komplexität der Performance-Management-Aufgabe zu reduzieren. Bei der Konzeption des Architekturmodells wird deshalb auf drei Mechanismen zur Komplexitätsreduktion zurückgegriffen:

- Metapher und Begriffssystem (siehe Abschnitt 3.1.1.2)
- Differenzierung in Modellebenen und Sichten (siehe Abschnitt 3.1.1.4)

- Aggregation und Subsystembildung (siehe Abschnitt 3.1.1.1)

Aus modelltheoretischer Sicht trägt bereits die Modellabbildung selbst zur Komplexitätsreduktion bei, indem das Modellsystem als eine Art WahrnehmungsfILTER nur die Informationen bereithält, die für die Durchführung der beiden Teilaufgaben der Performance-Gestaltung und -Lenkung wesentlich sind. Die Entscheidung, welche Aspekte der betrieblichen Realität wesentlich sind, erfordert aus systemtheoretischer Sicht die „Klärung grundlegender Systemdimensionen, also die Lösung des Relevanz- und Grenzproblems“ [Beck90, S. 297] (siehe Abschnitt 3.1.1.1). Doch auch das Interaktionsproblem muss im Rahmen einer solchen Modellabbildung gelöst werden, da sonst die grundlegenden Funktionsmechanismen des Systems nicht verstanden werden können (vgl. [Beck90], S. 297).

Bei der Bewältigung des Relevanz-, Grenz- und Interaktionsproblems hilft die Verwendung eines Modellierungsansatzes (siehe Abschnitt 3.1.1.2). Ohne Modellierungsansatz fehlt es an der erforderlichen Abstimmung zwischen dem in Form eines Meta-Modells spezifizierten Begriffssystem mit dem durch die Wahl der Metapher festgelegten Blickwinkel. Es ist dann sehr viel schwieriger, die relevanten Systemelemente und Funktionsmechanismen zu erkennen und konsistent zueinander im Modell abzubilden. Für das Performance-Management bedeutet das, dass man den Blickwinkel, aus dem man das Unternehmen betrachtet, von dem zu betrachtenden Gegenstand trennen muss, da andernfalls die Messgrößen nicht eindeutig und überschneidungsfrei in den Leistungsstrukturen des Unternehmens verankert werden können.

Deutlich wird dies am Beispiel der Perspektiven, aus der die *Balanced Scorecard* ein Unternehmen betrachtet. Typische Perspektiven sind die Finanz-, Geschäftsprozess-, Kunden- sowie die Lern- und Entwicklungsperspektive (vgl. [KaNo96b, S. 9]), bei denen nicht konsequent zwischen Betrachtungsgegenstand und Blickwinkel unterschieden wird (vgl. [KüWe03, S. 26]). Denn einerseits begründet ein Geschäftsprozess einen eigenen Blickwinkel zur Erfassung von Prozessen als Messobjekt, andererseits kann ein Geschäftsprozess auch Messobjekt einer anderen Betrachtungsperspektive sein. So lassen sich in einer Scorecard zum Beispiel Prozesskennzahlen zur Evaluierung von Kundenbindungsprozessen sowohl der Prozess- als auch der Kundenperspektive zuordnen.

Um die Komplexität des Modellsystems weiter zu reduzieren, kann neben einem Begriffssystem und der Wahl eines Blickwinkels auf weitere Hilfsmittel zur Komplexitätsreduktion zurückgegriffen werden: die Differenzierung in Modellebenen und Sichten sowie die Aggregation und Subsystembildung. Doch

gerade hier offenbaren sich Defizite in den bestehenden Ansätzen zum Performance-Measurement und Management (vgl. [Klin00, S. 115]).

Obwohl viele Autoren betonen, dass sich der Anwendungsfokus des Performance-Measurements bzw. Management über sämtliche Leistungs- und Organisationsebenen eines Unternehmens erstrecken soll (vgl. [Glei01, S. 12], [WeKM01, S. 49], [KüWe03, S. 8]), ist gerade die Frage nach der „ebenspezifischen Entwicklung von Leistungsindikatoren“ [Klin00, S. 119] noch nicht zufriedenstellend beantwortet worden. In der Literatur fehlt es an konkreten Lösungsvorschlägen, wie die Messgrößen abgeleitet (vgl. [Glei01, S. 23], [SaBH02, S. 1254]) und anschließend für nachfolgende Leistungsebenen spezifiziert werden können (vgl. [Hoff00, S. 60], [KüWe03, S. 34]). Da zudem viele Autoren die Begriffe Leistungs- und Organisationsebene sehr unterschiedlich gebrauchen, bleibt es unklar, „auf welchen unterschiedlichen Ebenen die Performance gesteuert werden sollte“ [Ried00, S. 54]. Dies soll am Beispiel eines oft zitierten Vorschlags zur Ebenengliederung im Performance-Management gezeigt werden: dem Ebenenmodell von Rummler und Brache (vgl. [RuBr95, S. 16-17], [Hron96, S. 15], [Span94, S. 26-27], [Glei01, S. 70], [Erdm03, S. 98]).

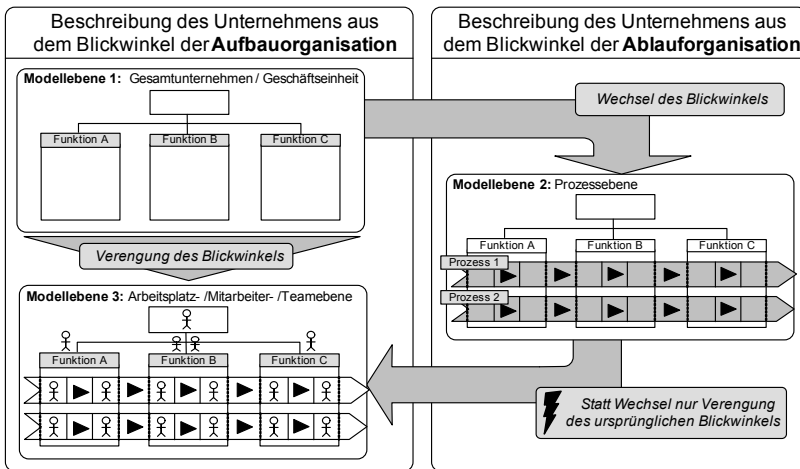


Abbildung 16: Konzeptionelles Defizit des Architekturmodells von Rummler und Brache (in Anlehnung an [Klin00, S. 179])

Die erste Modellebene beschreibt das Gesamtunternehmen und seine Geschäftseinheiten. Die zweite Modellebene betrachtet die Geschäftsprozesse des

Unternehmens. Die dritte und letzte Ebene fokussiert die Mitarbeiter bzw. die einzelnen Teams. Auf jeder dieser drei Leistungsebenen soll sich die Performance eines Unternehmens erheben und beschreiben lassen (siehe Abbildung 16).

Diese von Rummler und Brache vorgeschlagene Ebenengliederung ist problematisch, weil sie mit den Berichts- und Hierarchieebenen eines Unternehmens nicht in Einklang gebracht werden kann (vgl. [Klin00, S. 115]), was die Disaggregation von Messgrößen erschwert. So wird der Blickwinkel der ersten und dritten Betrachtungsebene durch die hierarchische Aufbaustruktur des Unternehmens bestimmt. Während man das Unternehmen auf der ersten Ebene aggregiert betrachtet, disaggregiert man dieses, indem man auf der dritten Ebene Mitarbeiter und Teams fokussiert. Der Unterschied zwischen der ersten und dritten Ebene resultiert daher nur aus einer Verengung bzw. Verbreiterung des Blickwinkels - nicht aber aus einem Wechsel des Blickwinkels. Dies spricht aus Sicht des generischen Architekturrahmens gegen die Einführung einer separaten Modellebene (siehe Abschnitt 3.1.1.4). Ein Wechsel des Blickwinkels vollzieht sich nur auf der zweiten Ebene, von wo aus der Blick nicht mehr auf die hierarchische Aufbauorganisation, sondern auf die dynamischen Betriebsabläufe der Prozessebene fällt.

Darüber hinaus ist in dem Ebenenmodell von Rummler und Brache keine Prozesshierarchie vorgesehen, deren Haupt- und Teilprozesse sich parallel zur Aufbaustruktur des Unternehmens entwickeln und mit dieser in Beziehung stehen. Aus diesem Grund fehlt es dem Modell von Rummler und Brache nicht nur an einer überschneidungsfreien Zuordnung der gewählten Blickwinkel zu den Modellebenen, sondern auch an einem Ebenen übergreifenden Mechanismus zur Aggregation und Subsystembildung. Aus diesem Grund ist die Ebenengliederung von Rummler und Brache nur ansatzweise geeignet, die Komplexität der Performance-Management-Aufgabe, insbesondere die der Teilaufgabe der Performance-Gestaltung, zu reduzieren. Die organisatorischen und prozessualen Rahmenbedingungen für eine solide und dauerhafte Unternehmensperformance lassen sich damit nur unzureichend erfassen, abbilden und gestalten.

Eine überschneidungsfreie Zuordnung von Blickwinkeln und Modellebenen findet sich hingegen bei der Unternehmensarchitektur der SOM-Methodik (siehe Abschnitt 3.1.1.4). Die Abgrenzung zwischen Unternehmensplan- und Geschäftsprozessebene resultiert aus einer Trennung in Außen- und Innensicht. Die Abgrenzung zwischen Geschäftsprozess- und Ressourcenebene basiert auf der Trennung zwischen Aufgaben und Aufgabenträgern. Diese Differenzierung bietet

der Aufgabe der Performance-Gestaltung die notwendigen Freiheitsgrade, um die betrieblichen Geschäftsprozesse ressourcenunabhängig analysieren und konzipieren zu können (vgl. [Sinz04, S. 316]). Mit den Teilprozessen, Vorgängen und Einzelaktivitäten der Geschäftsprozessebene sowie den Anwendungssystemen, Organisationseinheiten, Maschinen und Anlagen der Ressourcenspezifikation sind die notwendigen Bezugsobjekte vorhanden, anhand derer man die Gesamtunternehmung und ihr Wertschöpfungsgefüge im Modell abbilden und gestalten kann.

Die betriebliche Performance lässt sich anhand der Unternehmensarchitektur aber noch nicht im gleichen Maße effizient lenken, d.h. steuern und kontrollieren. Es fehlt ein Modellsystem, das die Messgrößen in einer für die Aufgabe der Performance-Lenkung geeigneten Form repräsentiert. Dieses zusätzliche Modellsystem wird im Folgenden als Performance-Measure-System (PMS) bezeichnet und bildet zusammen mit den drei Ebenen der Unternehmensarchitektur das Performance-Management-Architekturmodell (PMA), das in Abbildung 17 dargestellt ist. Die dreidimensionale Darstellung ermöglicht es, die vier Modellebenen (Y-Achse) nicht nur nach Sichten (X-Achse), sondern auch in Übereinstimmung mit den Hierarchieebenen eines Unternehmens in Aggregationsstufen und Subsysteme zu gliedern (Z-Achse). Die vier Modellebenen werden im Folgenden einzeln beschrieben.

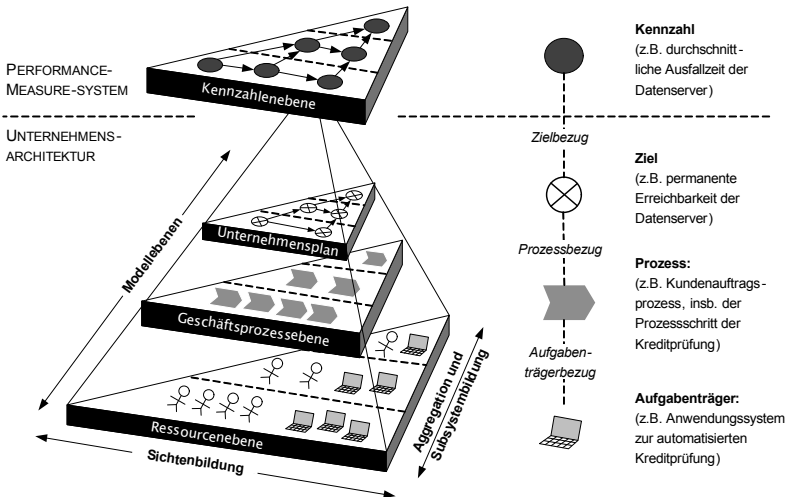


Abbildung 17: Performance-Management-Architekturmodell

Die Ziele der Unternehmensplanebene können über Zweck-Mittel-Beziehungen oder definitionslogisch verbunden werden.¹ Eine Zweck-Mittel-Beziehung liegt vor, wenn die Zielerreichung eines untergeordneten Ziels „Mittel zur Erreichung des übergeordneten Ziels (Mittel zum Zweck)“ [Wild82, S. 59] ist. Gewinn- und Umsatzziele lassen sich hingegen definitionslogisch mit dem Ziel der Umsatzrentabilität verknüpfen, da sich diese aus dem rechnerischen Quotienten beider Größen ergibt. Die Ziele der Unternehmensplanebene können in Übereinstimmung mit den Hierarchiestufen der Gesamtunternehmung in das Zielsystem eingeflochten werden, zum Beispiel als strategische Gesamtziele, Bereichsziele oder Abteilungsziele (vgl. [Wild82, S. 61]).

Entsprechend können auch die Geschäftsprozesse auf den Aggregationsstufen ihrer Kern- und Teilprozesse hierarchisch aufgespalten und bis auf die Stufe einzelner Vorgänge und Aktivitäten zerlegt werden. Analog lassen sich auch die personellen und maschinellen Aufgabenträger der Ressourcenebene auf unterschiedlichen Hierarchiestufen zu organisatorischen Aufgabenträgerkomplexen gruppieren (vgl. [FeSi08, S. 59]). So kann sich zum Beispiel eine Montagelinie aus einzelnen Montagemodulen zusammensetzen.

Das PMS enthält als Modellbausteine die für die Steuerung und Kontrolle der Unternehmensperformance notwendigen Indikatoren und Kennzahlen (Performance-Measures). Diese werden aus dem hierarchischen Zielsystem des Unternehmensplans abgeleitet, wobei für jedes Ziel oder Teilziel ein oder mehrere Performance-Measures definiert werden können. Art und Umfang der Zielerreichung können auch von externen Umweltentwicklungen abhängig sein. Daher lassen sich zusätzliche Performance-Measures zur Überwachung performancerelevanter Umweltbedingungen in das PMS aufnehmen.

Analog zur Unternehmensplanebene können sich die internen Performance-Measures auf unterschiedlichen Aggregationsstufen befinden, je nachdem, ob sie sich zum Beispiel auf ein strategisches, taktisches oder operatives Ziel des Unternehmensplans beziehen, dessen Erreichung sie messen sollen. Um aber über mehrere Hierarchieebenen hinweg eine aufeinander abgestimmte Steuerung und Kontrolle der Gesamtpformance zu ermöglichen, sind auch feingliedrigere Abstufungen denkbar (vgl. [Ried00, S. 52]). Die Performance-Measures können untereinander kausal verbunden werden. Auf Basis kausaler Kennzahlbeziehungen können dann Früh- und Spätindikatoren unterschieden und verknüpft werden (vgl. [Wied85, S. 318], [LeEu02, S. 77]). Diese Kennzahlbeziehungen

¹ Auf das Wesen und die Unterschiede von Zweck-Mittel- und definitionslogischen Beziehungen geht speziell Abschnitt 4.1.2 näher ein.

ergeben sich weitgehend aus der Definitionslogik und den Zweck-Mittel-Beziehungen des zugrunde liegenden Zielsystems. Wird die Zielerreichung eines Ziels durch mehrere Performance-Measures abgebildet, können diese ebenfalls auf empirisch-logischer oder definitionslogischer Basis verknüpft werden.¹

Neben den Kausalverbindungen auf der PMS-Ebene weisen die Performance-Measures auch vertikale Bezüge zu den Systemelementen der anderen Modellebenen auf. Da die Geschäftsprozesse das Lösungsverfahren für den Unternehmensplan darstellen (vgl. [FeSi96, S. 49]; siehe Abschnitt 3.1.1.4), sind die Ziele und Performance-Measures einer Hierarchiestufe direkt mit den Teilprozessen oder Aktivitäten eines Geschäftsprozesses derselben Hierarchiestufe verbunden. Darüber hinaus entstehen bei einer konkreten Aufgabendurchführung Zuordnungsbeziehungen zwischen den Aufgaben der Geschäftsebene und den zugehörigen Aufgabenträgern der Ressourcenebene. Über diese vertikalen Verbindungsstränge sind die Ziele und Performance-Measures transitiv mit einem oder mehreren Aufgabenträgern verbunden. Diese Beziehungen zeigt Abbildung 17 anhand eines Beispiels zur Kreditprüfung.

Um zu zeigen, wie sich mithilfe des ganzheitlichen Performance-Management-Architekturmodells die Unternehmensperformance gestalten und lenken lässt, betrachtet der folgende Abschnitt das Performance-Management aus kybernetischer Sicht.

3.1.4 Kybernetisches Regelkreismodell für das Performance-Management

Das in diesem Abschnitt vorgestellte kybernetische Regelkreismodell soll die Steuerungs- und Regelungsvorgänge bei der Gestaltung und Lenkung der betrieblichen Performance aufzeigen. Diese Vorgänge resultieren zum einen aus dem Koordinationsbedarf zwischen den Teilaufgaben der Performance-Gestaltung und -Lenkung (vgl. Abschnitt 3.1.2), zum anderen aus den Abhängigkeitsbeziehungen, die zwischen ihrem Aufgabenobjekt und dem Unternehmen als Realsystem bestehen.

Das Regelkreismodell wird in zwei Schritten entwickelt. Zunächst werden die Steuerungs- und Regelungsvorgänge für die Performance-Gestaltung und -Lenkung getrennt voneinander vorgestellt. Erst in einem zweiten Schritt wird

¹ Mit kausalen Kennzahlbeziehungen setzt sich speziell Abschnitt 4.1.3 auseinander.

das dynamische Zusammenspiel zwischen den beiden Teilaufgaben und ihren Aufgabenobjekten beschrieben, indem die Regelkreismodelle zu einem gemeinsamen Modell kombiniert werden.

In Abschnitt 3.1.3 wurde das Unternehmensarchitekturmodell bereits als geeignetes Aufgabenobjekt für die Performance-Gestaltung eingeführt. Die drei Modellebenen der Unternehmensarchitektur übernehmen hierbei die Funktion einer Hilfsregelstrecke (siehe Abschnitt 3.1.1.2), die die Komplexität des eigentlichen Aufgabenobjekts, des betrieblichen Realsystems, für die Aufgabe der Performance-Gestaltung reduziert. Da Gestalten „das gedankliche Entwerfen eines Modells der Institution“ [Ulri01, S. 66] bedeutet, übernimmt das Unternehmensarchitekturmodell primär die Funktion eines Gestaltungsmodells. Als solches bildet es „eine noch nicht existierende, aber noch zu schaffende Wirklichkeit ab“ [Ulri01, S. 66]. Die Unternehmensarchitektur übernimmt aber auch die Aufgabe eines Beschreibungsmodells, da für eine gezielte Umgestaltung des Modellsystems ein Abgleich mit der im Realsystem anzutreffenden Ist-Architektur notwendig ist. Diese Doppelfunktion wird in Abbildung 18 durch die Sensor-/Aktorbeziehung zwischen Hilfsregelstrecke und dem Unternehmen als Realsystem verdeutlicht.

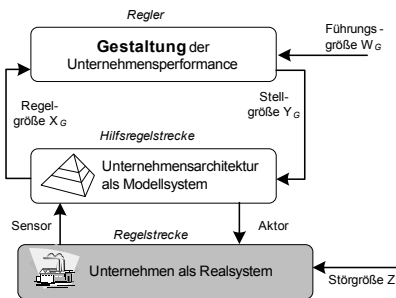


Abbildung 18: Performance-Gestaltung als Regelkreismodell

Über die Sensorbeziehung wird die Architektur des realen Unternehmens als IST-Zustand im Modell abgebildet und vom Regler, der die Aufgabe der Performance-Gestaltung übernimmt, als Regelgröße X_G abgegriffen. Als exogene Führungsgröße W_G ist im Hinblick auf die in Abschnitt 3.1.2 formulierte Zielsetzung des Performance-Managements das Anspruchsniveau der relevanten Stakeholder einzusetzen.

Nach einem Abgleich mit dem aus dieser exogenen Führungsgröße abgeleiteten SOLL-Zustand wird die Unternehmensarchitektur zunächst im Modell gestaltet (Stellgröße Y_G). Die Modellarchitektur wird anschließend über die Aktorbeziehung auf das Unternehmen als reale Regelstrecke übertragen. Bewirkt eine exogene Störgröße Z , dass die tatsächliche Unternehmensarchitektur von der im Modellsystem entworfenen Architektur abweicht, wird dies vom Regler

über die Sensorbeziehung und die Regelgröße X_G registriert. Der Regelkreis beginnt dann von Neuem.

Im Regelkreismodell der Performance-Lenkung schiebt sich das Performance-Measure-System als eine zweite Hilfsregelstrecke zwischen die Unternehmensarchitektur und den Regler, der die Aufgabe der Performance-Lenkung verantwortet (siehe Abbildung 19). Das Performance-Measure-System enthält Messinformationen, die der Regler über die Regelgröße X_L aufnimmt und anschließend mit den Zielwerten vergleicht, die sich aus der Führungsgröße W_L ergeben. Weichen Ziel- und Messwerte voneinander ab, greift der Regler steuernd in das Unternehmen als Realsystem ein (Stellgröße Y_L). Ob der Steuerungseingriff erfolgreich war, erfährt der Regler, indem ihm das PMS im Anschluss aktualisierte Messinformationen über die Regelgröße X_L zur Verfügung stellt.

Zu beachten ist, dass das Performance-Measure-System in keiner direkten Beziehung mit dem Unternehmen als Realsystem steht. Stattdessen bildet es zusammen mit dem Modell der Unternehmensarchitektur ein zusammengesetztes Hilfsregelstreckensystem (vgl. [Meye94, S. 16-17]). Die Messgrößen des PMS beziehen sich auf die in der Unternehmensarchitektur erfassten Bezugsobjekte (siehe Abschnitt 3.1.1.2) und sind somit in der betrieblichen Leistungssphäre verankert. Diese Beziehung wird in Abbildung 19 durch den Sensor 2 dargestellt.

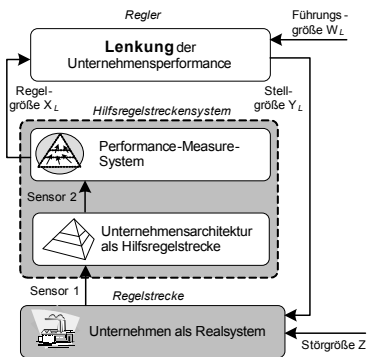


Abbildung 19: Performance-Lenkung als Regelkreismodell

Bei der Performance-Lenkung werden beide Hilfsregelstrecken ausschließlich als Beschreibungsmodell verwendet. Auf die in Abbildung 18 enthaltene Akteurbeziehung zwischen Unternehmensarchitektur und Unternehmen kann allerdings verzichtet werden, da diese Beziehung nur für die Performance-Gestaltung von Bedeutung ist. Der Performance-Lenkung steht bei der Steuerung nur so viel Handlungsspielraum zur Verfügung, wie ihr die Aufgabe der Performance-Gestaltung zugesteht. Deshalb dürfen die über die Stellgröße Y_L erfolgten

Steuerungseingriffe nicht dazu führen, dass die reale Unternehmensarchitektur von der im Modell gestalteten Architektur abweicht. Um diese Konsistenz sicher-

zustellen, ist eine enge Abstimmung zwischen den Reglern der Performance-Gestaltung und -Lenkung nötig. Um diese Abstimmung darzustellen, sind beide Regelkreise miteinander zu kombinieren (siehe Abbildung 20).

Die Performance-Gestaltung und -Lenkung bilden analog zum Hilfsregelstreckensystem ein zusammengesetztes Reglersystem. Die Abstimmung zwischen beiden Reglern folgt dem Prinzip des Management by Exception. „Dabei greift ein hierarchisch übergeordneter Regler erst dann ein, wenn eine bestimmte Ausnahmesituation vorliegt, die von dem jeweils untergeordneten Regler nicht mehr beherrscht wird“ [FeSi08, S. 41]. Tritt beispielsweise nach dem Einwirken einer Störgröße Z eine Performance-Abweichung auf, kann diese idealerweise vom Regler der Performance-Lenkung mit einem *lenkenden* Steuerungseingriff in das Realsystem behoben werden (Stellgröße Y_L). Das System wäre in diesem Fall „lenkig“, da es in der Lage ist, „bestimmte Vorzugszustände anzunehmen und andere zu vermeiden“ [Ulri01, S. 114]. Kann allerdings der gewünschte System-

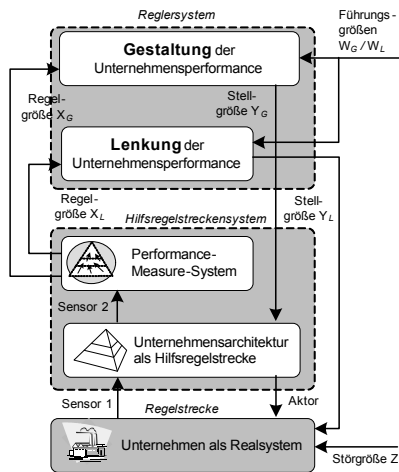


Abbildung 20: Performance-Management als kybernetisches Regelkreismodell

zustand nicht wieder hergestellt werden, hat das System die Eigenschaft der Lenkfähigkeit verloren. Dieser Verlust ist dem übergeordneten Regler, der Performance-Gestaltung, durch die Regelgröße X_G zu melden, woraufhin dieser versucht, das System wieder lenkfähig zu gestalten. Zu diesem Zweck muss die Unternehmensarchitektur durch *gestaltende* Steuerungseingriffe (Stellgröße Y_G) so verändert werden, dass die Voraussetzung für eine erfolgreiche Performance-Lenkung wieder gegeben ist und der erwünschte Systemzustand durch *lenkende* Steuerungseingriffe (Stellgröße Y_L) wieder hergestellt werden kann.

Das kybernetische Regelkreismodell dient im folgenden Abschnitt als Grundlage für die Konzeption eines generischen Prozessmodells für das Performance-Management, dessen Ablauf die Steuerungs- und Regelungsvorgänge vorstrukturieren (vgl. [Ried00, S. 60], [Wett02, S. 20]).

3.2 Generisches Prozessmodell für das Performance-Management

Im vorherigen Abschnitt wurde die Aufgabe des Performance-Managements in die beiden Teilaufgaben der Performance-Gestaltung und Lenkung zerlegt, die ein Architekturmodell als Aufgabenobjekt nutzen. Wie die beiden Teilaufgaben des Performance-Managements interagieren und mit dem Architekturmodell die betriebliche Performance gestalten und lenken, zeigt das kybernetische Regelkreismodell. Dieser Bezugsrahmen bildet nun die Grundlage für die Entwicklung eines generischen Prozessmodells für das Performance-Management. Dieses Prozessmodell zeichnet sich dadurch aus, dass es nicht zwischen dem Aufbau und dem Betrieb des Performance-Managements trennt. Auf diese Trennung wird verzichtet, da das Performance-Management ein iterativer Prozess ist, dessen Prozessschritte sowohl beim Aufbau als auch bei der fortlaufenden Anpassung des Performance-Managements von Bedeutung sind.

Generisch ist dieses Prozessmodell in zweierlei Hinsicht: Zum einen, weil sowohl seine Prozessstruktur als auch sein Prozessablauf deduktiv aus dem Aufgaben-, Architektur- und Regelkreismodell abgeleitet werden, zum anderen, weil die Prozessbeschreibung so allgemein gehalten ist, dass sie sich nicht nur für eine bestimmte Klasse von Unternehmen eignet, sondern eine Vorlage für das Performance-Management jedweden Unternehmens ist, unabhängig von dessen Branche oder Größe. Da es sich um ein Prozessmodell handelt, wird die Ressourcenebene ausgeklammert. Die Frage, welche Organisationseinheiten die Prozessschritte durchführen und welche Möglichkeiten sich zur IT-Unterstützung bieten, muss für ein spezifisches Unternehmen, speziell vor dem Hintergrund seiner Aufbauorganisation und bereits vorhandener IT-Systeme beantwortet werden.

Abschnitt 3.2.1 erläutert die prozessualen Grundlagen, bevor Abschnitt 3.2.2 die Prozessstruktur und Abschnitt 3.2.3 den Prozessablauf vorstellt.

3.2.1 Grundlagen von Prozessen

In den 30er Jahren des letzten Jahrhunderts erkannten die beiden Autoren Nordsieck (vgl. [Nord31]) und Hennig (vgl. [Henn71]) unabhängig voneinander, dass nicht nur der organisatorische Aufbau, sondern auch die organisatorischen Ablaufbeziehungen betrachtet werden müssen, um zu einem realitätsnahen Bild eines Unternehmens zu gelangen (vgl. [Gait83, S. 5]). Für Kosiol, der in den 60er Jahren an die Arbeit von Nordsieck anknüpfte (vgl. [Kosi76, Vor-

wort]), sind Aufbau- und Ablauforganisation lediglich „verschiedene Gesichtspunkte der Betrachtung für den gleichen einheitlichen Gegenstand“ [Kosi76, S. 32]. Beide Sichtweisen lassen sich daher nur gedanklich voneinander trennen (vgl. [Gait83, S. 23]).

Die Aufbauorganisation legt die Zielsetzungen der Bereiche, Abteilungen und Stellen eines Unternehmens fest, indem sie aus der obersten Betriebsaufgabe entsprechende Teilaufgaben ableitet (vgl. [Gait83, S. 2]) und diese anschließend geeigneten Aufgabenträgern zuordnet (vgl. [Kosi76, S. 186-187]). Die Ablauforganisation rückt hingegen nicht die Zielsetzung, sondern den Arbeitsprozess zur Zielerreichung in den Mittelpunkt (vgl. [Kosi76, S. 185], [Gait83, S. 23]). Ein Prozess gibt an, mit welcher Tätigkeit und mit welchen Arbeitsmitteln ein Gegenstand zu bearbeiten ist ([Kosi76, S. 67]).

Ein Prozess kann formal als ein Input-Output-System definiert werden, das Ressourcen als Input verbraucht, um daraus eine Leistung zu erstellen, die es als Output an einen Leistungsempfänger abgibt (vgl. [FeSi93, S. 590], [FeSi08, S. 197]). Nach Kosiol ist ein Prozess ein „raumzeitlich sich abspielender Vorgang“ [Kosi76, S. 185]. Demnach kann das Lösungsverfahren einer Aufgabe als Prozess beschrieben werden (vgl. [Nord72, S. 10], [Kosi76, S. 43]), da sich die Durchführung einer Aufgabe als Vorgang darstellen lässt (vgl. [FeSi93, S. 590]). Ein solcher Vorgang wird von einem Ereignis ausgelöst, das als Vorereignis genau die Aufgabe anstößt, für die der Vorgang das prozessuale Lösungsverfahren darstellt (vgl. [FeSi08, S. 61]). Jeder Vorgang produziert ein Nachereignis, das wiederum eine andere Aufgabe – und somit dessen Lösungsverfahren als Folgeprozess – anstoßen kann (vgl. [FeSi08, S. 61]). Ein Geschäftsprozess ist somit ein „ereignisgesteuerter Ablauf von Aufgabendurchführungen“ [FeSi08, S. 136]. Auf diese Weise entsteht ein über Ereignisse gekoppeltes Netz an Vorgängen bzw. Prozessen, das sich parallel zur Zerlegungsstruktur der Aufgaben in Teilaufgaben herausbildet (vgl. [FeSi08, S. 61]). Die Zerlegungsstruktur der Vorgänge wird durch die Zerlegung der Aufgaben in Teilaufgaben bestimmt (vgl. [FeSi08, S. 62]).

Prozesse lassen sich hierarchisch in Teilprozesse, Prozesssegmente und Prozesselemente zerlegen, wobei Letztere die einzelnen Prozessaktivitäten beschreiben (vgl. [Gait83, S. 75, S. 79]). Weiterhin lässt sich ein Geschäftsprozess in Haupt- und Serviceprozesse unterteilen. Im Gegensatz zu einem Hauptprozess, dessen Leistungsempfänger stets Teil der Umwelt ist, gibt ein Serviceprozess seine Leistung entweder an einen Haupt- oder an einen anderen Serviceprozess ab (vgl. [FeSi08, S. 194]). Ein Unternehmen zeichnet sich durch eine „integra-

tive Struktur von Teilprozessen“ [Gait83, S. 63] aus und kann als ein „System von Prozessen“ [Horv02, S. 108] aufgefasst werden.

Um ein Prozesssystem für ein Unternehmen zu bilden, wurde von Kosiol das Analyse-Synthese-Verfahren vorgeschlagen, das ein Top-Down-Vorgehen beschreibt.¹ Kosiol betrachtet die analytische Zerlegung der Betriebsaufgabe in Teilaufgaben als notwendige Bedingung für die anschließend durchzuführende Aufgabensynthese. Erst durch die Aufgabensynthese gelangt man zur Aufbauorganisation, indem die Teilaufgaben zu Stellen zusammengefasst und den Aufgabenträgern zugeordnet werden (vgl. [Kosi76, S. 32-33]). Nachdem mittels Aufgabenanalyse und -synthese der organisatorische *Aufbau* festgelegt ist, wird anschließend der organisatorische *Ablauf* des Unternehmens betrachtet, den Kosiol ebenfalls nach dem Analyse-Synthese-Prinzip entwickelt (vgl. [Kosi76, S. 189-191]). Kosiol spricht in diesem Zusammenhang von der Arbeitsanalyse und der Arbeitssynthese. Da die Teilaufgaben der untersten Aufgabenebene die Ausgangsbasis für die Arbeitsanalyse bilden, kann die Arbeitsanalyse als Verlängerung der Aufgabenanalyse aufgefasst werden (vgl. [Kosi76, S. 189]).

3.2.2 Prozessstruktur

In diesem Abschnitt werden die strukturbestimmenden Elemente des generischen Performance-Management-Prozesses vorgestellt. Dem Prinzip der verrichtungsorientierten Aufgabenzerlegung folgend, wurde die Aufgabe des Performance-Management-Prozesses in die beiden Teilaufgaben der Performance-Gestaltung und -Lenkung zerlegt (siehe 3.1.2). Das Lösungsverfahren jeder Teilaufgabe kann als Teilprozess eines übergeordneten Performance-Management-Prozesses spezifiziert werden. Statt aber direkt auf dem Unternehmen als Realsystem zu operieren, nutzt jeder Teilprozess sein eigenes Teilmodellsystem des Architekturmodells (siehe Abschnitt 3.1.3). Während der Gestaltungsprozess das Unternehmen mithilfe des Modells der Unternehmensarchitektur gestaltet, nutzt der Lenkungsprozess das Performance-Measure-Systems (PMS), um das Unternehmensgeschehen mit direkten Steuerungseingriffen zielgerichtet zu lenken (siehe Abschnitt 3.1.4).

Beide Teilmodellsysteme müssen jedoch zunächst erstellt, d.h. *geplant* und *umgesetzt* werden. Daher kann sowohl der Gestaltungs- als auch der Lenkungsprozess in je eine *Planungs-* und *Umsetzungsphase* unterteilt werden. Neben der

¹ Andere Autoren, wie zum Beispiel Gaitanides, vertreten einen Bottom-Up-Ansatz (vgl. [Gait83, S. 63], [GaSV94, S. 6]).

Planungs- und Umsetzungsphase ist die *Lenkungsphase* die dritte und letzte Phase des Performance-Management-Prozesses. Die Lenkungsphase ist allerdings allein dem Teilprozess der Performance-Lenkung zuzuordnen, da nur in dieser Phase die Kennzahlen und Indikatoren des PMS verwendet werden, um die Unternehmensperformance zu *steuern* und zu *kontrollieren*. Es werden somit insgesamt drei generische Hauptphasen unterschieden: die *Planungs-*, *Umsetzungs-* und *Lenkungsphase* (vgl. [BMW + 00, S. 3], [Ried00, S. 30], [Wett02, S. 187]).

Jede dieser drei Hauptphasen unterteilt sich darüber hinaus in je zwei Teilphasen, bestehend aus einzelnen Prozessschritten. Während die Zerlegung der Planungs- und Umsetzungsphase objektorientiert erfolgt, d.h. anhand der beiden Teilmodellsysteme, gliedert sich die Lenkungsphase verrichtungsorientiert in eine Steuerungs- und eine Kontrollphase (zu den Zerlegungsprinzipien siehe Abschnitt 3.1.1.3). Abbildung 21 zeigt die daraus resultierende Struktur des Performance-Management-Prozesses.

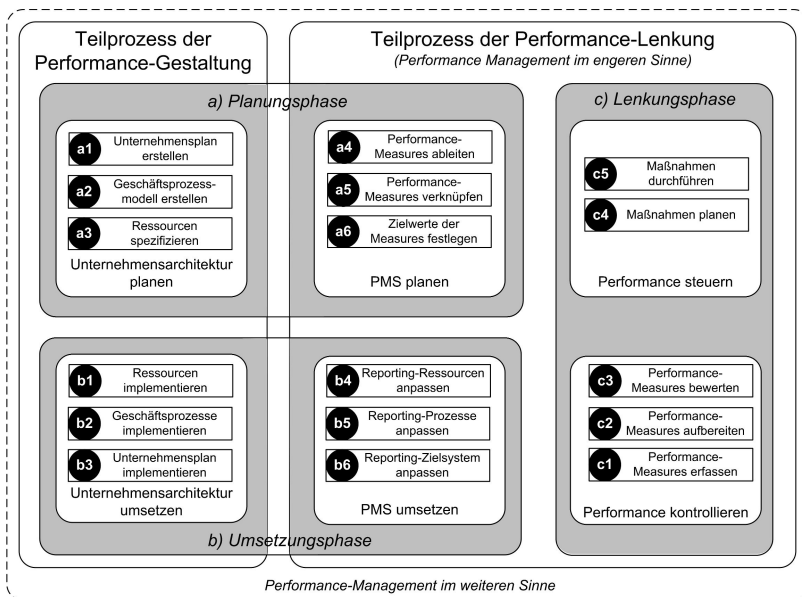


Abbildung 21: Teilprozesse, Phasen und Aktivitäten des Performance-Management-Prozessmodells

In einem weiteren Strukturierungsschritt können für jede Teilphase die einzelnen Prozessaktivitäten angegeben werden. Während sich die Prozessaktivitäten

ten der Planungs- und Umsetzungsphase an den Modellebenen und Strukturelementen des Architekturmodells orientieren, sind die Aktivitäten der Lenkungsphase in Anlehnung an den klassischen Management- und Kontrollprozess zerlegt worden (vgl. [KoBr72, S. 27], [Wild82, S. 36-37], [StSc93, S. 10]). Die Aktivitäten des Performance-Management-Prozesses (siehe Abbildung 21) werden im Folgenden erläutert.

3.2.2.1 Teilprozess der Performance-Gestaltung

In der Literatur herrscht weitgehend Konsens, dass die Bildung von Kennzahlen und Indikatoren eine explizit formulierte Strategie voraussetzt (vgl. [JoKa87, S. 256], [Blan99, S. 94], [BMW + 00, S. 3], [AnFa02, S. 50], [KüWe03, S. 72]). Die Formulierung der Strategien rechnet man aber meist nicht dem Performance-Management-Prozess zu, sondern betrachtet diese als Aufgabe eines übergeordneten Planungsprozesses. An diesen Planungsprozess knüpft der Performance-Management-Prozess lediglich an, indem er die formulierten Strategien aufgreift und in quantitativ messbare Performanceziele übersetzt (vgl. [Ried00, S. 36], [GlKi02, S. 90], [Wett02, S. 129-130], [MeWi04, S. 7]).

Aus systemtheoretischer Sicht entspricht die Frage nach der Abgrenzung des Performance-Management-Prozesses dem in Abschnitt 3.1.1.1 angesprochenen Grenzproblem. Wo der Performance-Management-Prozess beginnt und wo er endet, lässt sich vom Standpunkt der Systemtheorie aus weder grundsätzlich noch allgemeingültig, sondern nur im Hinblick auf die der Prozessdifferenzierung zugrunde liegenden Zielsetzung beantworten (siehe Abschnitt 3.1.1.1). Indem die Aufgabe des Performance-Managements in die beiden Teilaufgaben der Performance-Gestaltung und -Lenkung zerlegt wurde (siehe Abschnitt 3.1.2), liegt dieser Prozessdifferenzierung sowohl das Gestaltungs- als auch das Lenkungsziel zugrunde. Diesem Verständnis trägt das in Abbildung 21 dargestellte Prozessmodell Rechnung, indem es zwischen einem Performance-Management im engeren und weiteren Sinne unterscheidet. In einem engeren Sinne umfasst der dargestellte Performance-Management-Prozess ausschließlich die Aktivitäten der Performance-Lenkung. In einem weiteren Sinne wird ihm auch der Teilprozess der Performance-Gestaltung zugerechnet, mit dem erst die Voraussetzungen für die Entwicklung und Lenkung der Performance geschaffen werden.

Die Planung der Unternehmensarchitektur beginnt mit der Erstellung des Unternehmensplans (siehe Abbildung 21: a1). Zunächst ist Klarheit über die oberste Zwecksetzung des Unternehmens (vgl. [Kosi76, S. 41]) und die darauf

ausgerichteten Unternehmensstrategien zu gewinnen, bevor diese entlang der organisatorischen Hierarchie- und Aggregationsebenen in konkretere Teilziele aufgespalten werden (siehe Abschnitt 3.1.3). Die Strategie- und Zielformulierung sollte stets unter Berücksichtigung der als relevant eingestuften Stakeholderansprüche geschehen (vgl. [BrBr95, S. 111-118], [AtWW97, S. 27], [Müll98, S. 37-38], [Klin99, S. 15], [Glei01, S. 22], [Wade01, S. 45], [AnFa02, S. 67-70]). Da die Ziele jedoch nicht unabhängig voneinander festgelegt werden können, sollten diese sorgfältig aufeinander abgestimmt in ein Zielsystem eingebunden werden (vgl. [Wild82, S. 53]). Das Zielsystem sollte realistisch, operational, geordnet, konsistent, aktuell, vollständig, durchsetzbar, transparent und überprüfbar sein sowie in Kongruenz zur Organisation stehen (vgl. [Wild82, S. 55]).

Die nächsten beiden Prozessschritte bestehen darin, die zweite und dritte Ebene der Unternehmensarchitektur zu planen, d.h. eine konkrete Vorstellung über die Geschäftsprozesse und deren organisatorische Ausrichtung und Verankerung zu gewinnen (siehe Abbildung 21: a2 und a3) (vgl. [GIKi02, S. 90], [AnFa02, S. 56-61]).

Da die Geschäftsprozesse das Lösungsverfahren des Unternehmensplans sind (vgl. [RuBr95, S. 45 u. 47], [Sinz04, S. 316]), sollten zunächst die Unternehmensziele „einzelnen Geschäftsprozessen zugeordnet werden und sukzessive bis auf Teilprozessebene verfeinert werden“ [Hoff00, S. 135]. Daraufhin sind die Prozesse in ihrem Ablauf und ihrer Struktur so zu spezifizieren, dass die jeweiligen Ziele erreicht werden können (vgl. [Mart03, S. 8]): „Once we have Process Goals, we need to make sure that our processes are structured (designed) to meet the goals efficiently“ [RuBr95, S. 23]. Auf dieser Modellebene spiegelt sich die strategische Ausrichtung des Unternehmens in der Prozessarchitektur wider, indem sie die Schwerpunkte für deren Gestaltung und Verbesserung vorgibt. Wade verdeutlicht diesen Zusammenhang an folgendem Beispiel:

„Once the strategic focus area is finalized, it is critical to identify which processes are most strategic for the organization. If your organization is focused on being the low-cost producer, employees must focus on the processes that deliver the core products/services and the key quality detection/correction processes. Customer focused organizations must optimize customer service, market research, and product/service delivery. Product focused organizations must optimize the new product development, marketing, and sales processes.“ [Wade01, S. 91]

Die Planung der Unternehmensarchitektur wird mit der Spezifikation ihrer Ressourcen abgeschlossen (siehe Abbildung 21: a3). Die Ressourcen der dritten Modellebene führen die Geschäftsprozesse der zweiten Modellebene aus (vgl. [Sinz04, S. 316]) und sind den Prozessaktivitäten als Aufgabenträger direkt

zuzuordnen. Hierbei können zwei Arten von Aufgabenträgern unterschieden werden: maschinelle und personelle Aufgabenträger (vgl. [FeSi08, S. 52]). Ausgehend von den modellierten Geschäftsprozessen sind zunächst die *personellen* Aufgabenträger innerhalb der Aufbauorganisation zu spezifizieren ([FeSi08, S. 194]), etwa indem sie zu Teams, Abteilungen oder Geschäftsbereichen zusammengefasst werden (vgl. [RuBr95, S. 181]). Die *maschinellen* Aufgabenträger, die sich in Anwendungssysteme bzw. Anlagen und Maschinen differenzieren, können analog zur Struktur der Aufbauorganisation ebenfalls zu hierarchischen Aufgabenträgerkomplexen zusammengefasst (vgl. [FeSi08, S. 59]) und mit der Prozessarchitektur der zweiten Modellebene verknüpft werden.

In der zweiten Prozessphase der Performance-Gestaltung ist das geplante Modell der Unternehmensarchitektur auf das reale Unternehmen zu übertragen und umzusetzen. Die Aktivitäten der Umsetzungsphase orientieren sich ebenfalls an den drei Modellebenen der Unternehmensarchitektur. Da sich die Geschäftsprozesse nur mithilfe der für ihre Durchführung nötigen Ressourcen einführen lassen, beginnt die Umsetzung der Unternehmensarchitektur mit dem Einsetzen der maschinellen und personellen Aufgabenträger (siehe Abbildung 21: b1). Konkret bedeutet dies, dass man beispielsweise neue Mitarbeiter einstellt oder neue Anwendungssysteme bzw. Maschinen und Anlagen installiert. Anschließend ist die personelle und maschinelle Integration der Aufgabenträger sicherzustellen. Hierzu sind die im Geschäftsprozessmodell spezifizierten Aufgaben ihren maschinellen bzw. personellen Aufgabenträgern zuzuordnen (siehe Abbildung 21: b2) (vgl. [FeSi08, S. 57-59]). Die Umsetzung des Unternehmensplans erfolgt, indem man die im Zielsystem festgehaltenen Ziele verbindlich denjenigen Personen vorgibt, die die Erreichung der Ziele verantworten und einen wesentlichen Beitrag zur Zielerreichung leisten (siehe Abbildung 21: b3). Damit ist der Teilprozess der Performance-Gestaltung abgeschlossen.

3.2.2.2 Teilprozess der Performance-Lenkung

In der ersten Phase der Performance-Lenkung wird das Performance-Measure-System geplant, bevor es in der zweiten Phase umgesetzt und in der dritten Phase zur Steuerung und Kontrolle der Unternehmensperformance dient.

Die erste Planungsaktivität besteht darin, aus den im Unternehmensplan formulierten Strategien und Zielen geeignete Performance-Measures abzuleiten (siehe Abbildung 21: a4). Hierbei ist es ratsam, das Zielsystem sukzessive von oben nach unten zu durchlaufen, um Top-Down geeignete Kennzahlen und Indi-

katoren zur Messung der Zielerreichung zu suchen (vgl. [KüWe03, S. 72]). Da es oftmals schwierig ist, aus Strategien konkrete Messgrößen abzuleiten, schlagen einige Autoren vor, dies über den Umweg der kritischen Erfolgsfaktoren durchzuführen (vgl. [GIGC97, S. 217], [Brun99, S. 64], [Hoff00, S. 102], [HoMa99], [BuWG04a, S. 12]).

Das Konzept der kritischen Erfolgsfaktoren geht auf Rockart zurück, der damit die zentralen Kernaspekte eines Unternehmens bezeichnet. Diese sind dort, „where ‚things must go right‘ for the business to flourish“ [Rock79, S. 85]. Die kritischen Erfolgsfaktoren sind die grundlegenden Parameter, die „den Erfolg von Unternehmen nachhaltig und entscheidend beeinflussen“ [Schu96, S. 200] und bei der Umsetzung der Unternehmensstrategien eine entscheidende Rolle spielen (vgl. [Brun99, S. 65]) (zur Bestimmung der Erfolgsfaktoren vgl. [GrHZ96], [Brun99, S. 82-89]). Sind die Erfolgsfaktoren hinreichend konkretisiert, fällt es in der Regel leichter, konkrete Messkriterien abzuleiten und als Maßstab zur Beurteilung der Erfolgsfaktoren zu verwenden (vgl. [HoMa99, S. 392], [Hoff00, S. 103]).

Als Ausgangspunkt der Messgrößenentwicklung, speziell für die Identifizierung nicht-finanzieller Kennzahlen und Indikatoren, können auch die vom Teilprozess der Performance-Gestaltung vorgegebenen Prozesse und Ressourcen dienen. Diese sind innerhalb der Unternehmensarchitektur mit den Zielen und Teilzielen der Unternehmensplanebene verbunden (siehe Abschnitt 3.1.3). Ausgehend von einem Ziel lassen sich diese vertikalen Verbindungsstränge dazu nutzen, gezielt diejenigen Prozesselemente und Ressourcen zu identifizieren, die die Erreichung eines bestimmten Ziels verantworten bzw. beeinflussen. Die identifizierten Prozesselemente und Ressourcen kommen dann als potenzielle Messobjekte für nicht-finanzielle Performance-Measures in Frage (vgl. [Hoff00, S. 135 und 139], [AnFa02, S. 60]). Hierbei sind insbesondere die Schnittstellen zwischen den Prozessen von Bedeutung, da dort der Prozessinput und -output mithilfe von Messgrößen erfasst werden kann (vgl. [FJB+91, S. 78-94], [SoVr94, S. 64]). Zu beachten ist, dass man sich bei der Ableitung der Performance-Measures am Ideal eines objektiven Informationsbedarfs orientiert und die Problematik der aktuellen oder potenziellen Verfügbarkeit der Performance-Daten – zumindest für den Augenblick – noch ausklammert (vgl. [Ecc191, S. 38]).

Nachdem für jedes Ziel eine oder mehrere Messgrößen festgelegt wurden, sind diese in einem zweiten Schritt kausal zu verknüpfen (siehe Abbildung 21: a5) (vgl. [Wett02, S. 90]). Hierbei müssen insbesondere die Einflusswirkungen

der nicht-finanziellen Indikatoren auf die finanziellen Kennzahlen verstanden und offen gelegt werden (vgl. [EcPy92, S. 43]). Je nachdem, ob sich die Änderung eines Messwertes im Zeitverlauf mittelbar oder unmittelbar im Ergebnis einer anderen Messgröße niederschlägt, lassen sich Früh- von Spätindikatoren unterscheiden (vgl. [KüWe03, S. 19], [Glei01, S. 221]). Eine solche Unterscheidung lässt sich zunächst parallel zur Zweck-Mittel-Ordnung des Zielsystems vornehmen (siehe Abschnitt 3.2.2.1; vgl. [Wild82, S. 59]). Im Anschluss können aber auch diejenigen Messgrößen kausal verknüpft werden, die die Zielerreichung eines einzelnen Ziels abbilden. Bei der kausalen Verknüpfung der Messgrößen kann eine Betrachtung der Geschäftsprozesse hilfreich sein, mit denen die Messgrößen über das Zielsystem verbunden sind (siehe Abbildung 17). Aus den charakteristischen Prozesseigenschaften, etwa der Struktur, dem Ablauf und der Taktung eines Prozesses sowie den Stellen, an denen die Messpunkte gesetzt wurden, lassen sich in der Regel wertvolle Informationen bezüglich Richtung und Intensität von Kennzahlenverknüpfungen ableiten (vgl. [Baum02, S. 25]).

Im Anschluss an die Verknüpfung der Kennzahlen sind die Performanceziele quantitativ festzulegen (siehe Abbildung 21: a6). Für einzelne, ausgewählte Performance-Measures können Zielwerte bestimmt und ggf. um absolute oder relative Schwellwerte oder Abweichungstoleranzen ergänzt werden (vgl. [GIGC97, S. 217], [Glei01, S. 26], [AnFa02, S. 88-89], [KüWe03, S. 159]). Auch hier ist es ratsam, sich an den Zielen und Strategien des Unternehmensplans zu orientieren (vgl. [Glei01, S. 25-26]). Die Ziel- bzw. Schwellwerte der Messgrößen sollten so gesetzt sein, dass bei ihrer Erreichung bzw. Einhaltung der Unternehmensplan erfolgreich zu realisieren ist. Die quantitativen Zielvorgaben dürfen nicht im Konflikt zueinander stehen und müssen von den hierfür vorgesehenen Ressourcen im Hinblick auf deren Leistungsfähigkeit auch realistisch zu erreichen sein (vgl. [Wild82, S. 62]). Zielkonflikte können mithilfe der im vorherigen Prozessschritt entwickelten Zweck-Mittel-Beziehungen aufgedeckt werden (siehe Abschnitt 3.2.1.2). Zielkonflikte treten auf, falls sich die Maßnahmen zur Zielerfüllung – oder die Zielerfüllung selbst – negativ auf das Erreichen eines anderen Ziels auswirken (Zielkonkurrenz) oder dessen Erreichung sogar ganz ausschließen (Zielantonomie) (vgl. [Wild82, S. 63]). Zielantonomien sind durch einen Rücksprung in den Zielbildungsprozess der Unternehmensarchitekturplanung (siehe Abbildung 21: a1) zu beheben. Eine Konkurrenz zwischen Zielen wird sich hingegen nie ganz vermeiden lassen (vgl. [LeEu02, S. 76-77]). Dies sollte bei der Festlegung der Zielwerte berücksichtigt werden, indem man zum Beispiel die Zielkonkurrenz durch eine entsprechende Priorisierung entschärft.

In der zweiten Phase, der Umsetzungsphase, ist das geplante PMS so umzusetzen, dass die definierten Messgrößen in der eigentlichen Lenkungsphase effizient erhoben, aufbereitet und interpretiert werden können. Im Gegensatz zu den Prozessschritten der PMS-Planung, die sich am strukturellen Aufbau des PMS orientieren, sind die Prozessschritte zur Umsetzung des PMS analog zu den drei Modellebenen der Unternehmensarchitektur gegliedert. D.h., dass zunächst die für die Leistungsmessung und -steuerung notwendigen Ressourcen einzusetzen und die entsprechenden Reporting-Prozesse einzuführen sind, bevor die festgelegten Performance-Ziele kommuniziert werden. Sofern jedoch kein komplett neues Berichtssystem aufgebaut werden soll, sind die bestehenden Strukturen und Systeme der Leistungsmessung zu erfassen und neu auszurichten (vgl. [Bred95b, S. 188-189], [AnFa02, S. 81]).

Der erste Umsetzungsschritt besteht darin, die für die Steuerung und Kontrolle der Performance benötigten personellen und maschinellen Ressourcen einzusetzen und in die Unternehmensarchitektur zu integrieren (siehe Abbildung 21: b4). Hinsichtlich der personellen Ressourcen bedeutet dies, dass beispielsweise neue Mitarbeiterstellen für das Berichtswesen geschaffen oder vorhandene Mitarbeiter von ihren bisherigen Aufgaben entbunden und für die Aufgaben der Performance-Steuerung und -Kontrolle abgestellt werden. Den weitaus größten Aufwand verursacht jedoch in der Regel die Anpassung der maschinellen Ressourcen, da diese eine erfolgreiche Umsetzung des PMS am meisten beeinflussen können (vgl. [BMW+00, S. 8]). So sind zunächst geeignete Datenquellen zu identifizieren (vgl. [AnFa02, S. 112], [KüWe03, 93-102]) sowie die Verfügbarkeit und Qualität der Daten zu überprüfen und sicherzustellen (vgl. [Knob00, S. 32], [KüWe03, S. 103-104 und 109-110], [Frie04, S. 2]). Darüber hinaus sind die Anwendungs- und Hardwaresysteme zu implementieren, mit denen die Performance-Daten gesammelt, aufbereitet, analysiert und schließlich kommuniziert werden sollen.

Im zweiten Umsetzungsschritt erfolgt die Anpassung bestehender bzw. die Einführung neuer Reporting-Prozesse (siehe Abbildung 21: b5). Werden die erforderlichen Daten noch nicht elektronisch, sondern nur in Papierform erfasst (vgl. [AnFa02, S. 114-115], [KüWe03, S. 60]), sind beispielsweise die Prozesse zur Datensammlung um neue Prozeduren der Datenextraktion und -transformation zu ergänzen (vgl. [BMW+00, S. 3], [KüWe03, S. 106]). Für jede Messgröße ist festzulegen, von wem und mit welcher Messfrequenz sie erfasst werden soll (vgl. [Ecc191, S. 44]). Ferner muss man festlegen, in welcher Frequenz und von wem die Performance-Daten zu analysieren sind (vgl. [KüWe03, S. 131-141])

und an wen die Analyseergebnisse in welcher Form kommuniziert werden sollen (vgl. [Ecc191, S. 44], [AnFa02, S. 146], [KüWe03, S. 143-151]).

Der letzte Schritt zur Umsetzung des PMS besteht darin, den personellen und maschinellen Aufgabenträgern die quantitativen Zielwerte derjenigen Performance-Measures mitzuteilen, die sie mit der Durchführung ihrer Aufgaben beeinflussen können. Damit die Mitarbeiter die Zielvorgaben akzeptieren, muss ihnen verständlich gemacht werden, weshalb für eine Messgröße ein bestimmter Zielwert erreicht werden soll. Dies kann beispielsweise anhand der kausalen Kennzahlverknüpfungen und den zugrunde liegenden Ursache-Wirkungs-Annahmen geschehen.

Nachdem das PMS und die zugrunde liegende Unternehmensarchitektur umgesetzt sind, kann in der Lenkungsphase schließlich damit begonnen werden, die Unternehmensperformance mithilfe der Kennzahlen und Indikatoren zu kontrollieren und zu steuern. Die Performance-Kontrolle beginnt mit dem Erfassen der Messdaten (siehe Abbildung 21: c1). Dies ist meist eine Routineaufgabe, bei der die im PMS spezifizierten Messgrößen regelmäßig aus den unterschiedlichen Datenquellen extrahiert und den Berichts- und Abfragesystemen zur Verfügung gestellt werden. Wird ein Data-Warehouse verwendet¹, erstreckt sich die automatische Datenerfassung über den gesamten ETL-Prozess der Datenextraktion, -transformation und des Ladens der Daten in das Data-Warehouse (vgl. [Sinz04, S. 315]). Eine manuelle Erfassung bedeutet in der Regel, dass Mitarbeiter die Messwerte per Hand in das System eintippen. Dies kann entweder durch eine zentrale Erfassungsstelle oder dezentral und direkt am Entstehungsort der Daten geschehen (vgl. [Wett02, S. 188]).

Die zahlreichen Messwerte müssen in einem zweiten Schritt aufbereitet und zu aussagekräftigen und entscheidungsrelevanten Informationspaketen zusammengefasst werden (siehe Abbildung 21: c2). Entscheidungsrelevanz ergibt sich maßgeblich aus Performance-Abweichungen. Daher steht bei der Aufbereitung der Performance-Daten zunächst die Identifizierung dieser Abweichungen im Vordergrund. Im Idealfall beschränkt man sich aber nicht auf Soll-Ist-Abweichungen, sondern ermittelt zusätzlich Wird-Ist- oder Ist-Ist-Abweichungen und stellt vorsteuernde Vergleiche zwischen Soll-Soll-, Soll-Wird- und Wird-Wird-Größen an (vgl. [Küpp97, S. 171]).

Die ersten drei Abweichungsarten (Soll-Ist, Wird-Ist, Ist-Ist) vergleichen die von einem Bezugsobjekt erreichten Ist-Wert entweder mit dem ursprünglich geplanten Zielwert (Soll-Ist-Vergleich), einer vormals prognostizierten Ziela-

¹ Auf das Data-Warehouse-Konzept geht speziell Abschnitt 5.3.2.2 ein.

sprägung (Wird-Ist-Vergleich) oder mit der aktuellen Kennzahlausprägung eines anderen, aber vergleichbaren Kontrollobjekts (Ist-Ist-Vergleich). Die drei anderen Vergleichsarten (Soll-Soll, Soll-Wird, Wird-Wird) werden ex-ante, d.h. vor dem eigentlichen Zeitpunkt der Zielerreichung durchgeführt und können dadurch frühzeitig Hinweise auf Zielkonflikte (Soll-Soll-Vergleich), zu entwickelnde Fehlentwicklungen (Soll-Wird-Vergleich) oder Prognoseinkonsistenzen (Wird-Wird-Vergleich) geben (vgl. [Küpp97, S. 171]).

Eine effiziente Berichterstattung orientiert sich bei der Darstellung der erkannten Abweichungen am Informationsempfänger (vgl. [GSGK02, S. 343]). Daher sollten die Daten vor ihrer Übermittlung gefiltert, strukturiert und in eine adäquate Form gebracht werden (vgl. [MeWi04, S. 8]). Indem man die Performance-Daten filtert und verdichtet, wird der Empfänger bei der Aufnahme und Auswertung der Informationen entlastet und die Komplexität einer Entscheidungssituation reduziert (vgl. [GIGC97, S. 33], [Wett02, S. 190]). Sind Performance-Daten über einen längeren Zeitraum verfügbar, lassen sich diese beispielsweise anhand von Zeitreihenanalysen grafisch aufbereiten und zu einer Informationen über die Trendrichtung verdichten.¹ Eine interessante Filterung der Messwerte kann auch erreicht werden, indem eine Kennzahl nur zusammen mit den Messwerten derjenigen Größen betrachtet wird, mit denen sie über eine Kennzahlbeziehung – direkt oder transitiv – verbunden ist.

Bei der anschließenden Bewertung (siehe Abbildung 21: c3) sind die Chancen und Risiken abzuschätzen, die sich für das Unternehmen, bzw. für den vom Berichtsempfänger verantworteten Teilbereich, aus den aktuellen Performance-Entwicklungen ergeben. Die Abweichungen sind hierbei anhand einer Risiko- und Chancenbewertung nach ihrem Handlungsbedarf zu priorisieren. Hierzu ist es ratsam, mithilfe unterstützender Methoden und Werkzeuge auch „hinter“ die Messgrößen zu schauen: „tools as self-audit, benchmarking and process analysis could be applied to give a broader picture of performance“ [Bred95c, S. 191].

Die Priorisierung der Performance-Abweichungen dient dazu, sich bei der im nächsten Prozessschritt folgenden Maßnahmenplanung ausschließlich auf die einflussstärksten Leistungsdifferenzen zu konzentrieren. Hierbei kann es „wirtschaftlicher sein, jenen Performance-Indikatoren Beachtung zu schenken, welche ein höher gestelltes Ziel (...) besonders stark beeinflussen“ [KüWe03, S. 134]. Ein solches Vorgehen gewährleistet zwar, dass die Ressourcen bei der Durch-

¹ Abhängig von der Hierarchieebene des Informationsempfängers ist es selbstverständlich auch denkbar, dass der Informationsempfänger die bereitgestellten Informationen selbst filtert und verdichtet (vgl. [WeKM01, S. 51]).

führung der Verbesserungsmaßnahmen effektiv eingesetzt werden, setzt aber voraus, dass die Zweck-Mittel-Beziehungen bekannt sind.

Um zu entscheiden, welche Handlungsalternativen sich effektiv bieten, kann nun auf das in Abbildung 17 skizzierte Architekturmodell zurückgegriffen werden (siehe Abschnitt 3.1.3). Da jede Maßgröße des PMS direkt oder transitiv mit den Elementen der Unternehmensplan-, Geschäftsprozess- und Ressourcenebene verknüpft ist, lässt sich unmittelbar nachvollziehen, in welchen Haupt- oder Serviceprozessen eine Performance-Abweichung entstanden ist und welche maschinellen oder personellen Ressourcen diese Abweichung verantworten. Dies ermöglicht im Zuge der Maßnahmenplanung eine rasche Fokussierung auf den Herkunfts- und Entstehungsort von Fehlentwicklungen. Dann muss aber dennoch folgende Frage beantwortet werden: Welche Maßnahmen können die Ursachen möglichst effizient und effektiv beheben und wie sind diese im Einzelnen auszugestalten? Je nachdem, wie die Antwort auf diese Frage ausfällt, nimmt der Performance-Management-Prozess einen anderen Verlauf. Welche Wege sich hierbei einschlagen lassen, zeigt der folgende Abschnitt.

3.2.3 Prozessablauf

Bei der Festlegung der Ablaufbeziehungen zwischen den Performance-Management-Aktivitäten ist zu beachten, dass es sich nicht um einen einmaligen, sondern um einen fortlaufenden, sich stetig wiederholenden Prozess handelt (vgl. [BuWG04, S. 5]). In der Praxis werden sich die einzelnen Phasen und Prozessschritte auch nicht streng sequenziell durchführen lassen, da es „zahlreiche Rückkopplungen und Phasenüberlappungen“ [Ried00, S. 30] geben wird. Aus diesem Grund ist es zweckmäßig, die Phasen und Aktivitäten des Performance-Management-Prozesses zyklisch – im Sinne eines geschlossenen Führungskreislaufs – anzuordnen anstatt sie linear aneinanderzureihen (vgl. [KüWe03, S. 21]). Zur Strukturierung dieses Führungskreislaufs greifen viele Autoren auf das Prinzip der kontinuierlichen Verbesserung zurück (vgl. [Bred95a, S. 77]), indem sie ihren Prozessmodellen den so genannten Deming-Zyklus zugrunde legen (vgl. [Bred95a, S. 87], [Glei01, S. 69], [Wett02, S. 187]).

W. E Deming unterteilt den Prozess der kontinuierlichen Verbesserung in die vier generischen Phasen *Plan*, *Do*, *Check* und *Act* (siehe Abbildung 22: vgl. [Demi02, S. 88]). Ziel des Deming-Zyklus ist es, die Qualität eines Systems mit jedem Durchlauf der vier Phasen kontinuierlich zu verbessern und weiterzuentwickeln. In der *Plan*-Phase ist zunächst auf Basis des aktuellen Systems ein Plan




Abbildung 22: Deming-Zyklus (in Anlehnung an [Demi02, S. 88])

aufzustellen, der vorgibt, welche Verbesserungsmaßnahmen für das aktuelle System umgesetzt werden sollen. Danach wird der Plan in der *Do*-Phase realisiert, bevor in der *Check*-Phase geprüft wird, ob die Umsetzung des Plans zu dem erhofften Ergebnis geführt hat. Ist kein befriedigendes Ergebnis erzielt worden, ist in der *Act*-Phase aus dem Misserfolg zu lernen und zu entscheiden, welche Verbesserungsmaßnahmen ergriffen werden können (vgl. Demi02, S. 88)]. Der Zyklus beginnt daraufhin aufs Neue.

Die Phaseneinteilung des Deming-Zyklus deckt sich unmittelbar mit den in Abschnitt 3.2.2 unterschiedenen Phasen des generischen Performance-Management-Prozesses. Hierbei entsprechen die beiden Hauptphasen der Planung und Umsetzung der *Plan*- und *Do*-Phase, wohingegen die beiden Teilphasen der Lenkungsphase mit der *Check*- bzw. *Act*-Phase übereinstimmen. Überträgt man die Reihenfolge der Deming-Phasen auf das Prozessmodell, so ergibt sich in einem ersten Schritt folgender einfacher Phasenzyklus (siehe Abbildung 23).

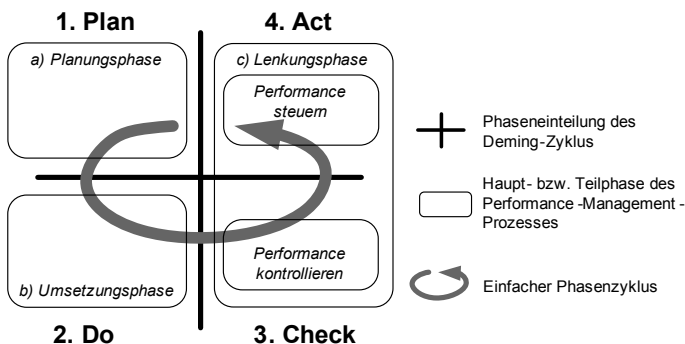


Abbildung 23: Einfacher Phasenzyklus des Performance-Managements

Die Unternehmensperformance ist zunächst anhand von Unternehmensarchitektur und PMS zu planen, bevor beide Modellsysteme in der Umsetzungsphase umgesetzt werden. Erst in der Teilphase der Performance-Kontrolle ist die Effi-

zienz und Effektivität der Unternehmensarchitektur mithilfe der Kennzahlen und Indikatoren des PMS zu überprüfen. Der Phasenzyklus schließt mit der Teilphase der Performance-Steuerung, wo auf Basis des Kontrollergebnisses entschieden wird, ob und durch welche Maßnahmen sich die Unternehmensperformance weiter verbessern lässt. An dieser Stelle gibt die „Kontrolle (...) Informationen über den Zielerreichungsgrad an die Planung zurück“ [StSc93, S. 119] und es beginnt ein neuer Zyklus.

Angesichts der hohen Komplexität von Unternehmen bedarf es kontinuierlich solcher Phasendurchläufe, um ein effektives und effizientes PMS zu entwickeln und umzusetzen. Ein solcher Prozess folgt häufig dem Prinzip von Versuch und Irrtum (vgl. [Bred95b, S. 169]). Um am Ende eines Zyklus die Ursachen einer Performance-Abweichung zu beheben, muss im nächsten Zyklus mindestens eine vorangegangene Phasenaktivität verändert durchgeführt werden. Erzielt ein Geschäftsprozess beispielsweise nicht mehr die geplante Durchlaufzeit, so könnte dies einerseits auf einen krankheitsbedingten Ausfall eines personellen Aufgabenträgers, andererseits auf eine kapazitätsbedingte Überlastung einer Produktionsmaschine zurückgeführt werden. Dieses Performance-Problem ließe sich mit einer Anpassung der Unternehmensarchitektur beheben, indem man etwa die beiden Prozessaktivitäten „Ressourcen spezifizieren“ und „Ressourcen implementieren“ erneut durchführt und zusätzliche personelle bzw. maschinelle Ressourcen als Kapazitätsreserve einsetzt.

Eine Wiederholung des gesamten Phasenzyklus – und somit aller Phasenaktivitäten – ist in der Regel sehr zeit- und kostenintensiv und auch nicht immer notwendig. Eine Performance-Abweichung muss nicht immer durch einen Rücksprung in den Teilprozess der Performance-Gestaltung und durch eine Anpassung der Unternehmensarchitektur behoben werden. Dass bestimmte Performance-Ziele nicht erreicht werden, kann auch daran liegen, dass man die Kennzahlen und Indikatoren des PMS mit unrealistischen Zielwerten versehen hat oder dass schlicht fehlerhafte Messwerte erfasst wurden. Daher muss die Möglichkeit bestehen, den Phasenzyklus fallweise, d.h. in Abhängigkeit von der Art der vermuteten Abweichungsursache und der geplanten Maßnahme, zu verkürzen.

Zur Verkürzung des Phasenzyklus bietet sich – als eine Art „Soll-Bruchstelle“ – die Trennlinie zwischen den Teilprozessen der Performance-Gestaltung und Performance-Lenkung an. Auf diese Weise lässt sich das PMS ändern, ohne dass gleichzeitig eine Anpassung der zugrunde liegenden Unternehmensarchitektur in Erwägung gezogen werden muss.

In Abschnitt 3.2.2 wurden beide Teilprozesse durch die Unterscheidung zwischen Planungs- und Umsetzungsphase in je zwei Teilprozessphasen gegliedert (siehe Abbildung 21). Diese Aufteilung ermöglicht es, innerhalb des Performance-Lenkungsprozesses von der Planungs- in die Umsetzungsphase zu wechseln, um dadurch den Phasenzyklus auch ohne Beteiligung des Gestaltungsprozesses fortzusetzen. Auf diese Weise lässt sich bei der Durchführung einer Verbesserungsmaßnahme der ursprüngliche Phasenzyklus verkürzen, da nicht beide Modellsysteme, sondern nur das PMS neu zu planen und/oder verändert umzusetzen ist.

Der einfache Phasenzyklus spaltet sich somit in zwei ineinander geschachtelte Phasenzyklen auf: einen Lenkungszyklus, der allein vom Teilprozess der Performance-Lenkung durchlaufen werden kann, und einen kombinierten Gestaltungs- und Lenkungszyklus, der sich zusätzlich über den Teilprozess der Performance-Gestaltung erstreckt und diesen mit dem Lenkungsprozess koppelt (siehe Abbildung 24).

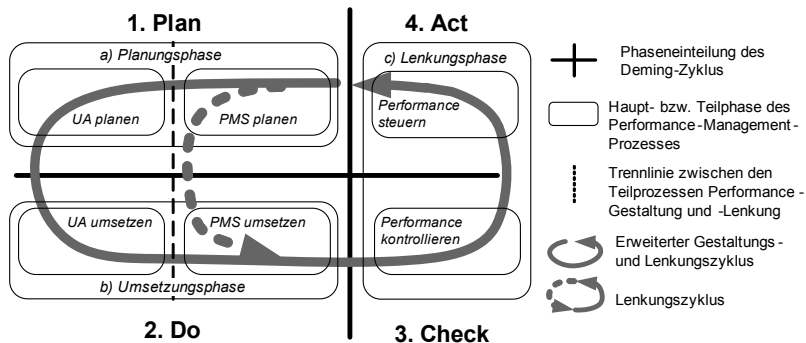


Abbildung 24: Gestaltungs- und Lenkungszyklen des Performance-Managements

Für ein ganzheitliches Performance-Management müssen der Gestaltungs- und Lenkungszyklus nahtlos ineinandergreifen und sorgfältig aufeinander abgestimmt sein. Wann man den Lenkungszyklus verlässt und in den erweiterten Gestaltungs- und Lenkungszyklus wechselt, hängt von der bereits erwähnten Systemeigenschaft der Lenkfähigkeit ab (siehe Abschnitt 3.1.4). Dies ist der Fall, wenn man am Ende des Lenkungsprozesses zur Einschätzung gelangt, dass sich die Performance trotz lenkender Eingriffe aus dem Korridor der zulässigen Aktivitätsfelder heraus entwickelt. Dann muss im Rahmen des erweiterten Gestaltungs- und Lenkungszyklus die Unternehmensarchitektur so umgestaltet werden,

dass die Voraussetzungen für die angestrebte Performance-Entwicklung wieder vorliegen - sei es durch Änderungen des Unternehmensplans, der Geschäftsprozesse oder der Ressourcenspezifikation.

4 Einsatz von Kausalhypothesen im Performance-Management

Dieses Kapitel soll zeigen, auf welche Weise das Performance-Management Kausalinformationen nutzen kann, um die betriebliche Performance zu gestalten und zu lenken. Das Kapitel ist somit eine Art Bindeglied zwischen den vorhergehenden und den nachfolgenden Kapiteln; es schlägt eine Brücke zwischen dem Performance-Management-Prozess als Empfänger von Kausalhypothesen und dem Analyseprozess, der diese entwickelt und überprüft. Abschnitt 4.1 geht zunächst der Frage nach, welche Bedeutung Kausalhypothesen im Performance-Management besitzen und in welcher Form sie dort verwendet werden. Der Abschnitt 4.2 zeigt, auf welche Weise die einzelnen Phasen und Aktivitäten des Performance-Management-Prozesses von Kausalhypothesen profitieren können.

4.1 Kausalhypothesen und ihre Bedeutung für das Performance-Management

Kausalhypothesen werden im Performance-Management zum einen zur Verknüpfung von Zielen in Form von Zweck-Mittel-Beziehungen genutzt, zum anderen, um die Kennzahlen, die die Zielerreichung messen, über kausale Kennzahlbeziehungen zu verbinden. So lassen sich Ziele, Kennzahlen und Ereignisse gegenseitig aufeinander beziehen. Abbildung 25 skizziert diese Zusammenhänge.




Abbildung 25: Zusammenhang zwischen Zweck-Mittel-Beziehungen, kausalen Kennzahlbeziehungen und Kausalhypothesen

Die folgenden Abschnitte stellen die drei Beziehungsarten einzeln vor, indem diese aus Sicht des Informationsempfängers beschrieben werden. Hierbei stehen allerdings weniger die theoretischen Grundlagen kausaler Zusammenhänge im Mittelpunkt als vielmehr das, was den *Umgang* mit Kausalhypothesen auszeichnet und weshalb ihr Einsatz im Performance-Management wesentlich ist. Auf die konzeptionellen Grundlagen von Kausalinformationen geht das darauffolgende Kapitel 5 ein.

4.1.1 Kausalhypothesen

Eine Kausalhypothese ist eine Vermutung, die unter der Annahme getroffen wird, dass sich kein Ereignis ohne Ursache ereignet und dass diese Ursache *ceteris paribus* stets die gleiche Wirkung hervorruft (vgl. [May99, S. 34], [Dow00, S. 15], [BaGr04, S. 19]). Dies bedeutet aber, dass sich kausale Gesetzmäßigkeiten streng genommen weder beobachten noch nachweisen lassen, da *ceteris paribus*-Bedingungen allein in einem experimentellen Umfeld geschaffen werden können (vgl. [Buck01, S. 16]). Diese Frage hat auch den englischen Philosophen David Hume beschäftigt. Für ihn ist Kausalität lediglich das Resultat unserer menschlichen Denkgewohnheit, aus zwei zeitgleich stattfindenden Ereignissen - wie aus dem Zusammenstoßen zweier Billardkugeln - einen Ursache-Wirkungs-Zusammenhang zu folgern (vgl. [May99, S. 5], [BaGr04, S. 18], [Wats05, S. 851]). Aus beobachteten Einzelfällen kausale Gesetzmäßigkeiten abzuleiten, stellt für Hume eine logisch nicht zu rechtfertigende Verallgemeinerung dar.

Kausalhypothesen sind jedoch ein elementarer Teil unserer „geistigen Landkarte“ [Baum02, S. 19] und formen das Weltbild, an dem wir unser Handeln ausrichten (vgl. [Buck01, S. 16]). Stimmt das Kausalmodell unserer geistigen Landkarte nicht mehr mit der beobachteten „kausalen Topographie“ der Realwelt überein, sind wir gezwungen, unsere Kausalhypothesen zu überprüfen und anzupassen. Daher kann unser Umgang mit Ursache und Wirkung nicht statischer, sondern nur dynamischer Natur sein. Hierbei erscheinen einige Ursache-Wirkungs-Zusammenhänge stabiler als andere. Diesen Unterschied erkannten schon vor über 2000 Jahren die Griechen, da sie davon überzeugt waren,

„dass es einen Unterschied gibt zwischen der Natur - die sich nach unveränderlichen Gesetzen verhält - und den Angelegenheiten des Menschen, die per se keiner solchen Ordnung unterliegen, sich aber anhand von auferlegten Strukturen auf verschiedene Weise ordnen und verändern lassen“ [Wats05, S. 212-213].

Zu den naturgesetzlichen Kausalzusammenhängen zählen sämtliche physikalischen, biologischen und chemischen Gesetzmäßigkeiten, die Gegenstand der Naturwissenschaften sind. Naturgesetzliche Zusammenhänge werden oft aus Beobachtung oder den Ergebnissen eines Experiments gefolgert und werden in der Regel in einem streng deterministischen Sinne verwendet (vgl. [Drex00, S. 276]). Im Idealfall lassen sie sich sogar in mathematischen Formeln ausdrücken und werden so berechenbar.

In den Sozialwissenschaften, zu denen auch die Betriebswirtschaft zählt, lassen sich Ursache und Wirkung weit weniger deterministisch verknüpfen. Kausalitäten werden „in einem eher wahrscheinlichkeitstheoretischen Sinn ausgelegt und verwendet“ [Buck01, S. 17]. Ein statistisch berechneter Wahrscheinlichkeitswert gibt an, mit welcher Wahrscheinlichkeit ein bestimmtes Ereignis als Folgewirkung eintritt. Dies ist meist ein Hinweis darauf, „daß wir mit unserem Wissen über die Eigenschaften der sozialen Realitäten noch nicht sehr weit fortgeschritten sind“ [Scha88, S. 62]. Denn in den Sozialwissenschaften ist das Eintreten eines Ereignisses auf menschliches Verhalten zurückzuführen, das - sofern es nicht reflexhaft geschieht - das Ergebnis eines kognitiven Entscheidungs- und Denkprozesses ist (vgl. [Wall01, S. 70], [NaWi02, S. 100]). An diesem Punkt entzündet sich nach wie vor die Diskussion, ob unsere Entscheidungs- und Denkprozesse nicht ebenfalls deterministischen Naturgesetzen folgen¹, und inwieweit es überhaupt legitim ist, von Willensfreiheit zu sprechen (vgl. [Sear06]). Diese, zum Teil philosophische Debatte, wird zwar regelmäßig von neuen Erkenntnissen der Hirnforschung provoziert, sie verliert aber gerade im betrieblichen Kontext an Bedeutung: Hier besteht nicht nur der Wunsch, sondern auch die Möglichkeit, das Verhalten von Mitarbeitern und Geschäftspartnern zu beeinflussen - sei es auf Basis hierarchischer Weisungsbefugnisse, mithilfe von Anreizsystemen oder vertraglich fixierten Verfügungsrechten.²

Wie sich sozial bedingte Kausalzusammenhänge stabilisieren und gestalten lassen, zeigt folgendes Beispiel: Ein überfülltes Schwimmbecken kann auf zweierlei Art und Weise die Ursache dafür sein, dass der Sprungturm in einem Freibad gesperrt wird: Sei es, weil sich der Bademeister auf Basis seiner individuel-

¹ Einen ausführlichen Überblick über die Diskussion zur Erklärung sozialen Handelns geben Schnell et al. (vgl. [SchE95, S. 87-106]).

² Während sich mit der Gestaltung von Anreizsystemen die Principal-Agent-Theorie beschäftigt (vgl. [JeMe76]), sind Verfügungsrechte Gegenstand der Property-Rights-Theorie (vgl. [Coas60]). Beide Theorien zählen zu den neoinstitutionalistischen Ansätzen, die davon ausgehen, „daß das Wissen und die Informationsverarbeitungsmöglichkeiten des Akteurs [zwar] begrenzt sind“ [PiDF98, S. 41], sich sein Verhalten aber durch entsprechende Anreize oder Verfügungsrechte beeinflussen lässt.

len Gefahreinschätzung dazu entschlossen hat, mit der Sperrung der Gefahr eines Badeunfalls vorzubeugen; sei es, weil er einer Dienstvorschrift Folge leistet, die besagt, dass der Sprungturm ab einer bestimmten Zahl von Schwimmern zu sperren ist. Indem die Dienstvorschrift die individuelle Entscheidungsfreiheit des Bademeisters einschränkt, stabilisiert sie den Kausalzusammenhang zwischen der Zahl der Schwimmer und der Sperrung des Sprungturms.

Auch Kilger macht deutlich, dass auch die Zusammenhänge der Kostenrechnung bewusst gestaltet werden: „Kostenfunktionen sind keine naturwissenschaftlich determinierten Gesetzmäßigkeiten, sondern Funktionen, die weitgehend von Entscheidungen abhängig sind. Daher wird durch die Kostenauflösung nicht festgelegt, wie sich die Kostenarten verhalten *werden*, sondern wie sie sich unter Zugrundelegung bestimmter Dispositionen verhalten *sollen*“ [Kilg88, S. 362].

Derartige Dispositionen, mit denen sich Kausalbeziehungen bewusst gestalten lassen, werden bei der Performance-Gestaltung, insbesondere bei der Planung der Unternehmensarchitektur festgelegt (siehe Abschnitt 3.1.3), etwa indem die betrieblichen Soll-Prozesse modelliert und bestimmte Prozessanweisungen und -richtlinien (so genannte Business Rules) den Mitarbeiter verbindlich vorgegeben werden. Kausalhypothesen werden in diesem Zusammenhang als Zweck-Mittel-Beziehungen gebraucht. Diese Beziehungsart wird im folgenden Abschnitt erläutert.

4.1.2 Zweck-Mittel-Beziehungen

Unternehmerisches Handeln orientiert sich ebenso wie menschliches Handeln an Zielen (vgl. [Kups79, S. 1]). Ein Ziel beschreibt einen erwünschten Zustand, der als Ergebnis von Handlungen herbeigeführt werden soll (vgl. [Kups79, S. 15], [Andr75, S. 17]). Aufgabe der Planung ist es, aus dem Ziel Handlungsalternativen abzuleiten und diese in Form von Planzielen zu konkretisieren, die „auf ihre Realisierbarkeit hinsichtlich der erforderlichen Ressourcen, Maßnahmen sowie sonstiger Voraussetzungen [zu prüfen sind]“ [Wild82, S. 80]. Zentrales Kriterium dieser Prüfung ist die Bewertung der Zweckmäßigkeit, also die Frage, ob sich die Handlungsalternativen zur Zielerreichung eignen. Um dies zu beantworten, sind die Wirkungen der Alternativen zu ermitteln und mit dem angestrebten Zielzustand zu vergleichen (vgl. [Hein76, 94], [Kups79, S. 63]). Dies geschieht auf Basis einer Ursache-Wirkungs-Vermutung, die zwischen der Handlung als Ursache und dem Ziel als Wirkung eine Instrumentalbeziehung begründet (vgl. [Kups79, S. 1]), die sich dadurch auszeichnet, „daß die durch Erreichung eines

Unterziels herbeigeführten Ergebnisse (Teil-)Ursachen für die Verwirklichung des Oberziels darstellen“ [Wild82, S. 59]. Oder wie es Berthel formuliert: „Ursachen werden als Mittel benutzt, um erwünschte Wirkungen als Zweck (Ziel) herbeizuführen“ [Bert73, S. 12].

Während eine Kausalbeziehung Ereignisse verknüpft, verbindet eine Zweck-Mittel-Beziehung ein Oberziel (Zweck) mit einem Unterziel (Mittel) und begründet somit eine Rangordnung zwischen den Zielen (vgl. [Kups79, S. 67]). Ist ein Unterziel gleichzeitig das Oberziel einer anderen Zweck-Mittel-Beziehung, bildet sich eine mehrstufige Zweck-Mittel-Hierarchie, deren Zielzustände die „Stationen auf dem Weg der Gesamtzielerreichung“ [Bert73, S. 11] beschreiben. Da jede Zielerreichung die Erfüllung von Aufgaben voraussetzt (vgl. [Bert73, S. 5]), spiegeln sich in einer Zielhierarchie die in einem Unternehmen durchzuführenden Aufgaben (vgl. [Kups79, S. 67]).

Ziele lassen sich nicht nur auf Basis von Kausalzusammenhängen, sondern noch auf eine weitere Art instrumental verknüpfen. Diese Art von Beziehung bildet zwar ebenfalls eine Rangordnung zwischen Ober- und Unterziel, diese Ordnung ist allerdings definitionslogischer und nicht kausaler Natur (vgl. [Hein76, S. 128], [Kups79, S. 33]). Ein Beispiel ist die Rechenvorschrift, dass sich der Gewinn aus der Differenz zwischen Umsatz und Kosten ergibt. Aus dem Oberziel der Gewinnsteigerung leiten sich aufgrund der Definitionslogik – und nicht aufgrund eines empirischen Kausalzusammenhangs – zwei Handlungsalternativen ab: die Kostenreduzierung und die Umsatzsteigerung. Während Heinen in solchen definitionslogischen Zusammenhängen noch schwach begründete Zweck-Mittel-Beziehungen sieht (vgl. [Hein76, S. 129]), sieht Kupsch in ihnen eine eigenständige Art der Instrumentalbeziehung: „Die definitionslogische Aufspaltung eines Oberziels in Unterziele begründet keine Zweck-Mittel-Beziehung, sondern kennzeichnet lediglich Teilelemente der Zielvariable des Oberziels“ [Kups79, S. 36].¹

Neben der Zweck-Mittel-Beziehung werden in der Literatur noch zwei weitere Arten von Zielrelationen unterschieden: die Präferenzbeziehung und die Interdependenzbeziehung (vgl. [Kups79, S. 26]). Die Präferenzbeziehung unterscheidet zwischen Haupt- und Nebenzielen und folgt einer vom Entscheidungsträger vorgenommenen Priorisierung (vgl. [Hein76, S. 107]). Die Ausprägung einer Interdependenzbeziehung lässt sich hingegen vom Entscheidungsträger

¹ Wie in Kapitel 5 noch zu begründen sein wird, folgt diese Arbeit weder der Ansicht von Kupsch noch von Heinen. Definitionslogische Beziehungen können Zweck-Mittel-Beziehungen mittelbar begründen, indem sie den zugrunde liegenden Kausalzusammenhängen die kausale Infrastruktur stellen (siehe Abschnitt 5.2.1.1).

unabhängig bestimmen (vgl. [Hein76, S. 103]), da hierzu nur die zielerreichenden Handlungen und ihre Ergebnisse zu betrachten sind (vgl. [Bert73, S. 74], [Hein76, S. 94]). Je nachdem, ob die Erfüllung des einen Ziels die Erfüllung des anderen Ziels steigert, verringert oder nicht beeinflusst, stehen die Ziele in einer komplementären, konkurrierenden oder indifferenten Beziehung (vgl. [Hein76, S. 94-95]).

Welche Art von Interdependenzbeziehung vorliegt, kann abhängig vom Zielerfüllungsgrad variieren (vgl. [Hein76, S. 104]). Verfolgt man beispielsweise das Ziel, durch Sport sowohl sein Wohlbefinden zu steigern als auch sein Gewicht zu reduzieren, stehen beide Ziele zunächst komplementär zueinander. Betreibt man allerdings exzessiven Sport, reduziert dies zwar weiterhin das Gewicht, möglicherweise verliert man dann allerdings den Spaß am Sport und spürt eine Beeinträchtigung des Wohlbefindens. Spätestens dann stehen die Ziele Gewichtsreduzierung und Wohlbefinden in einer Konkurrenzbeziehung. Dieses Beispiel zeigt, dass die Ausprägungen der Interdependenzbeziehung von den zur Zielerreichung gewählten Aktivitäten und dem Anspruchsniveau der Zielerreichung abhängen. Übertragen auf Unternehmen bedeutet das, dass zwei Ziele in einem Unternehmen komplementär verfolgt werden können, während sie in einem anderen Unternehmen in Konkurrenz zueinander stehen: „aufgrund verschiedener Unternehmungssituationen, Handlungsinstrumente und Zielkonzeptionen“ [Bert73, S. 73].

Zweck-Mittel-Beziehungen setzen eine komplementäre Zielbeziehung voraus (vgl. [Hein76, S. 104], [Kups79, S. 24]). Sie verlieren ihren Zweck-Mittel-Charakter aber, sobald eine komplementäre Zielbeziehung in eine Konkurrenzbeziehung umschlägt. Die Entscheidung, ob eine Zweck-Mittel-Beziehung vorliegt, kann deshalb nur unter Einbezug des Zielinhalts und des angestrebten Zielerreichungsgrads getroffen werden (vgl. [Bert73, S. 12]). Ist man beispielsweise Übergewichtig und möchte sein Wohlbefinden steigern sowie das Gewicht reduzieren, sind beide Ziele anfangs komplementär. Beide Ziele lassen sich nämlich durch sportliche Bewegung erreichen. Der Sport würde seinen Mittelcharakter allerdings spätestens dann verlieren, wenn er exzessiv betrieben wird und man sich aufgrund starken Untergewichts zunehmend unwohl und geschwächt fühlt.

Die Messung des Zielerreichungsgrads erfolgt in Form von Kennzahlen. Auf Basis von Soll-Ist-Vergleichen liefern sie „Informationen über die Zweckmäßigkeit der in der Zielhierarchie berücksichtigten Ursache-Wirkungs-Beziehung“ [Kups79, S. 71]. Welche Rolle Ursache-Wirkungs-Beziehungen zur Begründung kausaler Kennzahlbeziehungen spielen, zeigt der folgende Abschnitt.

4.1.3 Kausale Kennzahlbeziehungen

Eine mit Kennzahlen fundierte Unternehmenssteuerung, wie sie im Performance-Management angestrebt wird, vertraut darauf, dass die Messgrößen die relevanten Sachverhalte erfassen und in konzentrierter Form abbilden. „Jede Kennzahl erfasst aber nur einen engen Ausschnitt der komplexen Realität und stellt demzufolge ein grobes Abbild dieser Realität dar“ [Kütz03, S. 4]. Aus diesem Grund gelangt man durch eine zusammenhangslose Betrachtung einzelner Kennzahlen zu keinem stimmigen, widerspruchsfreien Gesamtbild, auf dessen Basis eine zielgerichtete Unternehmenssteuerung möglich wäre (vgl. [Küpp97, S. 325]). Kennzahlen sollten daher prinzipiell im Verbund mit anderen Kennzahlen betrachtet und zu einem geordneten Kennzahlensystem verknüpft werden (vgl. [Küpp97, S. 318], siehe Abschnitt 2.2.1)

Für finanzielle Kennzahlen sind in der Vergangenheit bereits verschiedene Kennzahlensysteme entwickelt worden, die sich meist an den Größen des Rechnungswesens orientieren, wie sie etwa im Jahresabschluss oder in der Bilanz verwendet werden (vgl. [Reic97, S. 46]). Kennzahlen werden in diesen Systemen entweder durch mathematische Umformungen und Definitionslogik zu rechenbaren Systemen verknüpft (zum Beispiel Vermögen = Anlagevermögen + Umlaufvermögen) (vgl. [Glad01, S. 96]). Vertreter derartiger Kennzahlensysteme sind beispielsweise das Du-Pont- oder das ZVEI-Kennzahlensystem (vgl. [Kups79, S. 87], [Lach79, S. 198], [Reic97, S. 30]).

Einerseits sind solche Rechensysteme dank ihrer mathematischen und definitionslogischen Kennzahlbeziehungen klar strukturiert, andererseits leistet die Analyse ihrer Kennzahlen nur einen begrenzten Beitrag zur Identifizierung von Abweichungsursachen (vgl. [Reic97, S. 48]). Anhand definitionslogischer Kennzahlbeziehungen kann zwar die Zusammensetzung einer Kennzahl aufgezeigt werden, nicht aber die eigentlichen Ursachen ihrer Ausprägung (vgl. [Küpp97, S. 326 u. 329]). Denn indem eine Spitzenkennzahl sukzessive anhand ihrer rechnerischen und definitionslogischen Beziehungen disaggregiert wird, greift man nur auf Informationen zurück, „die auf der höheren Stufe zur Informationsentlastung durch Verdichtung bewusst herausgefiltert worden waren. Man führt aber nicht Informationen über zusätzliche Bestimmungsgrößen in die Analyse ein, sondern deckt vorhandene implizite Informationen auf“ [Glad01, S. 96]. Aus diesem Grund erfüllen Kennzahlensysteme, deren Kennzahlen definitionslogisch verbunden sind, nur eine beschreibende und keine erklärende Funktion;

sie bilden die betriebliche Realität ab, können diese aber nicht erklären (vgl. [Reic97, S. 46-48]).

Möchte man ein Kennzahlensystem konzipieren, das in der Lage ist, auch die Ursachen von Kennzahlenabweichungen zu erklären, müssen die Kennzahlen auf Basis empirischer Kausalzusammenhänge sachlogisch verknüpft werden (vgl. [Lach79, S. 33], [Reic97, S. 51], [Glad01, S. 99]). Zwei Kennzahlen können aber nur dann kausal verknüpft werden, wenn auch zwischen den beiden Sachverhalten, die die Kennzahlen abbilden, ein empirisch nachweisbarer Ursache-Wirkungs-Zusammenhang existiert. Obwohl sich Kausalzusammenhänge einer exakten mathematischen Beschreibung entziehen (vgl. [Glad01, S. 99-100]), sind kausal begründete Kennzahlbeziehungen für das Performance-Management dennoch von großer Bedeutung. Mit ihrer Hilfe können nicht-finanzielle Messgrößen sowohl untereinander als auch mit den Kennzahlen der Finanzsphäre verbunden werden. Nicht-finanzielle Kennzahlen gewinnen dadurch an Aussagekraft und lassen sich leichter interpretieren. Ihre Bedeutung für den finanziellen Unternehmenserfolg erschließt sich aus den Einflusswirkungen, die durch die kausalen Kennzahlbeziehungen explizit dargestellt werden (vgl. [EcPy92, S. 43], siehe Abschnitt 2.2.2).

Bei der Verwendung von kausalen Kennzahlbeziehungen darf aber nicht vergessen werden, dass diese die realen Kausalzusammenhänge ebenso bruchstückhaft abbilden wie eine Kennzahl den eigentlichen Sachverhalt. Kausale Kennzahlbeziehungen können oft nur ein grobes, unvollständiges und deshalb oft nur vorläufiges Abbild realer Kausalzusammenhänge geben. Die eleganten Kennzahlen-Darstellungen, wie sie dem Management als Dashboard von IT-Lösungsanbietern präsentiert werden, suggerieren aber nicht selten das Gegenteil. Zu vergessen, dass es sich auch bei einem Dashboard nur um eine *Hilfsregelstrecke* handelt (siehe Abschnitt 3.1.1.2), kann dazu führen, dass man unfähig ist, auf kritische Vorfälle schnell und angemessen zu reagieren. Dies zeigt folgende Schilderung der Reaktorkatastrophe von Tschernobyl:

„The engineers in the control room looked at the reactor instrumentation. The reactor building and the fire that resulted from the meltdown were not in their direct view from the control room. However, it eventually became obvious to them from their instrumentation that something was wrong with the reactor. But they ‘knew’ that it couldn’t possibly have blown up. They looked outside to see what had happened. Thick on the ground was a layer of black graphite from the reactor core – all of it fearsomely radioactive. Dyatlov, the engineer who saw the black graphite on the ground, could not accept that (...) because he knew that for it to be core graphite was impossible. (...). Although his eyes registered their physical presence, he couldn’t actually see them for

what they were. Even in this deadly situation, what he knew to be true prevented him from seeing what was actually there.” [Pyle03, S. 8]

4.2 Einsatzmöglichkeiten von Kausalhypothesen im Performance-Management-Prozess

Indem sich sowohl Zweck-Mittel- als auch Kennzahlbeziehungen kausal begründen lassen, bieten sich im Verlauf des Performance-Management-Prozesses verschiedene Einsatzmöglichkeiten für Kausalhypothesen. Die beiden folgenden Abschnitte 4.2.1 und 4.2.2 knüpfen daher an das in Abschnitt 3.2 vorgestellte Prozessmodell an, indem sie die Einsatzmöglichkeiten von Kausalhypothesen für die Planungs- und Lenkungsphase vorstellen. In der Umsetzungsphase bieten sich hingegen keine Einsatzmöglichkeiten, da keine neuen Zweck-Mittel- oder Kennzahlbeziehungen mehr zu begründen sind. Die Unternehmensarchitektur und das Performance-Measure-System sind so zu implementieren, wie es in der Planungsphase bereits entschieden wurde.

4.2.1 Einsatzmöglichkeiten in der Planungsphase

Die Planungsphase erstreckt sich über die beiden Teilprozesse der Performance-Gestaltung und -Lenkung. Dieser Prozessstruktur folgend unterteilt sich die Planungsphase in zwei Teilphasen: in die Planung der Unternehmensarchitektur und in die Planung des Performance-Measure-Systems (siehe Abschnitt 3.2.2, Abbildung 21). Welchen Nutzen Kausalhypothesen in beiden Teilphasen stiften können, zeigen die folgenden Abschnitte.

4.2.1.1 Planung der Unternehmensarchitektur

Die Planung der Unternehmensarchitektur beginnt mit der Erstellung des Unternehmensplans (siehe Abbildung 21: a1). Im Unternehmensplan sind das Geschäftsmodell des Unternehmens sowie die auf Basis dieses Modells formulierten Unternehmensstrategien festzuhalten. Das Geschäftsmodell bildet somit den Ausgangspunkt des Strategie- und Zielbildungsprozesses und beschreibt die grundlegenden Kausalzusammenhänge der Unternehmensumwelt und der Märkte, in denen das Unternehmen wertschöpfend tätig werden möchte (vgl. [Kude01, S. 11], [BePi04, S. 448]).

Für die Formulierung gültiger Geschäftstheorien ist das Denken in Ursache-Wirkungs-Beziehungen eine wichtige Voraussetzung (vgl. [Brun99, S. 84]). Ursache-Wirkungs-Vermutungen bilden das Gerüst, an dem sich das unternehmerische Handeln orientiert und mit dessen Hilfe sich Strategien entwickeln, beschreiben und präzisieren lassen (vgl. [Wall01, S. 67], [KaNo04, S. 29]). Oder wie es Kaplan und Norton formulieren: „A Strategy is a set of hypotheses about cause and effect“ [KaNo96a, S. 149]. Die Operationalisierung der Strategien erfolgt, indem strategische Teilziele abgeleitet und unter Berücksichtigung ihrer spezifischen Zweck-Mittel-Beziehungen in ein konsistentes Zielsystem integriert werden (vgl. [Wild82, S. 59]; siehe Abschnitt 4.1.2).

Um die Ursache-Wirkungs-Beziehungen des Geschäftsmodells zu bestimmen, bedarf es einer offenen Diskussion, in der die Führungskräfte und Entscheidungsträger ihre impliziten Annahmen bezüglich unternehmensinterner und -externer Kausalzusammenhänge offen legen (vgl. [EcPy92, 44]). Die so zu Tage geförderten Ursache-Wirkungs-Vermutungen speisen sich zwar primär aus dem subjektiven Erfahrungswissen der Manager (vgl. [Wall01, S. 66]), machen aber „die personenspezifischen Vorstellungen über die zukünftige Strategie explizit“ [Pise04, S. 165]. Erst dann besteht die Chance, diese infrage zu stellen und ein von allen Beteiligten akzeptiertes Geschäftsverständnis zu entwickeln (vgl. [Bago80, S. 75], [Seng03, S. 17]). Dieses gemeinsame Verständnis über das Zusammenspiel von Ursache und Wirkung trägt entscheidend dazu bei, dass sich das Geschäftsmodell, die Strategien und das Zielsystem transparent über die Hierarchieebenen hinweg kommunizieren lassen (vgl. [Kude01, S. 11], [Kump01, S. 163]). Auch bei der Frage der Zielgewichtung geben Kausalhypothesen Orientierung. Zielkonflikte lassen sich auflösen, wenn die Ziele entsprechend ihrer Zweck-Mittel-Beziehungen und der zeitlichen Ordnung der zugrunde liegenden Kausalhypothesen priorisiert werden (vgl. [GoQu90, S. 193]): „If the goals are causally related (e.g., improved quality, customer service, and innovation cause higher profits), then the goals at the beginning of the causal chain must be emphasized over those later in the causal chain“ [LoLa90, S. 326].

Von Relevanz und Bedeutung sind Kausalhypothesen auch beim nächsten Prozessschritt, der Erstellung des Geschäftsprozessmodells (siehe Abbildung 21: a2). Kennt man die kausalen Wechselwirkungen, die zwischen den Phasen und Aktivitäten eines Prozesses bestehen, lassen sich alternative Prozessvarianten hinsichtlich ihrer Effizienz und Effektivität beurteilen. Kausalhypothesen können auch die wechselseitigen Abhängigkeiten zwischen Haupt- und Serviceprozessen abbilden und so zeigen, wie sich ein veränderter Prozessablauf auf einen ande-

ren Prozess auswirkt. Indem Prozesse nicht mehr nur als lineare Abfolge von Prozessschritten gesehen werden, sondern zusätzlich als ein kausal vernetztes Bündel von Aktivitäten, kann der Beitrag, den ein Prozess innerhalb der Unternehmensarchitektur zur Erfüllung des Unternehmensplans leistet, besser verstanden werden.

Dieses Wissen kann beim dritten Prozessschritt zur Spezifikation der Ressourcen genutzt werden (siehe Abbildung 21: a3). Mittels Kausalhypothesen lassen sich sowohl die Beziehungen zwischen den organisatorischen Einheiten aufzeigen (vgl. [Wall01, S. 67]) als auch die Beeinflussung der prozessualen Leistungsfähigkeit durch Wechselwirkungen zwischen maschinellen oder personellen Aufgabenträgern. Derartige Kausalhypothesen können dann bei der Zuordnung von Ressourcen berücksichtigt werden, etwa wenn eine Zuteilung von Schichtarbeitern auf Basis der Erfahrung erfolgt, die jene bereits mit bestimmten Maschinen oder Werkzeugen haben. Auch wenn die Mitglieder von Projektteams danach ausgewählt werden, ob sich ihre Kompetenzen und Fähigkeiten ergänzen, liegt dieser Auswahl die Kausalhypothese zugrunde, dass dies den Wissenstransfer zwischen erfahrenen und weniger erfahrenen Mitarbeitern fördert.

4.2.1.2 Planung des Performance-Measure-Systems

Wie im vorherigen Abschnitt gezeigt wurde, fördert die Diskussion und Klärung impliziter Ursache-Wirkungs-Annahmen die Bildung eines gemeinsamen Geschäfts- und Strategieverständnisses, das zur Planung einer effizienten und effektiven Unternehmensarchitektur benötigt wird. Kausalhypothesen sind aber auch bei der Planung des Performance-Measure-Systems von Bedeutung, da man sie sowohl zur Entwicklung nicht-finanzieller Messgrößen als auch zur Begründung von kausalen Kennzahlbeziehungen nutzen kann.

Obwohl in der Performance-Literatur schon oft über das Design von Performance-Measure-Systemen diskutiert wurde, besteht noch immer kein Konsens darüber, wie sich insbesondere nicht-finanzielle Messgrößen entwickeln lassen (vgl. [SaBH02, S. 1254]). Viele Vorschläge zur Kennzahldefinition sind sehr unspezifisch und vage (vgl. [Glei01, S. 23]) und es fehlt an konkreten Vorgehensweisen, die beschreiben, wie man insbesondere nicht-finanzielle Messgrößen systematisch herleitet (vgl. [Klin99, S. 1]). Dabei ist die Idee nicht-finanzieller Kennzahlen keineswegs neu (siehe Abschnitt 2.1.2). „But the problem is not how to make a case for non-financial measures, since the case has been establis-

hed for some time; rather, the problem is how to devise and elaborate credible measures“ [Ezza92, S. 116].

Eine große Herausforderung stellt die Identifizierung verlässlicher Frühindikatoren dar. Sie lassen sich nicht aus den Kennzahlen der finanzwirtschaftlichen Sphäre ableiten, da sie direkt in den operativen Prozessen der Leistungsebene zu verankern sind (vgl. [Klin99, S. 20]). Da sich Unternehmen aber gerade in ihren operativen Prozessen voneinander unterscheiden, variieren folglich auch die Messgrößen, die als Frühindikatoren in Frage kommen (vgl. [KüWe03, S. 73]). Es ist daher nicht verwunderlich, dass sich viele Führungskräfte trotz umfangreicher Listen an nicht-finanziellen Kennzahlen schwer tun, die richtigen Messgrößen für ihr Unternehmen auszuwählen (vgl. [Ezza92, S. 120], [ItLa04, S. 71]).

Aus diesem Grund sollte bei jeder Messgröße ein klares Verständnis vorhanden sein, *was genau warum* gemessen wird (vgl. [SaBH02, S. 1257]). Ein solches Verständnis können Kausalhypothesen vermitteln. Diese wurden idealerweise bereits bei der Formulierung des Geschäftsmodells, der Strategien und des Zielsystems diskutiert und bieten nun bei der Suche nach geeigneten Messgrößen wichtige Anknüpfungspunkte und Orientierung (siehe Abschnitt 3.2.1.1; vgl. [ShLA00, S. 549], [Hoff00 S. 96], [KaNo04, S. 9]). Denn sind die vermuteten Wechselwirkungen zwischen der nicht-finanziellen Leistungssphäre und der Finanzsphäre bereits in aggregierter Form beschrieben worden, ist es sehr viel leichter, diese „so weit wie möglich zurückzuverfolgen und Bereiche zu definieren, in denen Früherkennungsindikatoren zu suchen sind“ [Müll00, S. 56]. Das explizite Offenlegen und Diskutieren von Ursache-Wirkungs-Annahmen vereinfacht die Suche nach aussagekräftigen Messgrößen und Indikatoren, indem sie den Blick gezielt auf die Sachverhalte und Unternehmensbereiche lenken, wo sich die Auswirkungen negativer wie positiver Performance-Entwicklungen frühzeitig erkennen lassen (vgl. [Töpf01b, S. 70]).

Abbildung 24 zeigt beispielhaft, welcher Zusammenhang zwischen den Zweck-Mittel-Beziehungen der Strategie- und Zielbildung und den kausalen Kennzahlbeziehungen des Kennzahlensystems besteht.

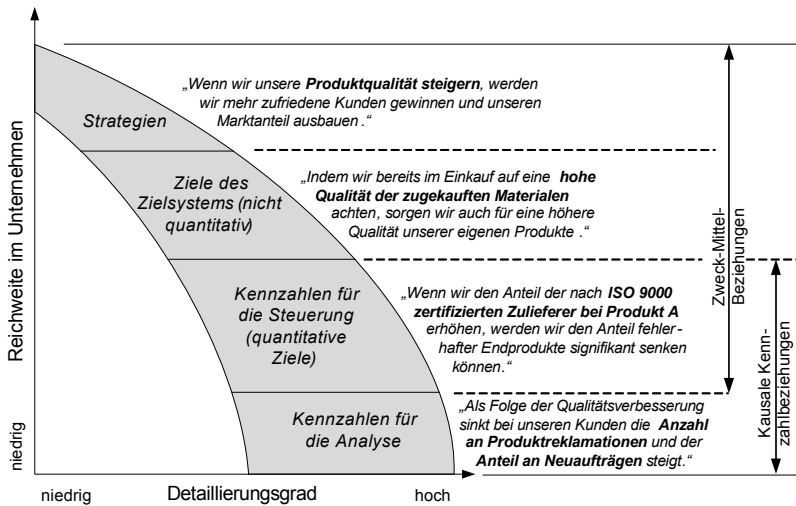


Abbildung 26: Abgrenzung von Zweck-Mittel- und kausalen Kennzahlbeziehungen

Kausale Kennzahlbeziehungen verknüpfen Kennzahlen, die sich zur Steuerung oder zur Analyse des Unternehmensgeschehens verwenden lassen. „Kennzahlen zu Steuerungszwecken haben einen normativen Charakter (Zielcharakter). Sie dienen der Planung und Bewertung von Alternativen, sollen das Verhalten der Handlungsträger beeinflussen und werden für Kontrollen herangezogen“ [Glad01, S. 20]. Qualitative Ziele können durch die Bildung von Steuerungskennzahlen quantifiziert und konkretisiert werden. Die kausalen Kennzahlbeziehungen der Steuerungskennzahlen nehmen somit direkt Bezug auf die Zweck-Mittel-Beziehungen der qualitativen Ziele. Steuerungskennzahlen weisen im Vergleich zu den qualitativen Zielen einen höheren Detaillierungsgrad auf, besitzen dafür aber meist eine geringere Reichweite und einen eingeschränkten Geltungsbereich im Unternehmen. So bezieht sich das vage Ziel, im Einkauf auf höhere Qualität zu achten, zunächst auf den gesamten Einkaufsprozess bzw. -bereich. Die quantitative Zielvorgabe, die Anzahl der nach ISO-9001 zertifizierten Zulieferer zu erhöhen, betrifft indes nur den Teilprozess bzw. Unternehmensbereich, der für die Auswahl von Zulieferern zuständig ist. Die quantitativen Zielvorgaben der Steuerungskennzahlen lassen sich somit sowohl als Teil des Kennzahlensystems als auch als Teil des Zielsystems interpretieren (vgl. [Küpp97, S. 318]).

Analysekennzahlen ergänzen die Steuerungskennzahlen, indem sie Sachverhalte abbilden, die zwar „nicht zum Gegenstand einer systematischen Planung gemacht werden“ [Glad01, S. 17], aber dennoch zur Klärung von Abweichungsursachen bzw. zur Prognose zukünftiger Entwicklungen beitragen. Mithilfe von Analysekennzahlen werden detaillierte Informationen zur Erreichung oder Nicht-Erreichung quantifizierter Zielvorgaben gewonnen. In Abbildung 26 werden die beiden Kennzahlen „Anzahl der Produktreklamationen“ und „Anzahl der Aufträge“ als Indikatoren für die Kundenzufriedenheit und den Erfolg der Qualitätsinitiative verwendet. Beide Messgrößen können nicht als Steuerungskennzahlen verwendet werden, da sie sich aus Unternehmenssicht nur indirekt beeinflussen lassen und maßgeblich von externen Faktoren, wie zum Beispiel der Preispolitik von Wettbewerbern, abhängen.

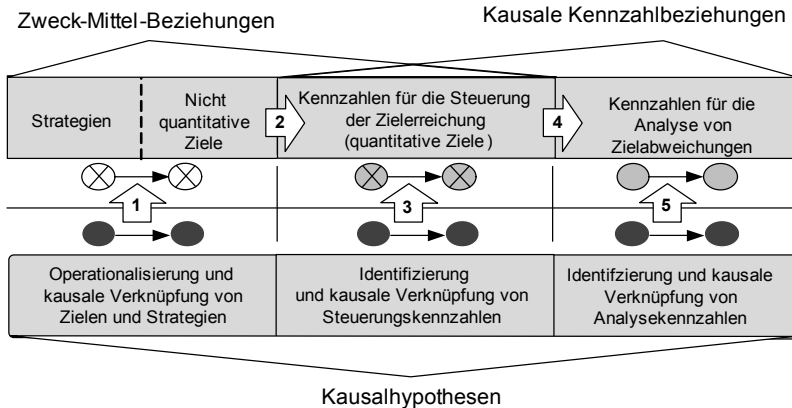


Abbildung 27: Einsatz von Kausalhypothesen zur Begründung von Zweck-Mittel- und kausalen Kennzahlbeziehungen

Abbildung 27 skizziert beispielhaft, wie sich Zweck-Mittel- und kausale Kennzahlbeziehungen auf Basis von Kausalhypothesen formulieren lassen. Zunächst dienen die Kausalhypothesen zur Operationalisierung von Strategien und zur Formulierung qualitativer Ziele (1). Da diese Ziele durch die Steuerungskennzahlen in konkret messbare Zielvorgaben übersetzt werden, sind die Steuerungskennzahlen zunächst direkt aus den qualitativen Zielen des Zielsystems abzuleiten (2). Beziehen sich zwei Steuerungskennzahlen auf unterschiedliche Ziele, die im Zielsystem über eine Zweck-Mittel-Beziehung verknüpft sind, kann daraus

eine entsprechende Kausalbeziehung zwischen den beiden Steuerungskennzahlen abgeleitet werden. Fehlt eine solche Zweck-Mittel-Beziehung, weil sich mehrere Steuerungskennzahlen auf ein einziges Ziel beziehen, sind diese „zielinternen“ Kennzahlbeziehungen auf Basis eigener Kausalhypothesen zu entwickeln (3). Die Kennzahlen zur Analyse lassen sich einerseits parallel zu den Steuerungskennzahlen und deren Kennzahlbeziehungen gewinnen (4), andererseits können weiterführende Ursache-Wirkungs-Beziehungen angenommen und zur Identifikation und kausalen Verknüpfung der Analysekenzahlen verwendet werden (5).

Die Planung des Performance-Measure-Systems wird abgeschlossen, indem für die einzelnen Steuerungskennzahlen die Zielwerte bestimmt werden, die erreicht werden sollen. Bei der Festlegung der Zielwerte sind Zielkonflikte meist nicht zu vermeiden (vgl. [LeEU02, S. 77]; siehe Abschnitt 3.2.2.2 und [Wild82, S. 63], [Bred95a, S. 80]). Ein grundlegendes Problem ist oftmals die Abstimmung der Messgrößen zwischen einzelnen Unternehmensbereichen.

Anhand der kausalen Kennzahlbeziehungen können potenzielle Zielkonflikte bereits im Vorfeld erkannt und bei der Zielwertbestimmung berücksichtigt werden (vgl. [Pise04, S. 186-187]). So muss beispielsweise darauf geachtet werden, dass bei einer Erhöhung finanzieller Zielvorgaben auch die Zielwerte nicht-finanzieller Steuerungsgrößen entsprechend angepasst werden (vgl. [BMW+00, S. 11]). Soll etwa die Messgröße des *Economic Value Added* um 10% erhöht werden, kann anhand der definitions- und sachlogischen Kennzahlbeziehungen nachvollzogen werden, welche unter- bzw. nachgeordneten Steuerungsgrößen ebenfalls mit höheren Zielwerten versehen werden müssen. Sind zudem die Intensitäten der Wirkungsbeziehungen bekannt, können die Zielwerte der Messgrößen so aufeinander abgestimmt werden, dass ihre insgesamt resultierende Wirkung im Falle einer positiven Zielerreichung zu dem erwünschten Endergebnis führt. Auf diese Weise lassen sich übertriebene und unrealistische Zielvorgaben erkennen und von vornherein vermeiden. Eccles und Pyburn haben schon 1992 darauf hingewiesen, dass man sich vor der Formulierung von Qualitätszielen zunächst folgende Fragen stellen muss: „How long does it take for improvements in quality to lead to increased customer satisfaction? How long does it take for improvements in customer satisfaction to lead to increased profitability? Is there a point at which improvements in quality no longer lead to increased customer satisfaction?“ [EcPy92, S. 42]. Dass es sich lohnt, solche Fragen auch zu beantworten, indem man die Annahmen über Ursache und Wirkung offen dis-

kutiert und die Kennzahlbeziehungen überprüft, zeigt folgendes Beispiel aus der Telekommunikationsbranche:

„Um die bestehenden Kunden zu halten, setzte die Firma sich zum Ziel, jeden einzelnen zu 100% zufrieden zu stellen. Die Unternehmensleitung versuchte aber niemals herauszufinden, ob es überhaupt einen Zusammenhang gab zwischen dem Zufriedenheitsgrad eines Kunden und dem Gewinn, den dieser einbrachte. Wir fanden heraus, dass der erwartete Zusammenhang tatsächlich bestand – aber nur bis zu einem gewissen Grad. Kunden, die 100-prozentig zufrieden waren, gaben nicht mehr Geld aus als Kunden, die nur 80% zufrieden waren.“ [ItLa04, S. 76]

4.2.2 Einsatzmöglichkeiten in der Lenkungsphase

Hat man sowohl die Ziele, Prozesse und Ressourcen der Unternehmensarchitektur als auch die Kennzahlen des Performance-Measure-Systems geplant und umgesetzt, gilt es in der Lenkungsphase die Performance zu kontrollieren und zu steuern. Dass auch die beiden Teilphasen der Performance-Kontrolle und -Steuerung von verlässlichen Kausalinformationen profitieren können, zeigen die folgenden beiden Abschnitte.

4.2.2.1 Kontrolle der Performance

Bei der Erfassung von Performance-Daten (siehe Abbildung 21: c1) spielen Kausalhypothesen und kausale Kennzahlbeziehungen keine Rolle. Es handelt sich um eine Routineaufgabe, die nach Möglichkeit automatisiert und nur in Ausnahmefällen manuell durchgeführt werden sollte. Gegenstand, Zeitpunkt und Frequenz der Messgrößenerfassung sind bereits in den Teilphasen der Planung und Umsetzung des Performance-Measure-Systems festgelegt worden. Da sich der Entscheidungs- und Handlungsspielraum in diesem Prozessschritt auf ein Minimum reduziert, sind Kausalinformationen weder von Vorteil noch von Nutzen.

Im Gegensatz zur Erfassung der Messwerte lässt sich die empfängerorientierte Aufbereitung der Performance-Daten (siehe Abbildung 21: c2) in sehr viel geringerem Maße automatisieren. Im Vordergrund steht die Suche nach entscheidungsrelevanten Performance-Abweichungen und deren Ursachen. Hierzu ist zunächst zu entscheiden, *welche* Messgrößen *wie* (zum Beispiel mit Soll-Ist-, Wird-Ist-, Ist-Ist-Vergleichen; siehe Abschnitt 3.2.2.2) zu vergleichen sind. Aufgrund der zahlreichen Dimensionen, anhand derer sich die Ausprägungen der Messgrößen sowohl inhaltlich als auch zeitlich differenzieren und aus-

werten lassen, ist man einer unüberschaubaren Anzahl kombinatorischer Kontroll- und Vergleichsmöglichkeiten ausgesetzt. Greift man bei der Auswertung aber auf die bereits im Vorfeld geknüpften Kennzahlbeziehungen zurück, lässt sich die Anzahl der Kennzahlenvergleiche auf ein praktikables Maß reduzieren (vgl. [Hoff00, S. 210]). Denn vorrangig sollten die Messgrößen gemeinsam ausgewertet werden, die über definitions- und sachlogische Beziehungen verbunden sind (vgl. [SaBH02, S. 1257]).

So lassen sich mithilfe definitionslogischer Kennzahlbeziehungen zunächst die Kenngrößen identifizieren, die aufgrund der rechnerischen Zusammensetzung die Ausprägung einer aggregierten Kennzahl bestimmen. Um konkrete Hinweise auf die Ursachen einer Messwertabweichung zu erhalten, müssen zusätzlich zu den definitionslogischen Kennzahlbeziehungen auch die kausalen Beziehungen der Messgrößen verfolgt werden (vgl. [Küpp97, S. 326]). Über kausale Kennzahlbeziehungen verweist eine Kennzahl auf ihren erweiterten Kontext und zeichnet die Analysepfade vor, denen man bei einer Ursachenanalyse folgen sollte. Dadurch gewinnt man ein klareres Bild von den Bestandteilen eines Performance-Problems (vgl. [SaBH02, S. 1256]).¹

Obwohl „Ursache-Wirkungsbeziehungen keine Automatismen darstellen, die unbedingt in qualitativ wie quantitativ vorhersehbarer Weise auch eintreten“ [Wall01, S. 69 u. 73], ist ihre Betrachtung schon allein deshalb notwendig, weil sich mit ihnen die Bedeutung und die Relevanz einzelner Messgrößen erschließen lassen (vgl. [Küpp97, S. 322], [BePi04, S. 449], [ItLa04, S. 75]).

Hat man sowohl die Performance-Abweichungen als auch die zugrunde liegenden Ursachen identifiziert, sind im darauf folgenden Prozessschritt die Performance-Measures zu bewerten (siehe Abbildung 21: c3). Damit für die Planung und Einleitung von Korrekturmaßnahmen noch ausreichend Zeit bleibt, sollten die Messwerte möglichst frühzeitig eine Gefährdung der Zielerreichung anzeigen. Es muss abgeschätzt werden, ob aus den Performance-Abweichungen ein konkreter Handlungs- bzw. Entscheidungsbedarf resultiert. Dieser besteht etwa dann, wenn man angesichts der erhobenen Messwerte Grund zur Annahme hat, dass die Erreichung eines Sach- oder Formalziels gefährdet ist. Dies lässt sich mit einer Wirkungsanalyse feststellen, bei der man die Auswirkungen einer Performance-Abweichung auf Basis von Kausalhypothesen prognostiziert. Ist der

¹ Hoffmann zeigt am Beispiel des Flughafen Hamburg, wie Kausalmodelle zur Reduzierung der Analysekomplexität beitragen. Statt Kennzahlen und Indikatoren ausschließlich statisch zu betrachten, versucht man beim Flughafen Hamburg, die dynamische Entwicklung und die Ausprägungen der Messwerte auf Basis ihrer kausalen Verknüpfungen zu erklären (vgl. [Hoff00, S. 208-209]).

Zusammenhang zwischen finanziellen und nicht-finanziellen Messgrößen klar und offen diskutiert worden, gelangt man sehr viel schneller zu einer einheitlichen Bewertung der Performance-Größen (vgl. [EcPy92, S. 43]) und der Entscheidungsprozess wird „nicht von einer Flut personenindividueller Vermutungen blockiert“ [BePi04, S. 449]. Kausalhypothesen geben „in Form von ‚Wenn-Dann‘-Formulierungen Auskunft darüber (...), wie die Ausprägung einer Kennzahl das Risiko verändert“ [Stei03, S. 636]. Sind Frühindikatoren über Kausalbeziehungen in das Kennzahlensystem eingebunden, lässt sich die zukünftige Geschäftsentwicklung eines Unternehmens besser voraussagen (vgl. [GSGK02, S. 344], [Pise04, S. 173-174]).

4.2.2.2 Steuerung der Performance

Allein durch ihre Messung verbessert sich die Performance eines Unternehmens noch nicht. Die Messergebnisse müssen in die Planung einfließen und die gewonnenen Erkenntnisse in konkrete Maßnahmen umgesetzt werden (vgl. [Müll98, S. 42], [Ried00, S. 66]). Vielen Unternehmen gelingt diese Verknüpfung zwischen Planung und Performance-Messung nicht (vgl. [Hach02, S. 1394]). Hat man jedoch ein Verständnis über die Wechselwirkungen zwischen den Messgrößen und ihrer zugrunde liegenden Ursache-Wirkungs-Zusammenhänge entwickelt, dann kann man damit die Performance eines Unternehmens nicht nur besser bewerten, sondern auch die zukünftige Entwicklung des Unternehmens wirkungsvoll steuern (vgl. [Schw02, S. 171]).

Nachdem man im vorherigen Prozessschritt den Einfluss einzelner Performance-Abweichungen auf die Zielerreichung antizipiert und das daraus resultierende Geschäftsrisiko abgeschätzt hat, müssen nun Korrektur- und Anpassungsmaßnahmen geplant und durchgeführt werden (siehe Abbildung 21: c4 und c5). Die Maßnahmen können in zwei Richtungen wirken: Entweder man beseitigt die in der Vergangenheit wirksam gewordenen Ursachen einer Performance-Abweichung oder man versucht, deren negative Auswirkung auf die zukünftige Zielerreichung durch korrigierende Steuerungseingriffe zu kompensieren. Obwohl die Beseitigung der Ursachen zweifelsohne die nachhaltigere Alternative ist, sind Kompensationsmaßnahmen dennoch einziges Mittel zum Zweck, falls die identifizierten Problemursachen außerhalb des Einflussbereichs des Unternehmens liegen. Schmäkelt beispielsweise ein Konkurrent durch seine aggressive Preispolitik den eigenen Marktanteil und Umsatz, könnte dieser

Effekt im Gegenzug mit einer Marketingkampagne in Verbindung mit einer Qualitäts- und Serviceoffensive kompensiert werden.

Auf Basis von Kausalhypothesen lassen sich die Stellhebel für effektive Maßnahmen identifizieren (vgl. [SaBH02, S. 1257]). Somit kann einerseits die „Wirkung strategischer Initiativen auf den Unternehmenswert“ [Brun99, S. 88] abgeschätzt werden, andererseits lassen sich auch Einzelmaßnahmen planen, die zwar zunächst nur auf operativer Ebene wirken, aber im Verbund einen ebenso positiven wie nachhaltigen Effekt aufweisen können. Das Beispiel eines Fast Food-Restaurants zeigt, wie kausale Wirkungskennntnisse die Effektivität geplanter Maßnahmen steigern können:

„Bevor das Unternehmen sein Kausalmodell entwickelte, definierte es die Mitarbeiterfluktuation als einen Schlüsselindikator. Denn das Management glaubte, dass eine starke Mitarbeiterbindung ein Zeichen für eine hohe Zufriedenheit und starke Motivation sei, was wiederum den Kundenservice verbessern und schließlich die Gewinne erhöhen würde. (...) Spätere Analysen ergaben aber, dass die Rentabilität von verschiedenen Restaurants mit gleicher Fluktuationsrate drastisch variierte. (...) Der Unterschied in der Rentabilität hing aber von der Fluktuation bei den höheren Angestellten ab, nicht von der Dauer der Unternehmenszugehörigkeit der einfachen Servicekräfte.“ [ItLa04, S. 74-75]

Das Unternehmen nutzte diese Informationen, um die kostenintensiven Programme zur Mitarbeitermotivation, wie etwa Bonuszahlungen und außertarifliche Arbeitgeberleistungen, auf die Gruppe der höheren Angestellten zu beschränken. Dies führte zu Kosteneinsparungen gegenüber dem ursprünglichen Vorhaben, die Programme auf die gesamte Belegschaft auszuweiten (vgl. [ItLa04, S. 75]).

Inwieweit Kausalhypothesen den letzten Prozessschritt - die Umsetzung der Maßnahmen (siehe Abbildung 21: c5) - unterstützen, hängt vom weiteren Verlauf des Performance-Management-Prozesses ab. Je nachdem, ob der Lenkungszyklus oder der erweiterte Gestaltungs- und Lenkungszyklus durchlaufen wird (siehe Abschnitt 3.2.3), können Kausalhypothesen zur Anpassung des Performance-Measure-Systems oder der Unternehmensarchitektur genutzt werden (siehe Abschnitt 4.2.1).

Ob der in diesem Kapitel beschriebene Einsatz von Zweck-Mittel- und kausalen Kennzahlbeziehungen dem Performance-Management nutzt, hängt entscheidend von der Qualität der zugrunde liegenden Kausalhypothesen ab. Die im Performance-Management verwendeten Kausalhypothesen sind deshalb kritisch zu hinterfragen. Mit welchen Methoden sich Kausalhypothesen evidenzbasiert entwickeln und überprüfen lassen, zeigt das folgende Kapitel 5. Im darauf folgenden Kapitel 6 werden diese Methoden als Gestaltungsoptionen eines Analysepro-

zesses beschrieben, der dem Performance-Management-Prozess die benötigten Kausalinformationen bereitstellt.

5 Grundlagen der Entwicklung und Überprüfung von Kausalhypothesen

"Diese Welt und die jenseitige Welt gebären ständig Neues: jede Ursache ist eine Mutter, ihre Wirkung das Kind. Wenn die Wirkung geboren ist, wird auch sie zur Ursache und gebiert wunderbare Wirkungen. Diese Ursachen sind die aufeinanderfolgenden Generationen, aber man braucht schon ein scharfes Auge, um die Glieder in ihrer Kette zu erkennen." Rumi zitiert nach [From04, S. 7]

Dieses Kapitel soll das Auge für Ursache-Wirkungs-Zusammenhänge schärfen. Hierzu werden die grundlegenden Konzepte und Methoden vorgestellt, auf die ein Analyseprozess bei der Entwicklung und Überprüfung von Kausalhypothesen zurückgreifen kann. Bevor in Kapitel 6 die Gestaltungsoptionen dieses Analyseprozesses im Detail vorgestellt werden, sind diese in Abschnitt 5.1 zunächst zu entwickeln. In Abschnitt 5.2 wird mit dem kausalanalytischen Architekturmodell ein integriertes Modellsystem für die evidenzbasierte Kausalanalyse entworfen. Auf dieses Modellsystem greifen die Gestaltungsoptionen des Analyseprozesses bei der Entwicklung und Überprüfung von Kausalhypothesen zurück. Zum Abschluss dieses Kapitels werden in Abschnitt 5.3 die grundlegenden Verfahren und Methoden der datenzentrierten Kausalanalyse erläutert.

5.1 Entwicklung der Gestaltungsoptionen

In diesem Abschnitt sollen Möglichkeiten zur Gestaltung eines Analyseprozesses aufgezeigt werden, der Kausalhypothesen evidenzbasiert entwickelt und überprüft. Vor der eigentlichen Entwicklung der Gestaltungsoptionen sind in Abschnitt 5.1.1 zunächst die Anforderungen zu spezifizieren, die an die vom Analyseprozess generierten Kausalinformationen zu stellen sind. Aus diesen Anforderungen bezüglich der Leistung des Analyseprozesses ergeben sich Implikationen für dessen Gestaltung, die in Abschnitt 5.1.2 erläutert werden. Sie bilden zusammen mit den Anforderungen an die Kausalinformationen den Ausgangspunkt für die Entwicklung der Gestaltungsoptionen. Hierzu werden in Abschnitt 5.1.3 die konzeptionellen Grundlagen von Kausalinformationen

untersucht, bevor in Abschnitt 5.1.4 die methodischen Grundlagen ihrer Entwicklung und Überprüfung erarbeitet werden. Die methodischen und konzeptionellen Grundlagen bilden schließlich den äußeren Rahmen für die Gestaltung des Analyseprozesses. Abbildung 28 fasst diesen Entwicklungspfad zusammen und zeigt, wie die folgenden Abschnitte inhaltlich aneinander anknüpfen.

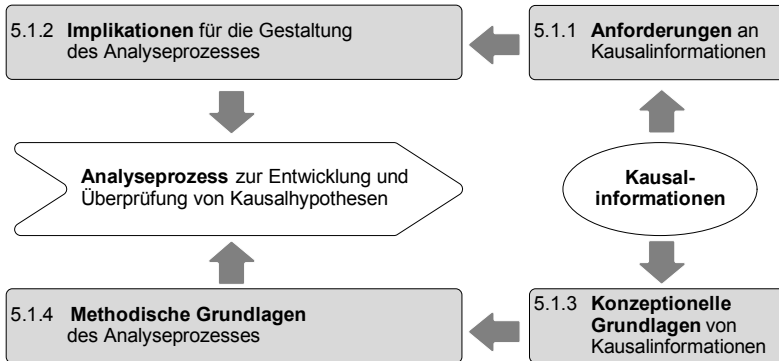


Abbildung 28: Methodisches Vorgehen zur Entwicklung der Gestaltungsoptionen

5.1.1 Anforderungen an Kausalinformationen

Ziel des Analyseprozesses ist es, Kausalinformationen bereitzustellen, die dem Performance-Management zu einer besseren Performance-Gestaltung und -Lenkung verhelfen sollen. Um dies zu gewährleisten, müssen die Kausalinformationen bestimmte Anforderungen erfüllen, die sich an den Kriterien orientieren, mit denen auch die Ergebnisse von Data-Mining-Analysen¹ zu beurteilen sind:

- *Gültigkeit:* Die Kausalaussage muss inhaltlich richtig sein und einen wahren Sachverhalt widerspiegeln.
- *Neuheit:* Dem Informationsempfänger ist der Ursache-Wirkungs-Zusammenhang unbekannt.
- *Verständlichkeit:* Der Informationsempfänger kann den Kausalzusammenhang nachvollziehen.

¹ Data-Mining ist eine datengetriebene Analyse, deren Verfahren in Abschnitt 5.3.1 vorgestellt werden. Die vier Kriterien werden im Data-Mining-Kontext verwendet, um die Interessantheit der Analyseergebnisse zu bewerten (vgl. [FrPM91, S. 4], [MüHS98]).

- **Nützlichkeit:** Die Kausalinformation unterstützt den Informationsempfänger bei der Erreichung eines Ziels bzw. der Lösung eines Problems.

Zwischen den vier Kriterien besteht folgendes Abhängigkeitsverhältnis: Eine Kausalinformation ist für den Informationsempfänger nur dann von Nutzen, wenn der Kausalzusammenhang sowohl gültig, verständlich als auch neu ist. Das Fehlen einer dieser Eigenschaften führt dazu, dass man die Kausalinformation entweder nicht verwenden kann (fehlender Neuigkeitswert), nicht verwenden will (fehlende Verständlichkeit) oder dass man bei der Verwendung der Information Gefahr läuft, falsch zu entscheiden und zu handeln (fehlende Gültigkeit). Dagegen kann ein Kausalzusammenhang gültig sein, obwohl er vom Empfänger nicht verstanden wird oder der Zusammenhang bereits bekannt ist. Ebenso ist es möglich, dass dem Empfänger eine neue Kausalinformation plausibel und verständlich erscheint, obwohl diese inhaltlich falsch ist. Die drei Basiskriterien der Gültigkeit, Neuheit und Verständlichkeit können somit unabhängig voneinander erfüllt sein. Das Kriterium der Nützlichkeit setzt die Erfüllung der drei Basiskriterien zwar voraus, impliziert aber zusätzlich, dass die Kausalinformation den Informationsempfänger bei der Zielerreichung bzw. Problemlösung unterstützt. Das bedeutet, dass eine Kausalinformation lediglich eine spezielle Art von Information ist und deshalb ebenfalls als „zweckorientiertes Wissen“ [Witt59, S. 14] zu definieren ist. Abbildung 29 fasst diese Abhängigkeiten zusammen.

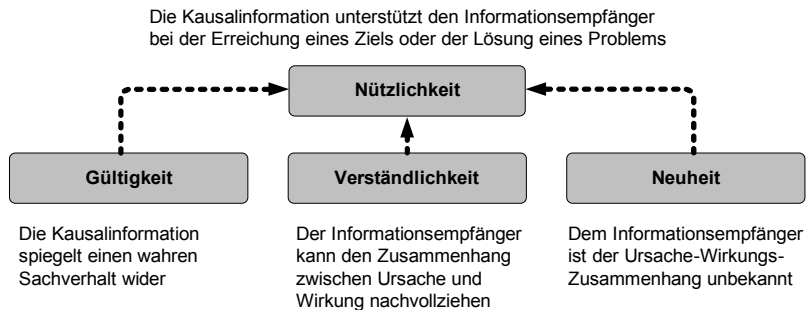


Abbildung 29: Anforderungen an Kausalinformationen

Die Forderung nach gültigen, verständlichen, neuen und nützlichen Kausalinformationen wirft nun die Frage auf, wie der Analyseprozess solche Informationen bereitstellen kann und welche Implikationen sich aus diesen Forderungen für seine Gestaltung ergeben.

5.1.2 Implikationen für die Gestaltung des Analyseprozesses

Von den vier Gütekriterien lässt sich allein die Frage nach der Gültigkeit einer Kausalinformation unabhängig vom Informationsempfänger beantworten. Ob eine Kausalinformation hingegen neu, verständlich oder nützlich ist, kann nur zusammen mit dem Informationsempfänger beantwortet werden.

Ob eine Kausalinformation neu ist, lässt sich nur vor dem Hintergrund der bereits vor der Analyse bekannten Informationen beantworten. Dies impliziert, dass man sich mit dem Informationsstand, dem Vorwissen des Informationsempfängers, auseinandersetzt. Die Informationen des Informationsempfängers können in zwei Kategorien eingeteilt werden:

- Die Informationen der *ersten Kategorie* geben Auskunft darüber, zwischen welchen Ereignissen ein Ursache-Wirkungs-Zusammenhang vermutet wird oder sogar als sicher gilt.
- In die *zweite Kategorie* fallen Informationen, die angeben, als wie sicher ein Kausalzusammenhang gilt und welche Hinweise auf seine Gültigkeit, so genannte Evidenzen, vorliegen.

Gemäß der ersten Kategorie kann eine Kausalinformation neu sein, falls zwei Ereignisse miteinander verknüpft werden, zwischen denen bislang keine Ursache-Wirkungs-Beziehung vermutet wurde. Gemäß der zweiten Kategorie ist eine Kausalinformation auch dann neu, wenn ein bereits bekannter, aber bislang nur vermuteter Kausalzusammenhang durch einen besser begründeten, sichereren Zusammenhang ersetzt wird. Um unnötigen Aufwand bei der Suche nach Kausalzusammenhängen zu vermeiden, muss der Informationsstand des Empfängers in beiden Kategorien abgefragt werden. Hinsichtlich des Kriteriums der Neuheit stellt sich deshalb bei der Gestaltung des Analyseprozesses folgende Frage:

- *Auf welche Weise lässt sich der Informationsstand des Empfängers in die Suche nach neuen Kausalinformationen einbeziehen?*

Indem man die bereits bekannten Informationen frühzeitig in die Analyse einbezieht, bekommt man Hinweise auf Lücken im Evidenzgebäude des Empfängers. Solche Wissenslücken können die Suche nach neuen Kausalzusammenhängen oder Evidenzen in eine bestimmte Richtung lenken und zur Eingrenzung des Analysebereichs genutzt werden. Um Wissenslücken im Informationsstand des

Empfängers zu identifizieren, benötigt man Kriterien, anhand derer sich unbegründete von begründeten Kausalannahmen unterscheiden lassen.

Dies entspricht der Forderung, die sich auch aus dem Kriterium der Gültigkeit ergibt. Um zwischen gültigen und ungültigen Kausalinformationen unterscheiden zu können, benötigt man Evidenzen. Aus methodischer Sicht wirft dies folgende Frage auf:

- *Welche Evidenzen sind zur Begründung eines Kausalzusammenhangs notwendig und mit welchen Verfahren lassen sich diese erzeugen?*

Anstatt nur unbegründete Kausalannahmen des Informationsempfängers zu überprüfen und Kausalinformationen der zweiten Kategorie zu liefern, muss der Analyseprozess auch in der Lage sein, neue Kausalannahmen im Sinne der ersten Kategorie zu entwickeln. Andernfalls würde der Informationsempfänger nur in dem bestärkt, was er ohnehin schon vermutet hatte.

Damit ist allerdings folgende Schwierigkeit verbunden: Um einen hohen Neuigkeitswert zu erhalten, müssen die entwickelten Kausalannahmen zwar abseits des bereits Bekannten und Vermuteten liegen, aber sie müssen dennoch von Anfang an ausreichend plausibel sein, um die daran anschließende Suche nach Evidenzen zu rechtfertigen. Da Kausalannahmen nicht mehr auf Basis von Spekulation, Assoziation oder Intuition getroffen werden sollen, muss bei der Entwicklung von Kausalannahmen ein Mittelweg zwischen dem Kriterium der Neuheit und der geforderten Anfangsplausibilität gefunden werden. Der Analyseprozess muss in der Lage sein, neue Kausalinformationen auf der Grundlage bereits bekannter und gesicherter Informationen zu entwickeln.

Die auf diese Weise entwickelten Kausalannahmen werden im Folgenden als Kausalhypothesen bezeichnet. Eine Kausalhypothese ist im Gegensatz zu einer Kausalannahme, die das Resultat einer Spekulation, Assoziation oder Intuition ist, systematisch entwickelt und zeichnet sich durch ihre Anfangsplausibilität aus (vgl. [Scha88, S. 27-28]). Daher muss bei der Gestaltung des Analyseprozesses folgende Frage beantwortet werden:

- *Mit welchen Verfahren lassen sich neue Kausalhypothesen entwickeln?*

Das nächste Kriterium - die Verständlichkeit - impliziert, dass sich verständliche von unverständlichen Kausalinformationen unterscheiden lassen. „Einen Vorgang zu verstehen heißt: ihn erklären zu können“ [Scha79, S. 127]. Ein Kausalzusammenhang ist erst dann verständlich, wenn auch nachzuvollziehen ist, wie und warum eine Ursache eine bestimmte Wirkung hervorruft. Unter diesem Aspekt ist zum Beispiel der von der Chaosforschung postulierte Kausalzusammenhang

menhang unverständlich, dass der Flügelschlag eines Schmetterlings die Ursache für einen Wirbelsturm sein kann. Was fehlt, ist eine schlüssige Erklärung, die verdeutlicht, wie eine solch kleine Ursache eine so große Wirkung hervorrufen kann. Doch wie und womit lässt sich ein Kausalzusammenhang erklären?

An dieser Stelle offenbart sich der rekursive Charakter kausaler Erklärungen: Verständliche Kausalinformationen bedürfen verständlicher Erklärungen. Ist die Erklärung selbst unverständlich, bedarf es einer Erklärung der Erklärung. So kann sich Erklärung an Erklärung reihen - so lange, bis eine für die Erklärung des Kausalzusammenhangs ausreichende Verständnistiefe erreicht ist. Wann diese Tiefe erreicht wird, hängt vom Informationsstand des Empfängers ab. Denn die Erklärung ist das fehlende Bindeglied, das die Kausalinformation mit dem Vorwissen des Empfängers verknüpft. Die Erklärung schließt eine beim Empfänger vorhandene Wissenslücke, die ihn bislang daran gehindert hat, den kausalen Wirkmechanismus zu verstehen. Ideal wäre es, wenn man sich bei der Erklärung eines Kausalzusammenhangs auf dieselben Evidenzen stützen könnte, die auch die Gültigkeit des Zusammenhangs belegen. Hinsichtlich des Kriteriums der Verständlichkeit ist bei der Gestaltung des Analyseprozesses daher folgende Frage zu beantworten:

- *Wie können die Evidenzen und der Informationsstand des Empfängers bei der Erklärung von Kausalzusammenhängen berücksichtigt werden?*

Hat man neue, gültige und verständliche Kausalinformationen bereitgestellt, so ist damit zwar die Voraussetzung für das vierte und letzte Kriterium, die Nützlichkeit erfüllt, garantiert ist diese damit noch nicht. Nützlich ist eine Kausalinformation erst dann, wenn sie den Informationsempfänger bei der Erreichung eines Ziels oder der Lösung eines Problems unterstützt. Um dies zu gewährleisten, muss der Analyseprozess stets den beabsichtigten Verwendungszweck der Information im Auge behalten, da sich an diesem die Nützlichkeit bemisst. Zusammen mit dem Verwendungszweck ist vor der eigentlichen Analyse auch der Analysebereich festzulegen, über den Kausalinformationen benötigt werden. Hinsichtlich der Nützlichkeit stellt sich bei der Gestaltung des Analyseprozesses daher folgende Frage:

- *Wie können Anwendungskontext und Verwendungszweck der Kausalinformation spezifiziert werden, um die Nützlichkeit der bereitgestellten Kausalinformationen zu beurteilen und sicherzustellen?*

In diesem Abschnitt wurden die Problemstellungen skizziert, die aus der Forderung nach neuen, verständlichen, gültigen und nützlichen Kausalinformati-

onen resultieren. Für diese Problemstellungen müssen die zu entwickelnden Gestaltungsoptionen Lösungen anbieten. Abbildung 30 fasst die Anforderungen an Kausalinformationen und die daraus resultierenden Implikationen für die Gestaltung des Analyseprozesses zusammen:

Auf welche Weise kann der Anwendungskontext der Kausalinformation spezifiziert werden, um die Nützlichkeit der Information zu beurteilen und sicherzustellen?

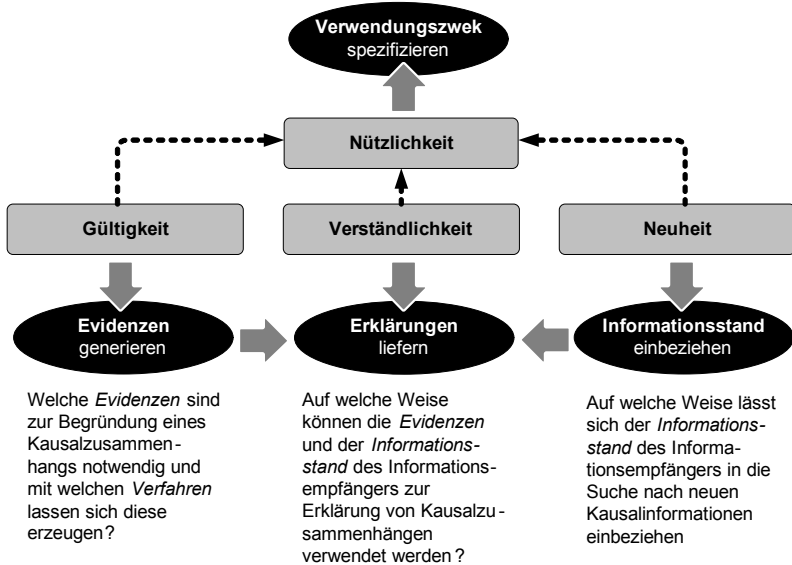


Abbildung 30: Anforderungen an die Gestaltung des Analyseprozesses

5.1.3 Konzeptionelle Grundlagen von Kausalinformationen

Nachdem in den beiden vorangegangenen Abschnitten die Anforderungen an Kausalinformationen und anschließend die daraus resultierenden Implikationen für die Prozessgestaltung erläutert wurden, widmet sich dieser Abschnitt den konzeptionellen Grundlagen von Kausalinformationen. In Abschnitt 5.1.3.1 wird zunächst geklärt, durch welche Wesensmerkmale sich ein Kausalzusammenhang auszeichnet und inwiefern der Nachweis eines dieser Merkmale als Evidenz für dessen Gültigkeit zu werten ist. In Abschnitt 5.1.3.2 werden verschiedene Ebenen vorgestellt, auf denen sich ein Kausalzusammenhang zum Nachweis dieser Wesensmerkmale betrachten lässt.

5.1.3.1 Wesensmerkmale kausaler Zusammenhänge

Um einen Kausalzusammenhang als gültig zu betrachten, müssen konkrete Hinweise für dessen Gültigkeit vorliegen. Ein konkreter Hinweis liegt vor, wenn nachgewiesen wurde, dass eines oder mehrere Merkmale vorhanden sind, die für einen Kausalzusammenhang wesentlich sind. Drei Wesensmerkmale kennzeichnen einen Kausalzusammenhang:

- *Bedingtheit*: Nur wenn spezifische Rahmenbedingungen erfüllt sind, kann die Ursache die Wirkung verursachen.
- *Chronologie*: Die Ursache ereignet sich zeitlich vor der Wirkung.
- *Gesetzmäßigkeit*: Immer wenn die spezifischen Rahmenbedingungen erfüllt sind und die Ursache eintritt, tritt auch die Wirkung ein.

Das erste Wesensmerkmal, die Bedingtheit, weist darauf hin, dass jeder Kausalzusammenhang auf einer für ihn spezifischen Bedingungskonstellatation beruht (vgl. [Cart97, S. 343], [Ster00, S. 107]). Diese Bedingungskonstellatation stellt die kausale Infrastruktur, die es der Ursache ermöglicht, die Wirkung überhaupt hervorzurufen. Sind diese Rahmenbedingungen der kausalen Infrastruktur nicht gegeben, kann die Wirkung nicht mehr als Folgeereignis der Ursache eintreten. Eine solche Rahmenbedingung ist beispielsweise ein Stromkabel, das einen Lichtschalter mit einer Lampe verbindet. Sobald das Stromkabel defekt ist, kann das Umlegen des Lichtschalters die Lampe nicht mehr zum Leuchten bringen.

Das zweite Wesensmerkmal, die Chronologie, fordert, dass sich eine Ursache stets vor ihrer Wirkung ereignet (vgl. [ScHE95, S. 222], [Pear00, S. 39]). Tritt ein Ereignis nach einem anderen Ereignis auf, so lässt sich dieses zeitlich nachfolgende Ereignis als Ursache des ersten Ereignisses ausschließen. Hat die Lampe bereits zu dem Zeitpunkt geleuchtet, als der Lichtschalter umgelegt wurde, kommt das Umlegen des Lichtschalters nicht mehr als Ursache für das Leuchten der Lampe infrage. Für den Fall, dass beide Ereignisse zeitgleich auftreten, lässt sich sogar jedweder Kausalzusammenhang zwischen den Ereignissen ausschließen.

Das dritte Wesensmerkmal, die Gesetzmäßigkeit, impliziert, dass immer dann, wenn sich die Ursache ereignet, auch die erwartete Wirkung eintritt (vgl. [Bago80, S. 5]). Wenn das Umlegen eines Schalters die Ursache für das Leuchten einer Lampe sein soll, dann muss die Lampe jedes Mal zu leuchten beginnen, wenn der Schalter entsprechend betätigt wird. Daher ist die „Existenz einer

Gesetzmäßigkeit die Voraussetzung dafür, um überhaupt sinnvoll von Ursache und Wirkung sprechen zu können“ [Scha88, S. 58]. Dies bedeutet aber nicht, dass das Wirkungsergebnis nicht auch durch alternative Ursachen hervorgerufen werden kann.

Der Nachweis eines Wesensmerkmals wird als Evidenz bezeichnet. Jedes dieser drei Wesensmerkmale begründet somit eine eigene Evidenzklasse, in der man Hinweise für die Gültigkeit eines Kausalzusammenhangs finden kann. Aus dem Nachweis eines einzelnen Wesensmerkmals kann noch nicht auf die Gültigkeit des Kausalzusammenhangs geschlossen werden. Damit ein Kausalzusammenhang als gültig akzeptiert werden kann, müssen in *jeder* der drei Evidenzklassen ein oder mehrere Nachweise erbracht werden.

Als eindeutig *ungültig* kann ein Kausalzusammenhang verworfen werden, wenn der Nachweis der Chronologie scheitert (vgl. [Simo76, S. 59]). Scheitert der Nachweis der Gesetzmäßigkeit, kann der Kausalzusammenhang trotzdem gültig sein. Denn damit sich das Wesensmerkmal der Gesetzmäßigkeit nachweisen lässt, muss die für den Kausalzusammenhang erforderliche Bedingungskonstellation vorliegen. Möglicherweise lag diese nicht vor, weil sie sich aufgrund ihrer hohen Spezifität nicht mehr reproduzieren lässt oder weil man die Bedingungskonstellation mangels genauerer Kenntnis nicht reproduzieren kann. Letzteres ist auch der Grund, weshalb man für Ursache-Wirkungs-Beziehungen oft nur Wahrscheinlichkeitswerte ausweisen kann. Dies widerspricht dem deterministischen Kausalverständnis aber nicht, da es nur ein Beleg dafür ist, dass man die Bedingungskonstellation bislang nur unzureichend kennt (vgl. [Scha88, S. 62], [May99, S. 33], [ScHE95, S. 66]). Aus diesem Grund setzt der Nachweis der Gesetzmäßigkeit eine Auseinandersetzung mit der Bedingungskonstellation und somit den Nachweis der Bedingtheit voraus.

5.1.3.2 Betrachtungsebenen kausaler Zusammenhänge

Nach der Vorstellung der kausalen Wesensmerkmale werden in diesem Abschnitt verschiedene Betrachtungsebenen vorgestellt, auf denen sich ein Kausalzusammenhang beschreiben lässt.

Je nachdem, ob man einen allgemeinen oder einen auf einen Einzelfall bezogenen Ursache-Wirkungs-Zusammenhang untersucht, kann zwischen einer Typ- und einer Instanzsicht unterschieden werden. Während bei einer Kausalbeschreibung aus Instanzsicht zwei Einzelereignisse verbunden sind, verknüpft eine Beschreibung aus Typsicht zwei Ereignistypen. Ein Ereignistyp charakterisiert

eine Menge gleichartiger Einzelereignisse - die Ereignisinstanzen - und beschreibt deren Ereignisklasse (vgl. [Sche01, S. 12], [BaGr04, S. 171]). Hat man etwa am 04.02.08 um 16:36 Uhr den grünen Lichtschalter in der Küche betätigt und damit die Küchenlampe angeknipst, kann man von diesem singulären, auf einen Zeitpunkt bezogenen Ereignis abstrahieren und den Ereignistyp „Grüner Lichtschalter wird umgelegt“ bilden. Dann wäre jedes Umlegen des grünen Lichtschalters - zu welcher Uhrzeit auch immer - eine gültige Instanziierung dieses Ereignistyps; zum Beispiel das Umlegen um 16:37 Uhr oder das um 13:58 Uhr. Abbildung 31 illustriert den Unterschied zwischen Typ- und Instanzsicht.

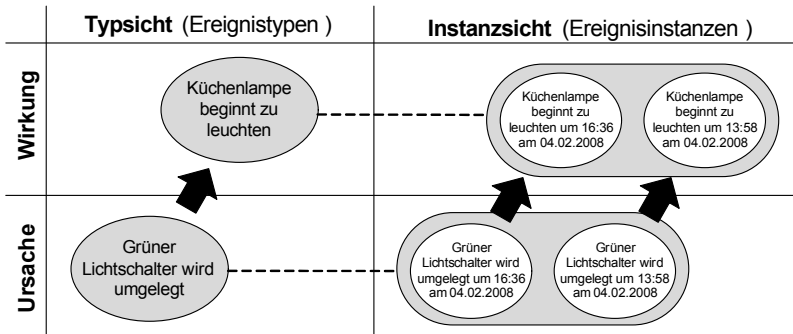


Abbildung 31: Typ- und Instanzsicht kausaler Ereignisbeziehungen

Ein Ereignistyp sagt nichts darüber aus, ob und wie oft ein Einzelereignis dieses Typs bereits aufgetreten ist und ob der Eintritt eines solchen Ereignisses überhaupt möglich ist. Dies wirft allerdings die Frage auf, wie man einen Ereignistyp formuliert und anhand welcher Kriterien sich entscheiden lässt, welchen Ereignistyp ein aufgetretenes Einzelereignis instanziiert. Um dies zu beantworten, muss die Ebene der Ereignisse verlassen und der Kausalzusammenhang auf einer anderen Ebene betrachtet werden: der Objektebene.

Ein Ereignis ist definiert als eine Zustandsänderung und beschreibt den Wechsel von einem Vor- in einen Nachzustand (vgl. [Sche01, S. 15], [Meix01, S. 76-77]). Auf diese Weise kann jedes Ereignis auf ein Objekt bezogen werden, und zwar auf genau das Objekt, dessen Zustand sich beim Ereigniseintritt ändert. Dieses Objekt fungiert als Ereignisträger. Da sich die Zustände von Objekten anhand der Ausprägungen ihrer Objekteigenschaften beschreiben lassen, zeigen Ereignisse stets Veränderungen dieser Objekteigenschaften an. So

bezieht sich beispielsweise das Ereignis „grüner Lichtschalter wird umgelegt“ auf das Objekt „grüner Lichtschalter“. Handelt es sich bei dem ereignistragenden Objekt um einen Kippschalter, so lässt sich das Ereignis als Wechsel von der Position „aus“ in die Position „an“ beschreiben. Analog verweist das Ereignis „Küchenlampe beginnt zu leuchten“ auf das Objekt Küchenlampe, dessen Zustand von „nicht leuchten“ oder „dunkel“ in den Nachzustand „leuchten“ oder „hell“ übergeht.

Ebenso wie auf der Ereignisebene kann auch auf der Objektebene zwischen Typen und Instanzen unterschieden werden. Ein Objekttyp fasst eine Menge gleichartiger Einzelobjekte zu einer Klasse von Objektinstanzen zusammen. Welche Einzelobjekte als gleichartig aufgefasst werden, hängt von den Ausprägungen ihrer Objekteigenschaften ab. Zur Bildung eines Objekttyps werden bestimmte Objekteigenschaften mit konkreten Eigenschaftswerten belegt. Diese typbildenden Eigenschaften werden als Typmerkmale bezeichnet. Anhand der Typmerkmale eines Objekttyps kann entschieden werden, ob ein Einzelobjekt eine gültige Objektinstanz eines Objekttyps ist. Dies ist nur dann der Fall, wenn das Einzelobjekt sämtliche von den Typmerkmalen geforderten Objekteigenschaften besitzt. Der Objekttyp GRÜNER LICHTSCHALTER¹ verwendet beispielsweise die Objekteigenschaft Farbe als Typmerkmal, was dazu führt, dass alle Lichtschalter, deren Farbe grün ist, eine Instanz dieses Objekttyps sind.

Damit ein Einzelereignis einen bestimmten Ereignistyp instanziiert, müssen zwei Bedingungen erfüllt sein: Zum einen, dass das ereignistragende Objekt eine gültige Instanziierung des ereignistragenden Objekttyps ist, zum anderen, dass bei der ereignistragenden Objektinstanz tatsächlich die vom Ereignistyp beschriebene Zustandsänderung stattgefunden hat. Abbildung 32 illustriert den Zusammenhang zwischen Objekt- und Ereignistypen sowie zwischen Objekt- und Ereignisinstanzen.

¹ Die Hervorhebung mit Kapitälchen signalisiert, dass ein Objekttyp referenziert wird. Objektinstanzen sind im Text nicht hervorgehoben.

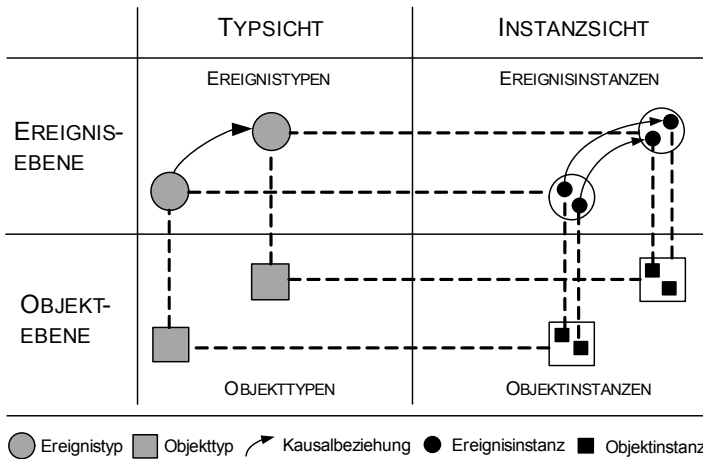


Abbildung 32: Zusammenhang zwischen Objekt- und Ereignistypen sowie zwischen Objekt- und Ereignisinstanzen.

Um einen Kausalzusammenhang auf der Ereignisebene beschreiben zu können, benötigt man auf der Objektebene detaillierte Kenntnisse über die Objekte und deren Eigenschaften. Diese Kenntnisse erhält man auf einer vorgelagerten Ebene: der Ebene der Sinneswahrnehmung. Ein Objektbegriff wird gebildet, indem man aus dem Strom der permanent einfließenden Sinnesreize bestimmte Reize herausfiltert und diese als zusammengehörige Eigenschaften eines Objekts begreift, die dessen Zustand beschreiben (vgl. [Niem77, S. 39]). So kann ein grüner Lichtschalter von einem beigefarbenen Lichtdimmer nicht nur auf Basis der visuellen Farb- und Formwahrnehmung, sondern auch auf Basis eines taktilen Reizes abgegrenzt werden; denn im Gegensatz zu einem Lichtschalter, der sich ein und ausschalten lässt, muss bei einem Lichtdimmer ein Drehknopf betätigt werden. Gleichzeitig bestimmen die bereits vorhandenen Objektbegriffe, welche Sinneseindrücke wahrgenommen werden. Das Objektvokabular übernimmt somit auch die Funktion eines Wahrnehmungsfilters.

Ein Objektbegriff muss aber nicht das Resultat sensorischer Wahrnehmungen sein, er kann genauso das Ergebnis abstrakter Denkprozesse sein (vgl. [Niem77, S. 4]). Der Objektbegriff bezeichnet dann kein physisch wahrnehmbares, sondern ein rein immaterielles Objekt, dessen Objekteigenschaften nur konstruiert, physisch aber nicht wahrnehmbar sind. Ein solches Objekt bezeichnet zum Beispiel der Begriff „Seele“. Abbildung 33 illustriert die Abhängigkeiten zwischen

der Ereignis- und der Objektebene sowie der zugrunde liegenden Ebene der Sinneswahrnehmung.

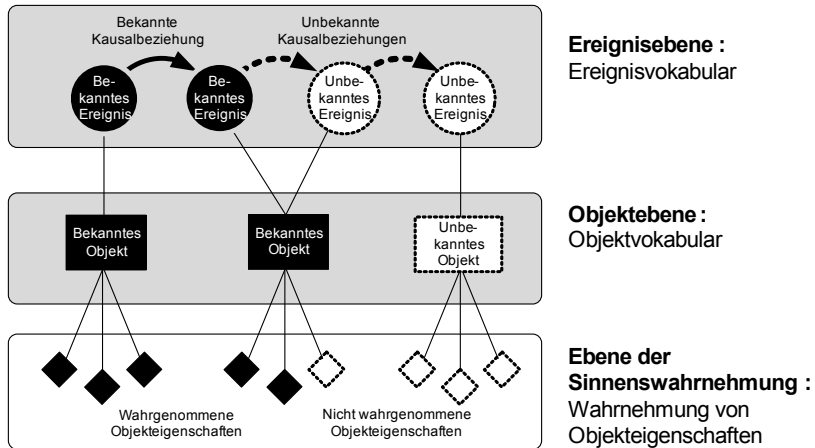


Abbildung 33: Abhängigkeiten zwischen den Betrachtungsebenen

Anhand der drei Betrachtungsebenen lässt sich nun erklären, worauf unser Kausalverständnis letztlich gründet und wie es sich entlang der drei Ebenen herausbildet. Um einen Kausalzusammenhang formulieren zu können, benötigt man auf der Ereignisebene ein entsprechend differenziertes Ereignisvokabular. Dieses beruht wiederum auf dem Objektvokabular der Objektebene, das auf Basis sensorischer Wahrnehmungs- und kognitiver Denkprozesse gebildet wird. Dass auf der Ereignisebene ein bestimmter Kausalzusammenhang fehlt, kann auf Lücken im Ereignis- oder Objektvokabular hinweisen, die sich möglicherweise auf Defizite in der Sinneswahrnehmung zurückführen lassen.

5.1.4 Methodische Grundlagen des Analyseprozesses

In diesem Abschnitt wird untersucht, welche methodischen Konsequenzen sich aus den konzeptionellen Grundlagen von Kausalinformationen ergeben. Was bedeutet es für Entwicklung und Überprüfung von Kausalhypothesen, dass sich Kausalzusammenhänge durch die drei Wesensmerkmale der Bedingtheit, Chronologie und Gesetzmäßigkeit auszeichnen und sich auf den drei im vorherigen Abschnitt skizzierten Ebenen betrachten lassen? Diese methodischen Überlegungen bilden die Basis für die Entwicklung der insgesamt vier Gestaltungsoptionen.

Jede Gestaltungsoption wird als prozessuales Lösungsverfahren für eine der beiden Aufgaben des Analyseprozesses konzipiert: die Entwicklung und Überprüfung von Kausalhypothesen. Beide Aufgaben werden zunächst in Abschnitt 5.1.4.1 beschrieben und voneinander abgegrenzt, bevor in Abschnitt 5.1.4.2 der methodische Entwurf der Gestaltungsoptionen folgt.

5.1.4.1 Entwicklung und Überprüfung von Kausalhypothesen

In Abschnitt 5.1.2 wurde bereits erwähnt, dass zu den Aufgaben des Analyseprozesses nicht nur die Überprüfung bereits vermuteter Kausalbeziehungen, sondern auch die Entwicklung neuer und bislang unbekannter Kausalhypothesen gehört. Da die Gestaltungsoptionen des Analyseprozesses das Lösungsverfahren für diese beiden Aufgaben darstellen, sind zunächst die spezifischen Problemstellungen der Hypothesenentwicklung und -überprüfung herauszuarbeiten. Zu diesem Zweck wird das Konzept der Untersuchungssituation verwendet (vgl. [Fers79, S. 43]), das in Abbildung 34 skizziert ist.

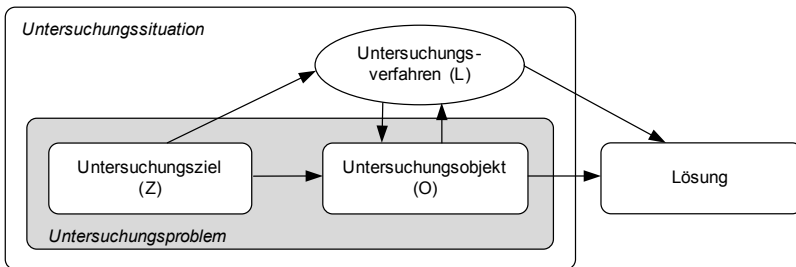


Abbildung 34: Konzept der Untersuchungssituation nach Ferstl

Eine Untersuchungssituation ist ein Tripel (Z, O, L) , bestehend aus einem Untersuchungsziel Z , einem Untersuchungsobjekt O sowie einer Menge von Untersuchungsverfahren L , mit denen sich eine Lösung für das Untersuchungsproblem generieren lässt. Ein Untersuchungsproblem besteht aus dem Tupel (O, Z) . Das Untersuchungsziel Z wird meist in Form einer Fragestellung formuliert und bezieht sich auf das Untersuchungsobjekt O . Gefragt wird nach unbekanntem Eigenschaften des Untersuchungsobjekts, insbesondere nach Verhaltens- oder Struktureigenschaften (vgl. [Fers79, S. 44]). Als Untersuchungsobjekt kommen sowohl formale als auch reale Systeme infrage.

Um das Objekt zu untersuchen, sind vier Aktivitäten durchzuführen: Zuerst muss das Untersuchungsobjekt O abgegrenzt und anhand seiner Objekteigenschaften beschrieben werden. Als Zweites ist das Ziel der Untersuchung festzulegen, bevor in einem dritten Schritt die Menge der zur Verfügung stehenden Untersuchungsverfahren bestimmt werden kann, mit denen sich das Untersuchungsziel erreichen lässt. In einem vierten Schritt sind aus dieser Menge ein oder mehrere geeignete Verfahren auszuwählen und auf das Untersuchungsobjekt anzuwenden.

Das Untersuchungsobjekt der *Entwicklung von Kausalhypothesen* ist ein bestimmter Ausschnitt der Realität, der als ein klar abgegrenzter Objektbereich die Diskurswelt der Untersuchung bildet (siehe Abschnitt 3.1.1.1, Seite 29). Ausgangspunkt der Hypothesenentwicklung ist stets ein bestimmtes Ausgangsereignis, das sich auf ein bestimmtes Objekt innerhalb dieses Objektbereichs bezieht. Als Ausgangsereignis für einen Fertigungsprozess käme zum Beispiel eine Durchlaufzeiterhöhung infrage. Als Objektbereich für eine Ursachenanalyse käme dann zum Beispiel der gesamte Fertigungsprozess, einer seiner Teilprozesse oder auch vor- und nachgelagerte Prozesse infrage, wie zum Beispiel der Lagerhaltungs- oder Bestellprozess.

Das Untersuchungsziel der Hypothesenentwicklung ist es, unbekannte Verhaltenseigenschaften des Objektbereichs in Form einer oder mehrerer Kausalhypothesen zu beschreiben. Wie der folgende Abschnitt 5.1.4.2 zeigen wird, lässt sich die Suche nach Verhaltenseigenschaften durch eine Analyse von Struktureigenschaften unterstützen, da es die Struktur ist, die das Verhalten prägt (vgl. [Ster00, S. 107]). Das Untersuchungsziel muss in Form einer analytischen Fragestellung konkretisiert werden, die durch das Ausgangsereignis und die zeitliche Richtung bestimmt wird, in die man bei der Suche nach einer Kausalhypothese blickt. Je nachdem, ob man das Ausgangsereignis als Ursachen- oder Wirkungsereignis begreift, handelt es sich bei der Untersuchung um eine Ursachen- oder Wirkungsforschung. Abhängig von der gewählten Blickrichtung sucht man Ereignisse, die sich zeitlich entweder vor oder nach dem Ausgangsereignis ereignet haben - oder sich erst noch ereignen können. Somit lassen sich insgesamt vier verschiedene Arten von Untersuchungszielen unterscheiden: die Ursachen- und Wirkungsforschung für ein vergangenes oder ein zukünftiges Ereignis (siehe Abbildung 35).

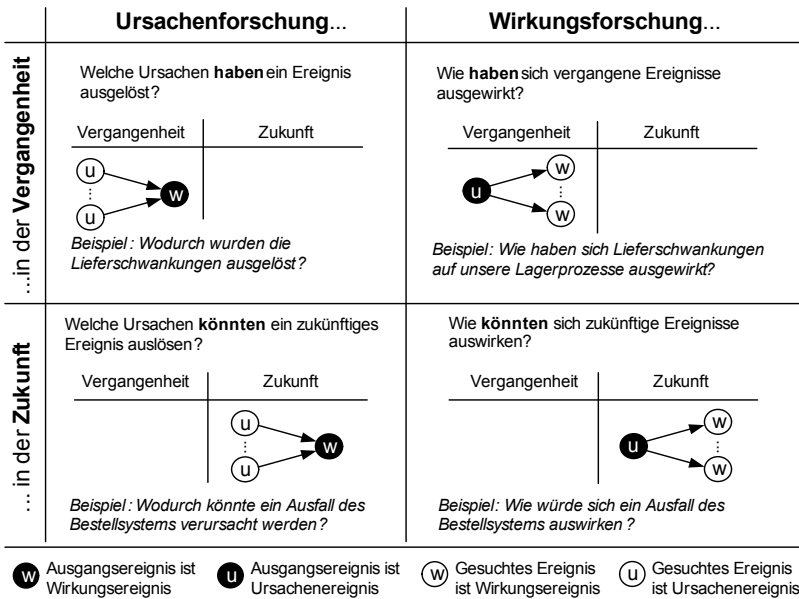


Abbildung 35: Untersuchungsziele der Hypothesenentwicklung

Die Lösung des Untersuchungsproblems ist eine Kausalhypothese, die das Verhalten des untersuchten Objektbereichs in Form kausal verketteter Ereignisfolgen beschreibt. Im Gegensatz zu einer unbegründeten Kausalannahme muss eine Kausalhypothese eine gewisse Anfangsplausibilität besitzen (siehe Abschnitt 5.1.2). Bei der Hypothesenentwicklung verläuft die Suche nach diesen Evidenzen ergebnisoffen; man versucht lediglich einen ersten Hinweis auf einen gültigen, noch unvermuteten Kausalzusammenhang zu gewinnen. Eine gezielte Suche nach Evidenzen würde hingegen bedeuten, dass man bereits einen bestimmten Kausalzusammenhang vor Augen hat. Ziel der Hypothesenentwicklung ist es jedoch, diesen Zusammenhang erst *auf Basis* von Evidenzen zu entwickeln. Das Untersuchungsverfahren muss daher in der Lage sein, solche Evidenzen zu erzeugen. Welche Rolle dabei die Abgrenzung des Objektbereichs spielt, soll an einem einfachen Beispiel für eine Ursachenforschung in der Vergangenheit erläutert werden:

Erlischt in einem Raum eine Lampe, so kann man das Ausgangsereignis als einen Zustandswechsel der Lampe beschreiben, etwa von „leuchtet“ zu „leuchtet

nicht“. Ziel der Untersuchung ist es, eine Kausalhypothese zu entwickeln, die erklärt, weshalb die Lampe erloschen ist. Das Untersuchungsobjekt kann nun auf unterschiedliche Weise abgegrenzt werden. Beschränkt man die Untersuchung auf das dem Ausgangsereignis zugrunde liegende Objekt der Lampe, dann können als Lösung für das Untersuchungsproblem nur solche Ursachenereignisse gefunden werden, die eine Zustandsänderung an der Lampe oder einem ihrer Teilobjekte anzeigen. Denn zu dem vom Untersuchungsobjekt Lampe aufgespannten Objektbereich zählen auch sämtliche Objekte, aus denen sich die Lampe zusammensetzt, etwa der Lampenschirm, die Fassung, die Glühbirne oder der Glühfaden. Bei dieser engen Abgrenzung des Untersuchungsobjekts käme beispielsweise ein durchgeglühter Glühfaden als Ursache infrage. Weitet man allerdings den Objektbereich der Untersuchung auf den gesamten Raum aus, in dem die Lampe erloschen ist, so erstreckt sich der Objektbereich der Untersuchung auf sämtliche Objekte, die Teil des Raums sind. Zum Objektbereich gehören dann möglicherweise auch ein Tisch, ein Stuhl sowie sämtliche Lichtschalter an den Wänden. Im Gegensatz zur ersten Untersuchungssituation könnte das Erlöschen der Lampe auf einen ausgeschalteten Lichtschalter zurückgeführt werden - sofern man einen Hinweis darauf erhält. Das bedeutet, dass mit jeder Ausweitung des Objektbereichs auch der Bereich potenzieller Lösungen des Untersuchungsproblems wächst. Ziel muss es sein, den Objektbereich der Untersuchung einerseits so eng wie möglich, andererseits so weit wie nötig zu fassen.

Bei der *Überprüfung von Kausalhypothesen* ist der Objektbereich hingegen leichter abzugrenzen, da sowohl das Ursachen- als auch das Wirkungsereignis bereits bekannt sind. Hat man zum Beispiel einen durchgeglühten Glühfaden als Ursache für das Erlöschen der Lampe angenommen, können die Lichtschalter, der Tisch oder die Stühle aus der Untersuchung ausgeklammert werden, da zum Objektbereich nur die ereignistragenden Objekte gehören: die Lampe und der Glühfaden.

Ziel der Hypothesenprüfung ist es, nach Evidenzen zu suchen, die zusätzlich zu den bereits vorhandenen Evidenzen auf die Gültigkeit einer Kausalhypothese hinweisen und so die noch vorhandenen Lücken im kausalen Evidenzgebäude schließen. Das Untersuchungsverfahren der Hypothesenprüfung muss daher ebenfalls in der Lage sein, Evidenzen für die Gültigkeit oder Ungültigkeit eines Kausalzusammenhangs zu erzeugen. Der Unterschied zur Hypothesenentwicklung besteht darin, dass nicht mehr irgendwelche, sondern eben genau die noch fehlenden Evidenzen zu generieren sind.

Die Lösung des Untersuchungsproblems sind dann Evidenzen aus den noch nicht berücksichtigten Evidenzklassen. Liegen in allen Evidenzklassen Gültigkeitshinweise vor, kann die überprüfte Kausalhypothese als gültig betrachtet werden kann. Weist die Lösung hingegen auf die Ungültigkeit der Hypothese hin, ist diese zu verwerfen. Wie jede andere Hypothese auch, kann aber allenfalls die Ungültigkeit einer Kausalhypothese, nicht aber ihre Gültigkeit bewiesen werden (vgl. [Popp66, S. 198]). Eine Kausalhypothese gilt so lange als gültig, so lange sie sich noch nicht als ungültig erwiesen hat. Aus diesem Grund sind die Kausalinformationen einer erfolgreichen Hypothesenprüfung nur als vorläufiges Kausalwissen zu betrachten.

Nachdem die beiden zentralen Untersuchungsprobleme des Analyseprozesses erläutert wurden, müssen als Nächstes geeignete Untersuchungsverfahren gefunden werden. Im folgenden Abschnitt wird skizziert, mit welchen Verfahren sich beide Untersuchungsprobleme lösen lassen, was schließlich zu den vier Gestaltungsoptionen des Analyseprozesses führt.

5.1.4.2 Modell- und datenzentrierte Kausalanalyse

Interpretiert man das Untersuchungsobjekt der Untersuchungssituation als Regelstrecke (siehe Abbildung 34), kann die Anwendung des Untersuchungsverfahrens als geschlossener Regelkreis aufgefasst werden (siehe Abbildung 8). Denn wie bereits in Abschnitt 3.1.1.2 erläutert wurde, kann die Komplexität der Regelstrecke reduziert werden, indem man diese durch ein Modell der Regelstrecke, eine Hilfsregelstrecke, ersetzt. Eine solche Modellabbildung eignet sich insbesondere für Untersuchungssituationen, „für die zunächst keine oder nur schwer durchführbare Untersuchungsverfahren zur Verfügung stehen“ [Fers79, S. 79]. Da dies bei der Entwicklung und Überprüfung von Kausalhypthesen der Fall ist (siehe Abschnitt 2.2.1), empfiehlt es sich, die ursprüngliche Untersuchungssituation in eine *modellgestützte* Untersuchungssituation zu transformieren (vgl. [Fers79, S. 79]). Ziel einer solchen Transformation ist es, eine alternative Untersuchungssituation zu schaffen, für die sich geeignete Verfahren finden und auf das Modellsystem anwenden lassen (vgl. [Klir69, S. 84]). Abbildung 36 zeigt, wie sich das ursprüngliche Untersuchungsproblem in eine modellgestützte Untersuchungssituation transformieren lässt.

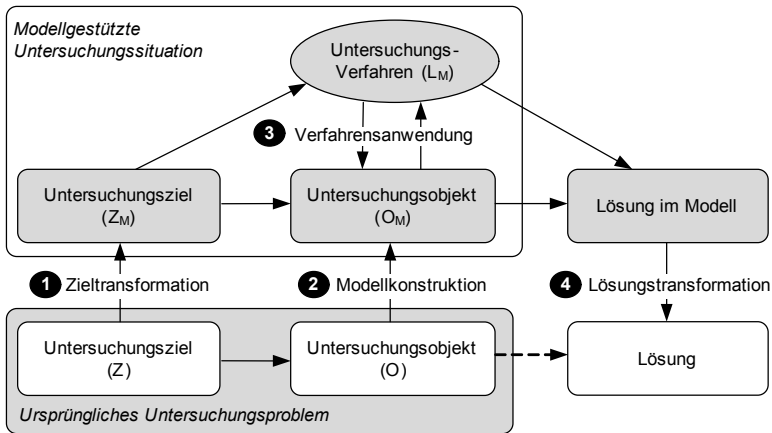


Abbildung 36: Modellgestützte Untersuchung (in Anlehnung an [Fers79, S. 80])

Die Transformation in eine modellgestützte Untersuchungssituation beginnt damit, dass das originäre Untersuchungsobjekt O mittels eines Modellsystems O_M abgebildet wird. Analog zu dieser Modellkonstruktion muss auch das Untersuchungsziel Z durch ein auf O_M bezogenes Modellziel Z_M ersetzt werden. Bei der Zieltransformation ist die ursprüngliche Fragestellung so umzuformulieren, dass nicht mehr nach Eigenschaften des originären Untersuchungsobjekts, sondern nach Eigenschaften des Modellsystems O_M gefragt wird. Damit sich ein Untersuchungsproblem über den Weg einer modellgestützten Untersuchungssituation lösen lässt, muss ein Untersuchungsverfahren gefunden und auf das Modellsystem O_M angewandt werden, das im Hinblick auf das Untersuchungsziel Z_M eine Modelllösung generiert. Diese Modelllösung muss schließlich in eine Lösung für das ursprüngliche Untersuchungsproblem transformiert werden.

Um die Hypothesenentwicklung und -überprüfung in eine modellgestützte Untersuchungssituation zu transformieren, muss zunächst ein geeignetes Modellsystem für die Kausalanalyse gefunden werden. Dieses Modellsystem muss sämtliche Aspekte des originären Untersuchungsobjekts abbilden, die für die Lösung der beiden Untersuchungsprobleme relevant sind. Wie bereits im vorangegangenen Abschnitt 5.1.4.1 erläutert, basiert sowohl die Entwicklung als auch die Überprüfung von Kausalhypothesen auf einer Suche nach Evidenzen. Um vorläufiges Kausalwissen zu erzeugen, müssen Evidenzen in allen drei Evidenzklassen vorliegen, die sich aus den kausalen Wesensmerkmalen der Bedingtheit, Chronologie und Gesetzmäßigkeit ergeben (siehe Abschnitt 5.1.3.1). Je

nachdem welches dieser drei Wesensmerkmale nachgewiesen werden soll, muss ein Kausalzusammenhang auf einer anderen Ebene betrachtet werden. Bei der Wahl des Modellsystems kann man sich daher an den in Abschnitt 5.1.3.2 vorgestellten Betrachtungsebenen wie folgt orientieren.

Um das Wesensmerkmal der *Bedingtheit* nachzuweisen, muss geklärt werden, unter welchen Bedingungen das Ursachenereignis in der Lage ist, das Wirkungsereignis hervorzurufen. Hierzu bietet sich eine Betrachtung des Kausalzusammenhangs auf der Objektebene an. Es ist zu klären, auf welche Weise das Ursachenobjekt mit dem Wirkungsobjekt verbunden ist und auf welchem Weg die Zustandsänderung am Ursachenobjekt die Zustandsänderung am Wirkungsobjekt herbeiführen kann (vgl. [Card04, S. 15]). Der Weg, den ein kausaler Wirkungsmechanismus auf der Objektebene nimmt, muss sich anhand einer Objektbeziehung zwischen den ereignistragenden Objekttypen begründen und nachvollziehen lassen. Dies soll an folgendem Beispiel erläutert werden:

Um zu klären, auf welche Weise das Umlenken des Schalters das Leuchten der Lampe hervorrufen kann, muss zunächst sowohl dem Ursachen- als auch dem Wirkungsereignis jeweils ein Objekt als Ereignisträger zugeordnet werden. Hat man einen Schalter und eine bestimmte Lampe als Ereignisträger identifiziert, muss als Nächstes untersucht werden, auf welche Weise der Schalter mit der Lampe in Beziehung steht und inwiefern sich der Kausalzusammenhang anhand dieser Objektbeziehung nachvollziehen lässt. Stellt man zum Beispiel fest, dass der Lichtschalter mit der Lampe über ein Stromkabel verbunden ist, kann das Leuchten der Lampe unter der Annahme erklärt werden, dass durch Betätigung des Schalters ein Stromkreis geschlossen und dadurch Strom zur Lampe geleitet wird.

Zur Klärung der kausalen Bedingungskonstellation benötigt man ein Modellsystem, das die für einen Kausalzusammenhang relevanten Objekte und Objektbeziehungen abbildet. Obwohl eine Abbildung von Objektinstanzen prinzipiell denkbar wäre, sollten in das Modellsystem ausschließlich Objekttypen aufgenommen werden. Die Typbildung ermöglicht ebenso wie die Bildung von Sichten und Modellebenen (siehe Abschnitt 3.1.1.4) eine Reduzierung der Modellkomplexität: Anstatt einzelne Objektinstanzen in das Modellsystem aufzunehmen, können diese auf Basis einer gemeinsamen Typspezifikation durch *einen* Objekttyp ersetzt werden.

Um die *Gesetzmäßigkeit* und *Chronologie* eines Kausalzusammenhangs nachzuweisen, muss ein Kausalzusammenhang auf der Ereignisebene betrachtet werden. Hierbei richtet sich der Blick insbesondere auf die Sequenzen realer Einzel-

ereignisse und somit auf die Ereignisinstanzen zweier Ereignistypen. Für einen Nachweis der Gesetzmäßigkeit und Chronologie müssen zwei Punkte erfüllt sein:

1. Ursachen- und Wirkungsereignis müssen sich real ereignet haben.
2. Immer dann, wenn sich das Ursachenereignis ereignet hat, ist anschließend auch das Wirkungsereignis eingetreten.

Um den ersten Punkt nachzuweisen, ist es von Bedeutung, dass jedes Ereignis einen Zustandsübergang beschreibt. Solche Zustandsübergänge können entweder direkt beobachtet oder mithilfe von Messverfahren aufgezeichnet und in einer Datenbasis dokumentiert werden. Hierzu charakterisiert man einen Zustand anhand von Merkmalen und zugehörigen Merkmalswerten. In der Datenbasis spiegelt sich das Eintreten eines Ereignisses dann in Form von Merkmalswertänderungen wider.

Der zweite Punkt impliziert, dass sich die Vorzustände beider Ereignisse gemeinsam - aber nicht zeitgleich - ändern. Solche gesetzmäßigen Abhängigkeiten können in der Datenbasis mithilfe von Korrelationen nachgewiesen werden, die zwischen den Merkmalen des Ursachen- und des Wirkungsereignisses bestehen. Um die Chronologie der Ereignisse untersuchen zu können, müssen in der Datenbasis zusätzlich die Zeitpunkte der Merkmalswertänderungen erfasst sein.

Da sich sowohl die Chronologie als auch die Gesetzmäßigkeit eines Kausalzusammenhangs auf Basis von Daten nachweisen lässt, ist diese Form der Analyse eine *datenzentrierte Kausalanalyse*. Der Nachweis der Bedingtheit wird hingegen als *modellzentrierte Kausalanalyse* bezeichnet, da hierfür die Objekte und Objektbeziehungen des Objektbereichs zu modellieren sind. Die datenzentrierte Kausalanalyse besitzt den Nachteil, dass man sich nur an die Fersen von Ursache und Wirkung heften kann. Ob ein Kausalzusammenhang gültig ist, kann nur anhand von Datenspuren untersucht werden, die die Ereignisse *nach* ihrem Eintreten in der Datenbasis hinterlassen haben. Für den Nachweis der Chronologie gilt, dass sich das Ursachen- und das Wirkungsereignis wenigstens einmal ereignet haben müssen. Für einen Nachweis der Gesetzmäßigkeit sollten beide Ereignisse mehrmals eingetreten sein, da eine signifikante Merkmalskorrelation auf den Merkmalsänderungen zahlreicher Ereignisinstanzen basiert.

Im Gegensatz dazu lässt sich die modellzentrierte Kausalanalyse schon im Vorfeld der Ereignisse durchführen. Zum einen, weil Kausalzusammenhänge nicht aus Instanz-, sondern aus Typsicht betrachtet werden, zum anderen, weil nicht die Ereignis-, sondern die Objektebene im Fokus steht. Deshalb können die

als Ereignisträger infrage kommenden Objekttypen bereits zu einem Zeitpunkt modelliert und untersucht werden, zu dem noch kein Ursachen- oder Wirkungsergebnis stattgefunden hat.

Zusammenfassend kann Folgendes festgehalten werden: Um einen Kausalzusammenhang als gültig akzeptieren zu können, müssen drei kausale Wesensmerkmale nachgewiesen werden. Abhängig davon, welches Wesensmerkmal man nachweisen möchte, ist eine modell- oder datenzentrierte Kausalanalyse nötig. Da nicht nur die Überprüfung, sondern auch die Entwicklung von Kausalhypothesen eine Suche nach Evidenzen ist, können Kausalhypothesen sowohl auf modell- als auch datenzentriertem Weg analysiert werden. Je nachdem, ob Kausalhypothesen zu entwickeln oder zu überprüfen sind, handelt es sich um eine ungerichtete oder zielgerichtete Suche nach Evidenzen. Dies führt zu den insgesamt vier Gestaltungsoptionen des Analyseprozesses, die in Abbildung 37 dargestellt sind.

	Entwicklung von Kausalhypothesen	Überprüfung von Kausalhypothesen
Modellzentrierte Kausalanalyse	<p>GESTALTUNGSOPTION I: MODELLZENTRIERTE ENTWICKLUNG VON KAUSALHYPOTHESEN</p> <p>➔ Entwicklung von Kausalhypothesen durch den Nachweis der Bedingtheit</p>	<p>GESTALTUNGSOPTION III: MODELLZENTRIERTE ÜBERPRÜFUNG VON KAUSALHYPOTHESEN</p> <p>➔ Überprüfung von Kausalhypothesen durch den Nachweis der Bedingtheit</p>
Datenzentrierte Kausalanalyse	<p>GESTALTUNGSOPTION II: DATENZENTRIERTE ENTWICKLUNG VON KAUSALHYPOTHESEN</p> <p>➔ Entwicklung von Kausalhypothesen durch den Nachweis der Gesetzmäßigkeit und Chronologie</p>	<p>GESTALTUNGSOPTION IV: DATENZENTRIERTE ÜBERPRÜFUNG VON KAUSALHYPOTHESEN</p> <p>➔ Überprüfung von Kausalhypothesen durch den Nachweis der Gesetzmäßigkeit und Chronologie</p>

Abbildung 37: Gestaltungsoptionen des Analyseprozesses

Die folgenden beiden Abschnitte erläutern die grundlegenden Konzepte und Methoden der vier Gestaltungsoptionen: das kausalanalytische Architekturmodell (Abschnitt 5.2) und die datenzentrierten Analyseverfahren (Abschnitt 5.3). Anschließend stellt Kapitel 6 die vier Gestaltungsoptionen des Analyseprozesses im Detail vor.

5.2 Kausalanalytisches Architekturmodell

Der modell- und datenzentrierten Kausalanalyse liegt die gemeinsame Idee zugrunde, dass sich die originäre Untersuchungssituation der Entwicklung und Überprüfung von Kausalhypothesen in eine modellgestützte Untersuchungssituation transformieren lässt. Hierbei ist das reale Untersuchungsobjekt durch ein geeignetes Modellsystem zu ersetzen, das die modell- und datenzentrierte Suche nach den kausalen Wesensmerkmalen ermöglicht. Aufgabe der Modellkonstruktion ist es, genau die Elemente des Objektbereichs abzubilden, die für die Anwendung der Untersuchungsverfahren zur Lösung des Untersuchungsproblems notwendig sind.

Um die kausalen Wesensmerkmale eines Kausalzusammenhangs nachzuweisen, muss dieser auf unterschiedlichen Ebenen sowie aus verschiedenen Sichten betrachtet werden (siehe Abschnitt 5.1.4.2). Im Zuge der Modellkonstruktion müssen diese Ebenen und Sichten so aufeinander abgestimmt werden, dass sich die Modellsysteme der modell- und datenzentrierten Kausalanalyse nicht widersprechen und ein konsistentes Bild der Realität wiedergeben. Dies erfordert eine integrierte Modellarchitektur, die den Prinzipien des generischen Architekturrahmens entspricht (siehe Abschnitt 3.1.1.4, Abbildung 11). Ziel dieses Abschnitts ist es, eine solche Modellarchitektur für die modell- und datenzentrierte Kausalanalyse vorzustellen.

Das kausalanalytische Architekturmodell gliedert sich in zwei Modellebenen: die Ereignis- und die Objektebene. Auf jeder dieser Ebenen ist eine Modellbildung aus Typ- und Instanzsicht möglich (siehe Abbildung 38). Die Modellarchitektur für die modellzentrierte Kausalanalyse wird als *typbezogene Kausalarchitektur* bezeichnet. Diese erfasst auf der Ereignisebene die Kausalbeziehungen zwischen den Ereignistypen, während die Objektebene die ereignistragenden Objekttypen und ihre Objektbeziehungen abbildet. Die datenzentrierte Kausalanalyse nutzt eine *instanzbezogene Kausalarchitektur*, die auf der Ereignisebene Daten über die Ereignisinstanzen bereithält. Die Daten der Objektebene beschreiben hingegen die ereignistragenden Objektinstanzen. Abbildung 38 skizziert den Aufbau des kausalanalytischen Architekturmodells und zeigt den Zusammenhang zwischen den Sichten und Modellebenen.

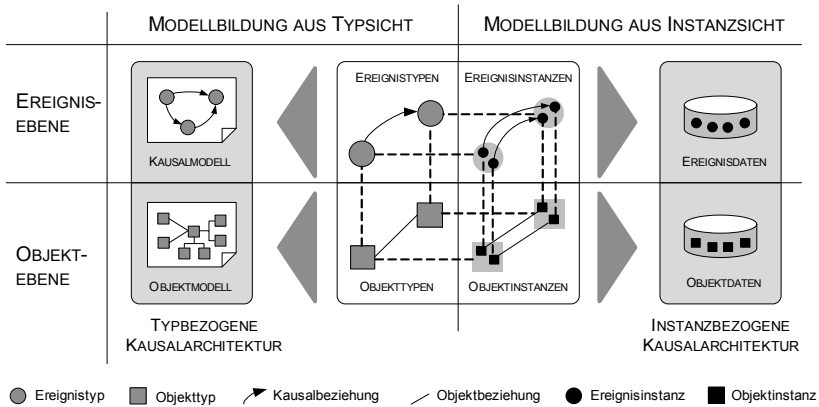


Abbildung 38: Kausalanalytisches Architekturmodell

In Abschnitt 5.2.1 werden zunächst die Modellbausteine und Beziehungen der typbezogenen Kausalarchitektur vorgestellt, bevor in Abschnitt 5.2.2 die Beschreibung der instanzbezogenen Kausalarchitektur folgt.

5.2.1 Typbezogene Kausalarchitektur

Die typbezogene Kausalarchitektur soll es ermöglichen, das kausale Wesensmerkmal der Bedingtheit nachzuweisen. Um die Bedingungskonstellation eines Kausalzusammenhangs aufzuzeigen, sind die zugrunde liegenden Objekttypen und Objektbeziehungen zu modellieren. Zwar lässt sich die Bedingtheit nur auf der Objektebene nachweisen, allerdings müssen auch die Ereignistypen in die Modellierung einbezogen werden:

- Bei der *Überprüfung einer Kausalhypothese* ist jedem der kausal verknüpften Ereignistypen ein Objekttyp als Ereignisträger zuzuordnen.
- Bei der *Entwicklung einer Kausalhypothese* ist umgekehrt zu verfahren: Ausgehend von den Objekttypen der Objektebene sucht man die für einen Kausalzusammenhang infrage kommenden Ereignistypen.

Aus diesen beiden Gründen benötigt man ein Modellsystem, das die Objekttypen und Beziehungen der Objektebene ebenso abbildet wie die Ereignistypen und Kausalbeziehungen der Ereignisebene. Für die Integration beider Modellebenen ist eine Abbildungsbeziehung zu definieren, aus der hervorgeht, wie die Ereignistypen in der Objektebene zu verankern sind und welchen Objekttypen sie

zugeordnet werden können. Abbildung 39 skizziert den Zusammenhang zwischen den beiden Modellebenen.

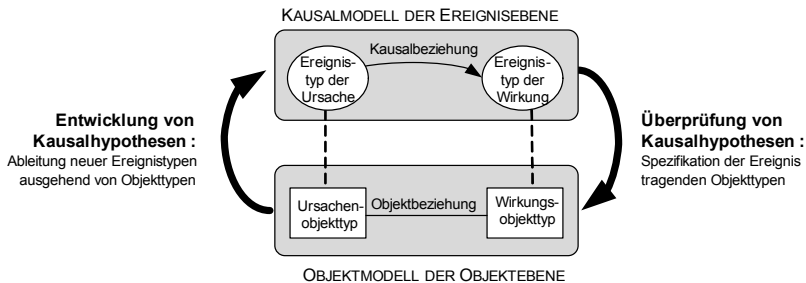


Abbildung 39: Teilmodellsysteme der typbezogenen Kausalarchitektur

In den folgenden beiden Abschnitten werden die Modellbausteine und Beziehungen der Objekt- und Ereignisebene spezifiziert. Hierzu wird - gemäß der Idee des generischen Architekturrahmens - zunächst für jede Modellebene ein eigenes Metamodell konstruiert. Anschließend werden die beide Metamodelle zu einem integrierten Metamodell verknüpft, das die Abbildungsbeziehung zwischen den Modellebenen festlegt.

5.2.1.1 Objekttypen und -beziehungen der Objektebene

Um die Bedingtheit eines Kausalzusammenhangs auf der Objektebene belegen zu können, müssen sowohl die als Ereignisträger infrage kommenden Objekttypen als auch deren Objektbeziehungen modelliert werden (siehe Abschnitt 5.1.4.2). Hierbei determinieren die verschiedenen Arten von Objektbeziehungen, welche Objekttypen sich unterscheiden lassen. Daher werden in diesem Abschnitt zunächst die verschiedenen Arten von Objektbeziehungen vorgestellt, bevor anschließend auf die Objekttypen selbst und ihre typbildenden Merkmale eingegangen wird.

Bei der Modellierung von Objektbeziehungen lassen sich drei Arten unterscheiden (vgl. [FeSi08, S. 219-220]):

- *Interaktionsbeziehung:* Die Instanzen zweier Objekttypen interagieren miteinander (interacts_with-Beziehung). Beispiel: Ein Projektmitarbeiter interagiert mit einem Computer, indem er ihn zur Bewältigung seiner Projektaufgaben nutzt.

- *Teil-Ganzes-Beziehung*: Eine Instanz des einen Objekttyps setzt sich aus einer oder mehreren Instanzen des anderen Objekttyps zusammen (is_part_of-Beziehung). Beispiel: Ein oder mehrere Projektmitarbeiter sind Teil eines Projekts.
- *Typbeziehung*: Die Instanz eines Objekttyps ist gleichzeitig eine Instanz eines zweiten, spezielleren Objekttyps (is_a-Beziehung). Beispiel: Ein Kunde vom Typ STAMMKUNDE ist eine spezielle Art von KUNDE. Der Objekttyp STAMMKUNDE ist eine Spezialisierung des Objekttyps KUNDE.

Bei einer *Interaktionsbeziehung* handelt es sich entweder um eine Objektübertragung oder die Erzeugung bzw. Veränderung eines Objekts (vgl. [Niem77, S. 6]). In Abbildung 40 sind beide Interaktionsarten anhand von Beispielen erläutert.

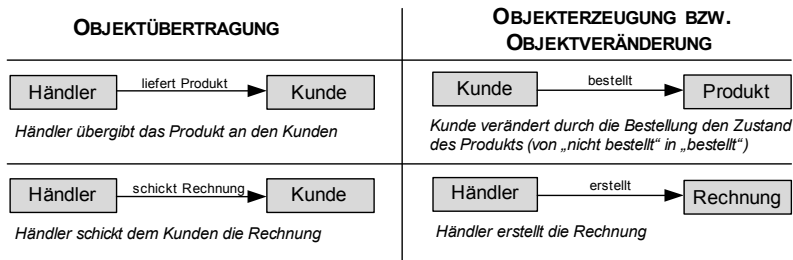


Abbildung 40: Beispiele für verschiedene Arten von Interaktionsbeziehungen

Bei einer *Objektübertragung* tauschen die Objektinstanzen der interagierenden Objekttypen ein oder mehrere Objekte aus. Je nachdem, ob es sich bei dem übertragenen Objekt um ein physisches oder nicht-physisches Objekt handelt, besteht zwischen den Objektinstanzen ein Güter- oder ein Informationsfluss. Bei einem Güterfluss tauschen die Objektinstanzen zum Beispiel Roh-, Hilfs- und Betriebsstoffe oder andere produzier- und lagerbare Güter aus. Ein Informationsfluss liegt vor, wenn zwei informationsverarbeitende Objekte eine oder mehrere Nachrichten austauschen, die sich aus einer Menge von Zeichen oder Symbolen (Daten) zusammensetzen. Als informationsverarbeitendes Objekt kommt sowohl ein automatisierter (Anwendungssystem) als auch ein nicht-automatisierter Aufgabenträger (Mensch) infrage (vgl. [FeSi08, S. 6]). Fasst man zwei oder mehrere Aufgabenträger zu einem informationsverarbeitenden System zusammen, erhält man ein Informationssystem (vgl. [FeSi08, S. 6]), das ebenfalls als Sender oder Empfänger von Nachrichten auftreten kann. Eine erfolgreiche Informationsüber-

mittlung setzt voraus, dass Sender und Empfänger über einen gemeinsamen Zeichenvorrat verfügen und sich auf eine Interpretationsvorschrift verständigt haben (vgl. [FeSi08, S. 139]). Erst wenn der Empfänger diese Interpretationsvorschrift auf die übermittelten Daten anwendet, findet eine Informationsübertragung statt.

Während bei der *Objekterzeugung* ein neues Objekt generiert wird, bedeutet eine *Objektänderung*, dass sich der Zustand eines bereits vorhandenen Objekts ändert. Dies schließt die Zerstörung des Objekts mit ein (vgl. [Niem77, S. 6]). Ein Beispiel für die Erzeugung eines Informationsobjekts ist die Erstellung einer Rechnung durch einen Händler (siehe Abbildung 40). Bearbeitet eine Maschine ein Blech, das anschließend von einem Fließband befördert wird, sind dies zwei Interaktionen: Die Maschine verändert den physischen Zustand des Blechs, das Fließband hingegen dessen Lage und Position. Als Objektveränderung kann jede Form der Energieübertragung gezählt werden, zum Beispiel wenn mechanische, thermische, elektrische, magnetische oder Strahlungsenergie übertragen wird.

Modelliert man eine Interaktionsbeziehung zwischen zwei Objekttypen, so setzt dies voraus, dass die interagierenden Objektinstanzen in einer für die Interaktion erforderlichen physisch-räumlichen Beziehung zueinander stehen. Sollen zum Beispiel zwei Computer Daten auf Basis von elektrischen oder optischen Impulsen austauschen, benötigt man eine physikalische Verbindung (vgl. [Krcm03, S. 200]), etwa in Form eines Kabels. Sind beide Computer in der Lage, via WLAN elektromagnetische Impulse zu senden und zu empfangen, müssen beide Objekte in einer bestimmten, für die Energieübertragung ausreichenden Entfernung zueinander stehen.

Im Gegensatz zu einer Interaktionsbeziehung, die stets zwei gleichrangige Objekte verknüpft, implizieren die beiden anderen Beziehungsarten eine Rangordnung zwischen den Objekten. Mit der Teil-Ganzes- und der Typbeziehung sind zwei elementare Konzepte der Abstraktion verbunden: die Aggregation und die Generalisierung. Die *Teil-Ganzes-Beziehung* verknüpft einen aggregierten Objekttyp mit einem oder mehreren Teilobjekttypen. Im Gegensatz zur Disaggregation, bei der man einen Objekttyp in Teilobjekttypen zerlegt, werden bei einer Aggregation ein oder mehrere Teilobjekttypen zu einem aggregierten Objekttyp zusammengefasst. Disaggregiert man einen Teilobjekttyp, tritt dieser nicht nur als Teilobjekttyp, sondern zusätzlich als aggregierter Objekttyp auf. Durch wiederholte Aggregation oder Disaggregation entsteht eine Hierarchie aus Aggregationsebenen, wie sie auch der Struktur einer Stückliste entspricht.

Eine *Typbeziehung* verknüpft zwar ebenfalls einen übergeordneten Objekttyp mit einem hierarchisch untergeordneten Objekttyp, dieser ist jedoch kein Teil-, sondern ein Subobjekttyp. Ein Subobjekttyp ist zwar eine Spezialisierung eines Superobjekttyps, kann aber auch selbst spezialisiert werden. Auf diese Weise lässt sich eine Hierarchie aus mehreren Typebenen bilden (vgl. [FeSi08, S. 135]), wie sie zum Beispiel die Biologie in Form von Taxonomien zur Klassifizierung von Lebewesen in Familien, Gattungen, Arten und Unterarten verwendet.

Zur *Spezialisierung* nutzt man die Objektmerkmale, anhand derer sich die Objektinstanzen eines Objekttyps beschreiben lassen (siehe Abschnitt 5.1.3.2). Zeichnet sich zum Beispiel eine Teilmenge von Objektinstanzen durch ähnliche oder sogar identische Merkmalswerte aus, können diese Merkmale zur Bildung eines spezialisierten Subobjekttyps verwendet werden. Aber auch unabhängig davon, ob Objektinstanzen eines Subobjekttyps existieren, fügt jeder Subobjekttyp den bereits vorhandenen Typmerkmalen seines Superobjekttyps neue Merkmale hinzu, oder schränkt deren zulässigen Wertebereich ein (vgl. [Fran03, S. 14]). Auf diese Weise lässt sich ein Superobjekttyp in verschiedene Subobjekttypen differenzieren, wobei aber jeder Subobjekttyp nur einen Superobjekttyp besitzt.

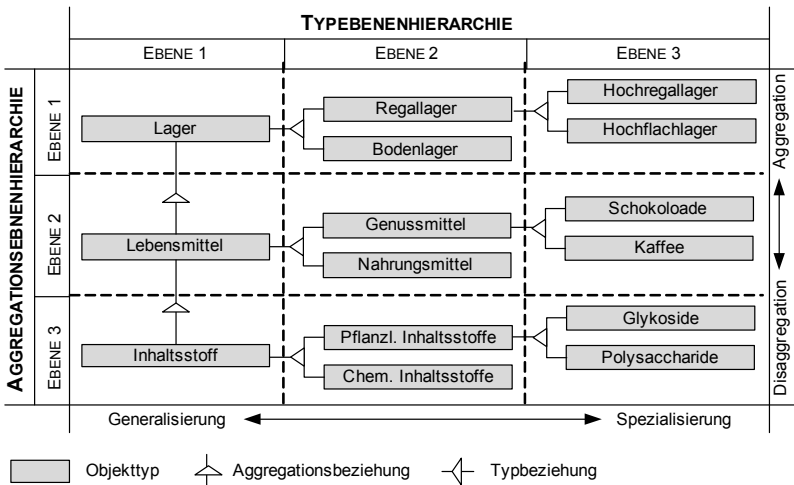


Abbildung 41: Beispiel einer Typ- und Aggregationsebenenhierarchie

Das Gegenstück zur Spezialisierung ist die Generalisierung. Hierbei fasst man die Objektinstanzen unterschiedlicher Objekttypen zu einem gemeinsamen Superobjekttyp zusammen. Analog zu einer Teil-Ganzes-Beziehung, die ausschließlich Objekttypen derselben Typebene verknüpft, können mit einer Typbeziehung nur Objekttypen derselben Aggregationsebene verbunden werden. Abbildung 41 illustriert den Unterschied zwischen Typ- und Aggregationsebenen am Beispiel eines Warenlagers für Lebensmittel.

Nachdem die verschiedenen Arten von Objektbeziehungen und die sich daraus ergebenden Objekttypen vorgestellt wurden, ist nun zu klären, anhand welcher Merkmale sich die Objektinstanzen eines Objekttyps beschreiben lassen und wie man diese Merkmale zur Bildung neuer Subobjekttypen verwenden kann.

In Bezug auf ein Objektmerkmal kann zwischen einem *Eigenschafts-* und einem *Beziehungsmerkmal* differenziert werden. Ein *Beziehungsmerkmal* charakterisiert die Beziehung zwischen den Objektinstanzen zweier Objekttypen. Je nachdem, ob zwischen den Objekttypen eine Interaktions- oder Teil-Ganzes-Beziehung besteht, handelt es sich um ein *Interaktions-* oder *Aggregationsmerkmal*. Folgende Sachverhalte lassen sich mit Beziehungsmerkmalen ausdrücken:

- a) **Mengenverhältnis:** Mit wie viel anderen Objektinstanzen interagiert eine Objektinstanz? Aus wie vielen Instanzen eines Teilobjekttyps setzt sich eine Instanz zusammen?
- b) **Häufigkeit:** Wie oft interagieren die Objektinstanzen zweier Objekttypen?
- c) **Spezifität:** Wie intensiv ist die Objektbeziehung oder wie lange dauert die Beziehung an?

Zum Beispiel kann ein Lager durch die „Anzahl der eingelagerten Lebensmittel“ oder ein Lebensmittel durch die „Anzahl der Inhaltsstoffe“ charakterisiert werden (siehe Abbildung 41). Das Gleiche gilt für eine Interaktionsbeziehung zwischen den Instanzen der Objekttypen KUNDE und HÄNDLER. Falls ein Händler nicht nur einen, sondern mehrere Kunden hat, lässt sich dies durch das Merkmal „Anzahl der Kunden“ ausdrücken. Das Merkmal „Anzahl der Wiederholkäufe“ beschreibt hingegen die Häufigkeit, mit der ein Kunde bei einem Händler einkauft. Ein Merkmal, das die Spezifität einer Beziehung ausdrückt, wäre die Verweildauer eines Kunden in einer Filiale während eines Einkaufs oder das Bestellvolumen einer Bestellung. Stantzt eine Maschine ein Blech, ist die aufgewendete Presskraft ein spezifisches Merkmal für die Interaktion zwischen den Objekttypen MASCHINE und WERKSTÜCK.

Um den Wert eines Beziehungsmerkmals zu bestimmen, müssen stets die Objektinstanzen zweier Objekttypen betrachtet werden. Der Wert eines *Eigenschaftsmerkmals* spezifiziert hingegen eine Objekteigenschaft, die ein Objekt unabhängig von seiner Beziehung zu anderen Objektinstanzen charakterisiert. Die Dimension eines Eigenschaftsmerkmals wird beispielsweise in Form von Temperatur-, Maß- oder Gewichtseinheiten angegeben. Auch die Farbe oder das Alter eines Objekts ist als Eigenschaftsmerkmal zu sehen.

Bei der Frage, welchem Objekttyp ein Objektmerkmal zuzuordnen ist, kann zwischen *originären* und *abgeleiteten Merkmalen* differenziert werden. Welcher dieser Merkmalskategorien ein Merkmal angehört, entscheidet sich, wenn man den merkmals tragenden Objekttyp isoliert betrachtet. Bei einer isolierten Betrachtung fokussiert man sich allein auf den merkmals tragenden Objekttyp und - sofern es sich um ein Beziehungsmerkmal handelt - zusätzlich auf den Objekttyp, den das Beziehungsmerkmal referenziert. Ein Merkmal ist genau dann ein originäres Merkmal, wenn es jede der drei Bedingungen erfüllt - andernfalls ist es ein Merkmal, das von einem anderen Objekttyp abgeleitet wurde:

1. Für jede Objektinstanz kann selbst dann ein eigener Merkmalswert bestimmt werden, wenn der Objekttyp isoliert betrachtet wird.
2. Die erste Bedingung ist für alle *Subobjekttypen* des merkmals tragenden Objekttyps erfüllbar.
3. Die erste Bedingung ist für alle höherrangigen Objekttypen (*Superobjekttypen* und *aggregierte Objekttypen*) unerfüllbar.

Modelliert man beispielsweise den Objekttyp SUBNOTEBOOK als Spezialisierung des Objekttyps NOTEBOOK und diesen wiederum als Spezialisierung des Objekttyps COMPUTER, handelt es sich bei dem Eigenschaftsmerkmal Preis um das originäre Merkmal des Superobjekttyps COMPUTER. Bei einem Notebook oder einem seiner Subobjekttypen wäre es hingegen als abgeleitetes Merkmal zu werten. Andernfalls würde dies der Bedingung drei widersprechen, da sich für jede Objektinstanz des Superobjekttyps COMPUTER ein Preis angeben lässt. Hat man dem Subobjekttyp NOTEBOOK den Teilobjekttyp AKKU hinzugefügt, dann wäre die Anzahl der Akkus ein originäres Merkmal des aggregierten Objekttyps NOTEBOOK. Bei seinem Teilobjekttyp AKKU wäre es hingegen ein abgeleitetes Merkmal. Denn bei einer isolierten Betrachtung kann für einen einzelnen Akku keine Anzahl von Akkus angegeben werden - es handelt sich schlicht um die falsche Aggregationsebene. Auch beim Objekttyp SUBNOTEBOOK wäre die Anzahl der

Akkus ein abgeleitetes Merkmal, da Bedingung drei nicht erfüllt ist. Als originäres Merkmal eines Akkus käme hingegen seine elektrische Ladung infrage, die sich etwa in Milliamperestunden angeben lässt.

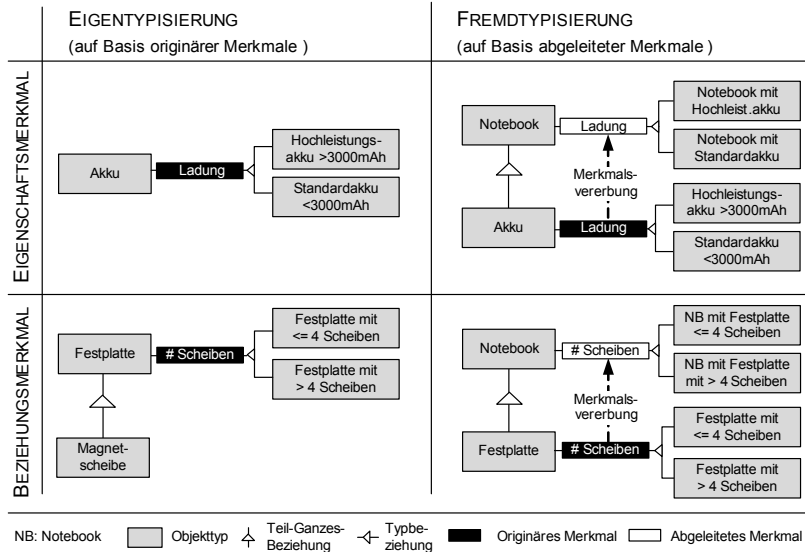


Abbildung 42: Möglichkeiten zur Bildung von Subobjekttypen

Durch eine *Merkmalsvererbung* lässt sich ein originäres Merkmal einem fremden Objekttyp zuordnen, bei dem es zu einem abgeleiteten Merkmal wird. Voraussetzung für eine Merkmalsvererbung ist, dass beide Objekttypen entweder direkt oder transitiv in einer der drei genannten Objektbeziehungen stehen. Abbildung 42 fasst verschiedene Möglichkeiten zur Merkmalsvererbung und Bildung von Subobjekttypen an einem Beispiel zusammen.

Abgeleitete Merkmale können ebenso wie originäre Merkmale zur Bildung von Subobjekttypen verwendet werden. Je nachdem, ob das zur Bildung eines Subobjekttyps verwendete Merkmal originär oder abgeleitet ist, handelt es sich um eine *Eigen-* oder *Fremdtypisierung*. Eine Eigen- oder Fremdtypisierung ist sowohl mit Eigenschafts- als auch mit Beziehungsmerkmalen möglich. Vererbt man beispielsweise das Eigenschaftsmerkmal elektrische Ladung vom Objekttyp AKKU über die Teil-Ganzes-Beziehung an den aggregierten Objekttyp NOTEBOOK, kann jedes Notebook danach unterschieden werden, ob es einen Akku mit mehr oder weniger als 3000 mAh besitzt.

Speziell für die Typbeziehung gilt, dass ein originäres Merkmal zwar problemlos vom Superobjektyp zum Subobjektyp vererbt werden kann, nicht aber notwendigerweise in umgekehrter Richtung. So wäre zum Beispiel die Akkulaufzeit unter Volllast ein originäres Eigenschaftsmerkmal des Objektyps NOTEBOOK. Vererbt man dieses Merkmal an den Subobjektypen SUBNOTEBOOK, lassen sich dort Subnotebooks mit langer und kurzer Akkulaufzeit unterscheiden. Eine Vererbung dieses Merkmals an den Superobjektyp COMPUTER wäre aber unzulässig, da sich nicht für jede Instanz vom Typ COMPUTER ein numerischer Wert für die Akkulaufzeit bestimmen lässt, etwa für einen Computer vom Typ DESKTOP-COMPUTER, der nur über eine abhängige Stromversorgung verfügt.

Der bislang erläuterte Zusammenhang zwischen den verschiedenen Objektypen und ihren Objektbeziehungen kann in Form eines Meta-Modells festgehalten werden, das in Abbildung 43 dargestellt ist. Es spezifiziert die Modellbausteine und Beziehungen, auf die man bei der Modellkonstruktion auf der Objektebene zurückgreifen kann.

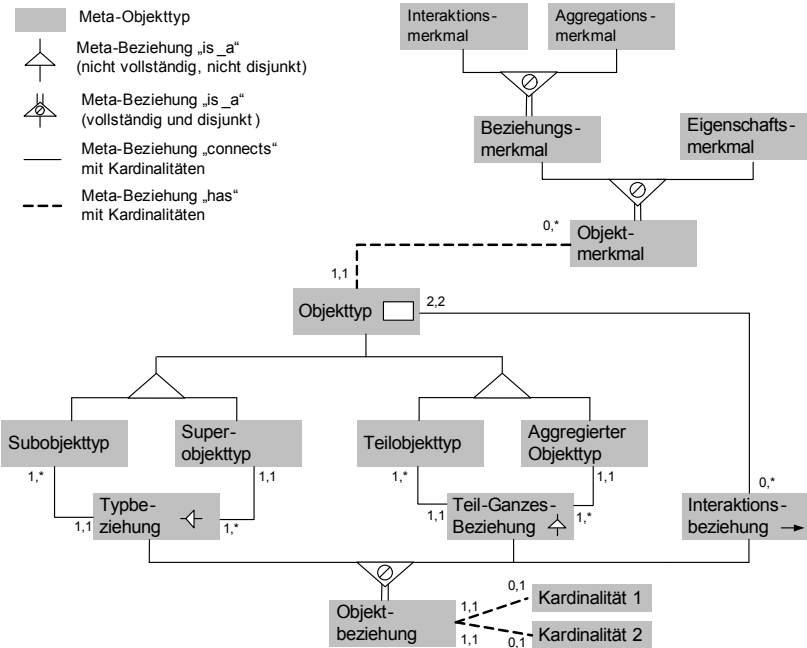


Abbildung 43: Meta-Modell der Objektebene

Eine Objektbeziehung ist entweder eine Interaktions-, Typ- oder Teil-Ganzes-Beziehung. Wie viele Objektinstanzen eines Objekttyps mit wie vielen Instanzen eines anderen Objekttyps in Beziehung stehen, kann über die Angabe von zwei Kardinalitäten spezifiziert werden (0,1), wobei jede Kardinalität exklusiv einer Objektbeziehung zugeordnet ist (1,1). Eine Typbeziehung ist die Spezialisierung einer Objektbeziehung und ist als solche mindestens einem Subobjekttyp (1,*) sowie genau einem Superobjekttyp zugeordnet (1,1). Ein Superobjekttyp kann allerdings mehrere Typbeziehungen (1,*) besitzen, was die Bildung alternativer Typhierarchien ermöglicht. Während eine Teil-Ganzes-Beziehung genau einen aggregierten Objekttyp (1,1) mit mindestens einem Teilobjekttyp (1,*) verknüpft, besitzt ein aggregierter Objekttyp eine oder mehrere Teil-Ganzes-Beziehungen (1,*). Jeder aggregierte Objekttyp, Teilobjekttyp sowie Sub- und Superobjekttyp ist ein Objekttyp. Hierbei ist es möglich, dass ein Objekttyp aufgrund seiner Objektbeziehungen mehrere Rollen gleichzeitig ausübt. So kann ein Objekttyp zum Beispiel gleichzeitig Super-, Sub- und Teilobjekttyp sein. Neben der Teil-Ganzes- und der Typbeziehung kann ein Objekttyp eine oder mehrere Interaktionsbeziehungen besitzen (0,*), wobei eine Interaktionsbeziehung stets zwei Objekttypen verknüpft (2,2).

Darüber hinaus können jedem Objekttyp mehrere Objektmerkmale zugeordnet werden (0,*), wobei sich ein Objektmerkmal auf genau einen Objekttyp bezieht (1,1). Ein Objektmerkmal ist entweder ein Eigenschafts- oder Beziehungsmerkmal, wobei sich ein Beziehungsmerkmal zusätzlich entweder als Interaktions- oder Aggregationsmerkmal klassifizieren lässt. Dieses differenzierte Begriffsverständnis über Objekttypen und ihre Beziehungen kann nun auf der Ereignisebene dazu genutzt werden, ein ebenso differenziertes Verständnis über Ereignistypen und Kausalbeziehungen zu entwickeln.

5.2.1.2 Ereignistypen und Kausalbeziehungen der Ereignisebene

Analog zur Objektebene erfolgt die Modellierung auf der Ereignisebene nicht aus der Instanz-, sondern aus der Typsicht. Folglich werden auch keine Einzelereignisse, sondern ausschließlich Ereignistypen modelliert. Während ein Einzelereignis die Zustandsänderung einer Objektinstanz beschreibt, fasst ein Ereignistyp gleichartige Ereignisse zu einer Klasse zusammen (siehe Abschnitt 5.1.3.2). Je nachdem, ob das Ereignis die Änderung eines Eigenschafts- oder Beziehungsmerkmals beschreibt, lassen sich folgende Ereignistypen unterscheiden:

- Ein *Eigenschaftsereignis* beschreibt die Merkmalswertänderung eines Eigenschaftsereignisses.
- Ein *Beziehungsereignis* beschreibt eine Veränderung im Beziehungsgefüge einer Objektinstanz und somit die Merkmalswertänderung eines Beziehungsmerkmals. Abhängig von der Art der Objektbeziehung handelt es sich um
 - ein *Aggregationsereignis*, wenn sich die Aggregationsbeziehung zu den Teilobjektinstanzen ändert,
 - ein *Interaktionsereignis*, wenn sich die Interaktionsbeziehung zu interagierenden Objektinstanzen verändert,
 - ein *Typwechselereignis*, wenn sich die Typbeziehung und somit die Zugehörigkeit einer Objektinstanz zu einem Subobjekttyp ändert.

Im Folgenden werden zunächst die verschiedenen Ereignistypen vorgestellt und anschließend die kausalen Beziehungen zwischen den Ereignistypen erläutert.

Ein *Eigenschaftsereignis* zeigt die Veränderung einer Objekteigenschaft an, die auf der Objektebene durch ein Eigenschaftsmerkmal repräsentiert wird. Handelt es sich um ein nominal skaliertes Eigenschaftsmerkmal, beschreibt das Ereignis den diskreten Wechsel von einem Vor- in einen Nachzustand, etwa wenn sich die Farbe eines Objekts von grün in rot ändert. Ist das Merkmal hingegen metrisch oder ordinal skaliert, kann zwischen einer Erhöhung und einer Verringerung des Merkmalswertes differenziert werden. Ein Eigenschaftsereignis liegt zum Beispiel vor, wenn sich das Budget eines Projekts oder die Motivation der Projektmitarbeiter erhöht. Ereignisträger eines Eigenschaftsereignisses ist stets derjenige Objekttyp, dem das sich ändernde Eigenschaftsmerkmal als originäres Merkmal zuzuordnen ist.

Das Gegenstück zu einem Eigenschaftsereignis ist das *Beziehungsereignis*. Das *Aggregationsereignis* zeigt an, dass sich bei einem Objekt der Wert eines Aggregationsmerkmals und somit die Anzahl der Instanzen eines Teilobjekttyps verändert hat. Je nachdem, ob sich die Anzahl der Teilobjektinstanzen erhöht oder verringert, werden entweder neue Teil-Ganzes-Beziehungen geknüpft oder bestehende Teil-Ganzes-Beziehungen aufgelöst. Als Ereignisträger fungiert stets der aggregierte Objekttyp, da ihm das Beziehungsmerkmal als originäres Merkmal zuzuordnen ist (siehe Abschnitt 5.2.1.2). Ein Aggregationsereignis liegt zum Beispiel vor, wenn sich bei einem Projekt die Anzahl der Projektmitarbeiter verringert oder erhöht.

Um ein *Interaktionsereignis* handelt es sich, wenn sich der Merkmalswert eines Interaktionsmerkmals ändert. So kann sich zum Beispiel die Anzahl der interagierenden Objektinstanzen erhöhen oder verringern, etwa wenn die Zahl der Mitarbeiter ansteigt, die auf einen zentralen Datenserver zur Durchführung ihrer Projektaufgaben zugreifen. Um ein Interaktionsereignis handelt es sich auch, wenn zwar die Anzahl der interagierenden Objektinstanzen gleich bleibt, sich aber die Häufigkeit der Interaktionen verändert. Ein solches Ereignis ließe sich möglicherweise gegen Ende eines Projekts beobachten, falls die Mitarbeiter vermehrt auf den Datenserver zugreifen müssten. Ereignisträger eines Interaktionsereignisses ist der Objekttyp, dem das Beziehungsmerkmal als objekt eigenes Merkmal zuzuordnen ist.

Im Gegensatz zu den drei anderen Ereignisarten beschreibt ein *Typwechselergebnis* die mögliche Konsequenz einer oder mehrerer Merkmalsänderungen: einen Typwechsel. Hierbei verliert eine Objektinstanz die Zuordnung zu ihrem aktuellen Objekttyp und wird eine Instanz eines anderen Subobjekttyps. Ob ein Typwechsel stattfindet, hängt davon ab, welches der typbildenden Merkmale sich wie geändert hat. Jedes Typwechselergebnis kann daher auf ein Eigenschafts-, Interaktions- oder Aggregationsereignis zurückgeführt werden. Unterscheidet man beispielsweise A- und B-Projekte nach der Höhe des Projektbudgets, kann ein B-Projekt zu einem A-Projekt werden (Typwechselergebnis), falls sich sein Budget entsprechend erhöht (Eigenschaftsereignis).

Ein Typwechselergebnis beschreibt entweder einen *bidirektionalen* oder *unidirektionalen Typwechsel*. Bei einem unidirektionalen Typwechsel kann eine Objektinstanz ihren Typ nur in eine Richtung wechseln und ihren ursprünglichen Typ nicht mehr zurückerhalten. Ein bidirektionaler Typwechsel impliziert hingegen, dass die Typänderung auch in umgekehrter Richtung verlaufen kann. Auf diese Weise setzt sich ein bidirektionales Typwechselergebnis aus zwei gegenläufigen unidirektionalen Typwechselergebnissen zusammen. Um ein Typwechselergebnis formulieren zu können, benötigt man ein differenziertes Objektvokabular, das neben den beiden Subobjekttypen auch den gemeinsamen Superobjekttyp mit einschließt. Ereignisträger eines unidirektionalen Typwechsels ist stets derjenige Subobjekttyp, dem eine Objektinstanz vor ihrem Typwechsel angehört. Ein bidirektionales Typwechselergebnis muss hingegen dem gemeinsamen Superobjekttyp der beiden Subobjekttypen zugeordnet sein. Falls ein A-Projekt wieder in ein B-Projekt zurückgestuft werden kann, lässt sich ein bidirektionales Typwechselergebnis formulieren, dessen Ereignisträger der Superobjekttyp PROJEKT ist.

Um die kausalen Zusammenhänge zwischen den verschiedenen Ereignissen beschreiben zu können, müssen diese kausal verknüpft werden. Hierbei ist zwischen *gleichläufigen* und *gegenläufigen Kausalbeziehungen* zu differenzieren (vgl. [Ster00, S. 142-143]). Diese Differenzierung beruht auf dem von Forrester entwickelten Ansatz zur systemdynamischen Modellierung (*System Dynamics*) (vgl. [Forr61]).¹ Bei einer gleichläufigen Kausalbeziehung verändern sich die von den Ereignistypen referenzierten Objektmerkmale in die gleiche Richtung. Eine gleichläufige Kausalbeziehung liegt zum Beispiel vor, wenn sich nach einer Erhöhung des Projektbudgets die Zuverlässigkeit und Qualität der Computer erhöht, da diese nun regelmäßig gewartet oder durch neuere Computer ersetzt werden können. Gegenläufig ist eine Kausalbeziehung, wenn sich die Objektmerkmale in entgegengesetzte Richtung entwickeln, etwa wenn die Erhöhung der Mitarbeitermotivation bei den Mitarbeitern zu einer Verringerung der krankheitsbedingten Fehltagel führt.

Eine gleich- oder gegenläufige Kausalbeziehung setzt voraus, dass sich beide Ereignistypen auf ein metrisches oder zumindest ordinal skaliertes Objektmerkmal beziehen, das sich erhöhen oder verringern kann. Ein solcher Merkmalsbezug fehlt jedoch, falls es sich um ein Typwechselereignis oder um ein Eigenschaftsereignis handelt, das sich auf ein nominal skaliertes Eigenschaftsmerkmal bezieht. Statt eines Objektmerkmals erhöht oder verringert sich hier die Wahrscheinlichkeit eines Ereigniseintritts. So erhöht oder verringert sich zum Beispiel die Wahrscheinlichkeit, dass ein B-Projekt in ein A-Projekt eingestuft wird (Typwechsel), wenn sich das Projektbudget erhöht oder verringert. Beide Ereignisse können deshalb durch eine gleichläufige Kausalbeziehung verknüpft werden. Abbildung 44 fasst einige Kausalbeziehungen des Projektbeispiels zusammen und zeigt, welchem Objekttyp die Ereignistypen jeweils zugeordnet sind.

¹ Obwohl sich die Art der Kausalmodellierung an die der systemdynamischen Modellierung orientiert, liegt dieser Arbeit ein differenzierterer Ereignisbegriff zugrunde, indem die Ereignisse konsequent auf Objektmerkmale der als Ereignisträger fungierenden Objekte zurückgeführt werden. Die systemdynamische Modellierung verzichtet hingegen auf eine Betrachtung von Objekten und Objektbeziehungen, was dazu führt, dass den Variablen eines System-Dynamics-Modells ein über die Kausalbeziehung hinaus gehender Zusammenhang fehlt. Da die verwendeten Variablen so oft beliebig und zusammenhangslos wirken, erschwert dies die Lesbarkeit von System-Dynamics-Modellen (siehe Abbildung 1).

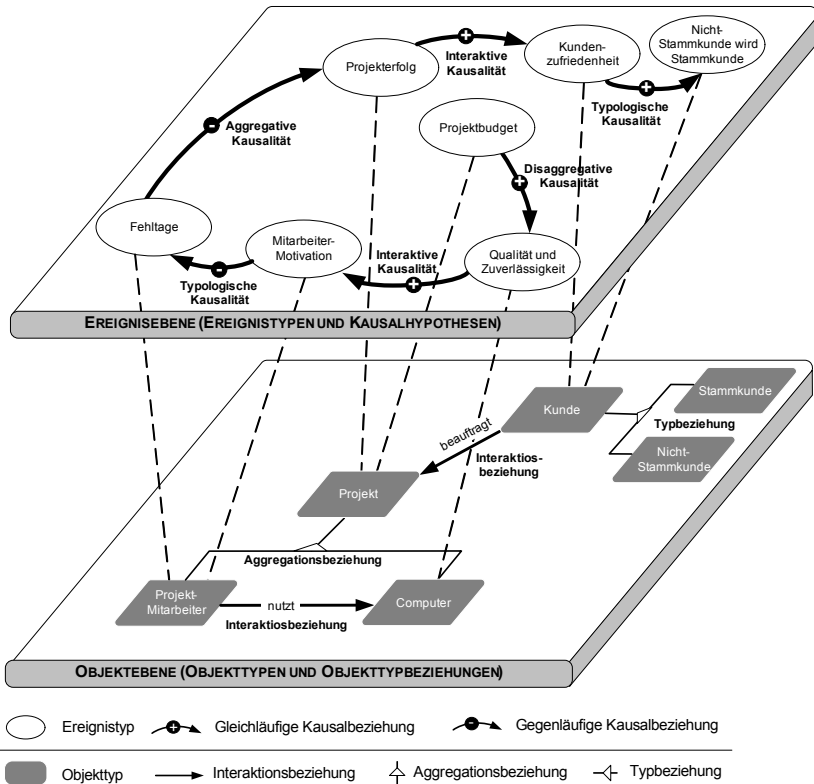


Abbildung 44: Beispiel einer typbezogenen Kausalarchitektur

Neben der Unterscheidung in gleich- und gegenläufig sind die Kausalbeziehungen in Abbildung 44 auch anhand der Ereignisträger und Objektbeziehungen differenziert. Anhand der Teil-Ganzes-Beziehung der Objektebene kann auf der Ereignisebene zwischen einer *aggregativen* und einer *disaggregativen Kausalbeziehung* differenziert werden. Bei einer aggregativen Kausalbeziehung bezieht sich das Ursachenergebnis auf einen Teilobjekttyp; die Kausalbeziehung verläuft vom Teil zum Ganzen. Ein Beispiel für eine aggregative Kausalhypothese ist die Aussage, dass der Erfolg eines Projekts umso größer sein wird, desto weniger Fehltag die Projektmitarbeiter aufweisen (siehe Abbildung 44). Bei einer disaggregativen Kausalbeziehung kehrt sich die kausale Richtung um. Die Kausalbeziehung

lung läuft nun vom Ganzen zum Teil, da sich das Wirkungsereignis auf den Teilobjekttyp bezieht. Eine disaggregative Kausalbeziehung liegt zum Beispiel bei der Vermutung vor, dass sich mit einer Erhöhung des Projektbudgets die Qualität und Zuverlässigkeit der Computer erhöht.

Eine *interaktive Kausalbeziehung* liegt vor, wenn die Ereignisträger des Ursachen- und Wirkungsereignisses zwei miteinander interagierende Objekttypen sind. Um eine interaktive Kausalbeziehung handelt es sich zum Beispiel, wenn die Motivation der Projektmitarbeiter von der Zuverlässigkeit und Bedienbarkeit der Computer beeinflusst wird, die sie zur Verrichtung ihrer Projektaufgaben nutzen (siehe Abbildung 44). Würden die Mitarbeiter die Computer nicht zur Verrichtung ihrer Aufgaben benötigen und infolge dessen nicht mit diesen interagieren, bliebe eine Verringerung der Computerausfälle für die Motivation der Mitarbeiter wirkungslos. Eine interaktive Kausalbeziehung liegt auch vor, wenn angenommen wird, dass ein erfolgreiches Projekt die Kundenzufriedenheit steigert. Dieser Kausalbeziehung liegt eine Interaktionsbeziehung zwischen den Objekttypen KUNDE und PROJEKT zugrunde, da ein Kunde den Auftrag für ein Projekt erteilt und dieses initiiert.

Die dritte und letzte Kausalart ist die *typologische Kausalbeziehung*. Sie basiert auf der Typbeziehung und ist, verglichen mit den anderen Kausalarten, ein Sonderfall. Ursachen- und Wirkungsereignis beziehen sich nicht auf verschiedene, sondern auf denselben Objekttyp. Eine typologische Kausalbeziehung ist beispielsweise die Behauptung, dass eine „*Erhöhung der Kundenzufriedenheit*“ zu mehr Wiederholkäufen führt und somit die Wahrscheinlichkeit erhöht, dass ein Kunde zu einem Stammkunden wird. Sowohl das Ursachen- als auch das Wirkungsereignis beschreiben Merkmalsänderungen am gleichen Objekttyp - in diesem Beispiel am Objekttyp KUNDE (siehe Abbildung 44).

Einen typologischen Kausalzusammenhang formuliert man meist dann, wenn sich für das Ursachen- und das Wirkungsereignis keine unterschiedlichen Objekttypen angeben lassen, oder wenn die Komplexität der Kausalbeschreibung bewusst reduziert werden soll. Der erste Fall trifft zu, wenn man über ein zu geringes Objektvokabular verfügt und nicht in der Lage ist, einen Objekttyp anhand einer Teil-Ganzes-Beziehung in Teilobjekttypen aufzuspalten. Aus diesem Grund kann der oben genannte Zusammenhang zwischen der Zufriedenheit eines Kunden und seiner Bereitschaft für einen Wiederholkauf trotz zahlreicher Fortschritte in der Hirnforschung nicht exakt anhand von neurobiologischen Prozessen beschrieben werden. Was fehlt ist das Objektvokabular über die beteiligten Hirnregionen und ihre neuronalen Interaktionen. Einen typologischen

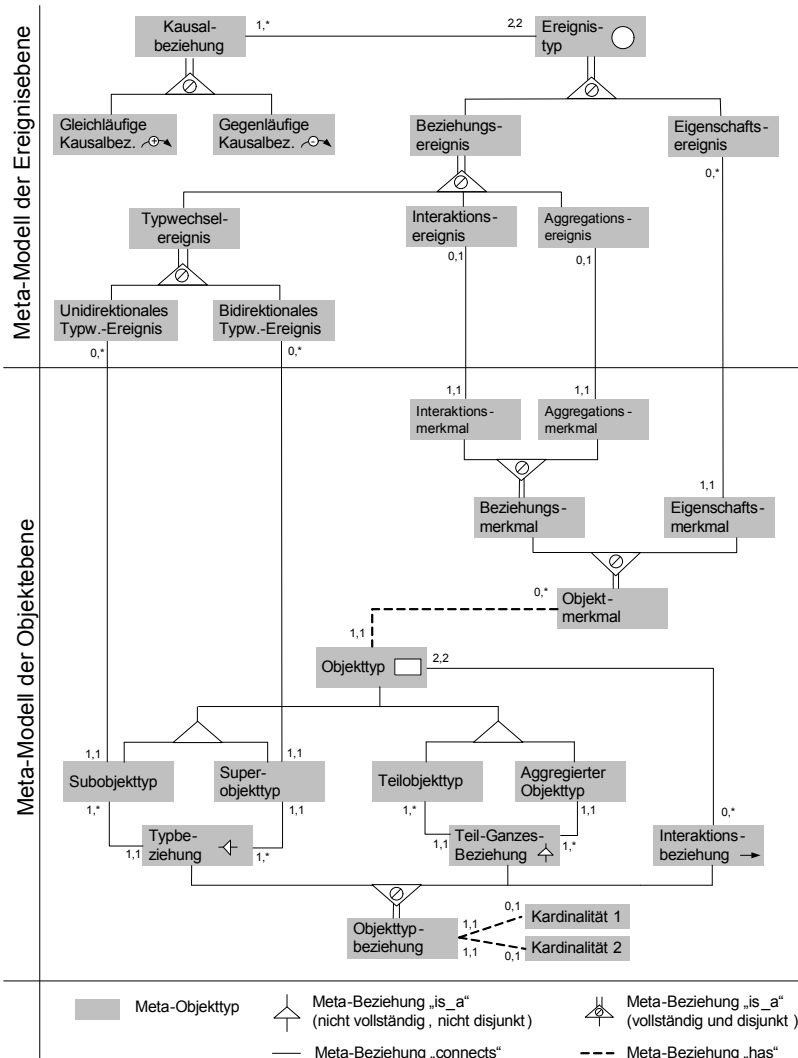


Abbildung 45: Integriertes Meta-Modell der typbezogenen Kausalarchitektur

Kausalzusammenhang, der aufgelöst wurde, findet man hingegen zwischen den beiden Ereignissen „Erhöhung des Projektbudgets“ und der „Zunahme des Pro-

jekterfolgs“. Da die an dem Kausalzusammenhang beteiligten Teilobjekttypen COMPUTER und PROJEKTMITARBEITER bekannt sind, kann der typologische Kausalzusammenhang aufgelöst und auf einer niedrigeren Aggregationsebene konkretisiert werden.

Die Modellbausteine und Beziehungen der Ereignisebene lassen sich in einem Meta-Modell spezifizieren, das zusammen mit dem der Objektebene ein integriertes Meta-Modell der typbezogenen Kausalarchitektur bildet (siehe Abbildung 45).

Ein Ereignistyp ist entweder ein Eigenschafts- oder ein Beziehungsereignis. Ein Eigenschaftsereignis beschreibt die Veränderung genau eines Eigenschaftsmerkmals (1,1). Da ein Eigenschaftsmerkmal auch nominal skaliert sein kann, lassen sich einem solchen Eigenschaftsmerkmal auch mehrere Eigenschaftsereignisse zuordnen (0,*) - je nachdem welche Merkmalswertkombinationen einen gültigen Zustandswechsel beschreiben. Ein Beziehungsereignis ist entweder ein Typwechsel-, Interaktions- oder Aggregationsereignis. Während sich ein Interaktions- und Aggregationsereignis auf genau ein Interaktions- bzw. Aggregationsmerkmal bezieht (1,1), bezieht sich ein Typwechselereignis entweder auf genau einen Subobjekttyp (1,1), falls es ein unidirektionales Typwechselereignis ist, oder auf genau einen Superobjekttyp (1,1), falls es als bidirektionales Typwechselereignis spezifiziert ist. Sowohl einem Interaktions- als auch einem Aggregationsmerkmal kann höchstens ein Interaktions- bzw. Aggregationsereignis zugeordnet werden (0,1). Ein Sub- oder Superobjekttyp kann hingegen auch Ereignisträger mehrerer uni- bzw. bidirektionaler Typwechselereignisse sein (0,*). Eine Kausalbeziehung verknüpft als gleich- oder gegenläufige Kausalbeziehung genau zwei Ereignistypen (2,2), wogegen ein Ereignistyp in mindestens einer Kausalbeziehung mit anderen Ereignistypen steht (1,*).

5.2.2 Instanzbezogene Kausalarchitektur

Analog zur typbezogenen Kausalarchitektur gliedert sich auch die instanzbezogene Kausalarchitektur in eine Ereignis- und eine Objektebene. Anstatt jedoch Ereignis- und Objekttypen zu enthalten, richtet sich der Blick nun auf einzelne Ereignis- und Objektinstanzen. Diese werden auf der Objekt- und Ereignisebene anhand spezifischer Merkmale beschrieben und in Form von Ereignis- und Objektdaten abgebildet. Welche Ereignis- und Objektmerkmale sich hierbei unterscheiden lassen und welcher Zusammenhang zwischen Objekt- und Ereignisdaten besteht, zeigen die folgenden beiden Abschnitte.

5.2.2.1 Objektdaten der Objektebene

Auf der Objektebene der instanzbezogenen Kausalarchitektur können die Zustände derjenigen Objektinstanzen beschrieben werden, deren Objekttypen auch Bestandteil der typbezogenen Kausalarchitektur sind. Gemäß der in Abschnitt 5.2.1.1 vorgenommenen Merkmalsdifferenzierung können die Zustände der Objektinstanzen sowohl anhand von Eigenschafts- als auch anhand von Beziehungsmerkmalen beschrieben werden. Um die Struktur dieser Datenbasis zu definieren, kann ein konzeptuelles Datenschema erstellt werden (vgl. [FeSi08, S. 145]). Je nachdem, ob man zur Strukturdefinition ein relationales oder ein objektorientiertes Datenbankmodell verwendet, handelt es sich bei dem Datenschema um ein Typ-basiertes, Klassen-Typ-basiertes oder Klassen-basiertes Schema (vgl. [Heue97, S. 298-299]).

Sämtliche Merkmalswerte der Eigenschafts- und Beziehungsmerkmale können Zeitpunkt bezogen erfasst werden. Das bedeutet, dass jeder Merkmalswert den Objektzustand einer Objektinstanz zu einem bestimmten Zeitpunkt widerspiegelt. Falls sich die Merkmalswerte eines Interaktionsmerkmals nur kumulativ ermitteln lassen, ist ein Zeitraum zu spezifizieren. Dies ist etwa bei Beziehungsmerkmalen erforderlich, die die Häufigkeit von Interaktionen wiedergeben sollen. Diese sind dann über einen längeren Zeitraum hinweg zu erfassen und zu addieren. Auf diese Weise lässt sich zum Beispiel die Anzahl der Bestellungen ermitteln, die von einem Kunden innerhalb eines Jahres aufgegeben wurden. Die Merkmalswerte eines Objektmerkmals lassen sich auch in Form von Mittelwerten verdichten.

Bei den Objektdaten kann zwischen auf einen *Zeitpunkt bezogenen Objektdaten* und den *Zeitverlauf beschreibenden Objektdaten* unterschieden werden. Bei Zeitpunkt bezogenen Objektdaten beziehen sich die Merkmalswerte eines Merkmals auf denselben Zeitpunkt, aber auf unterschiedliche Objektinstanzen. Die Merkmalswerte verschiedener Merkmale können jedoch unterschiedlichen Zeitpunkten zugeordnet sein. So lassen sich zum Beispiel die Umsatzdaten des dritten Quartals zusammen mit den Auftragsseingängen des ersten Quartals in einer Tabelle darstellen und vergleichen. Sollen die Objektdaten die Entwicklung der Merkmalswerte im Zeitverlauf darstellen, müssen Merkmalswerte für mehrere, aufeinander folgende Zeitpunkte verfügbar sein. Dies führt bei einem numerischen Merkmal zu einer Zeitreihe, bei einem nominal skalierten Merkmal zu einer Sequenz. Nur wenn die Merkmalswerte verschiedener Zeitpunkte vorhan-

den sind, können Vor- und Nachzustände unterschieden und die Objektdaten in Ereignisdaten transformiert werden. Welche Ereignismerkmale sich hierbei unterscheiden lassen und in welchem Bezug sie zu den Objektmerkmalen stehen, zeigt der folgende Abschnitt.

5.2.2.2 Ereignisdaten der Ereignisebene

Ereignisdaten beschreiben die bereits eingetretenen Ereignisse anhand von Ereignismerkmalen. Die Ereignismerkmale charakterisieren die Zustandsänderungen, von denen die Objektinstanzen der Objektebene betroffen sind. Diese Zustandsänderungen manifestieren sich in den Merkmalswertänderungen ihrer Objektmerkmale. Unabhängig von der Art des Ereignisses können folgende Ereignismerkmale unterschieden werden:

- *Ereigniseintritt*: Welche Zustandsänderung hat sich ereignet? Hat sich der Zustand eines Objektmerkmals überhaupt geändert?
- *Ereignisintensität*: In welchem Maße hat sich der Zustand geändert?
- *Ereigniszeitpunkt*: Wann hat sich der Zustand geändert?
- *Ereignisdauer*: Über welchen Zeitraum hat sich die Zustandsänderung erstreckt?

Ein *Ereigniseintritt* lässt sich ermitteln, indem man Merkmalswerte eines Objektmerkmals zu verschiedenen Zeitpunkten vergleicht. Eine Zustandsänderung - und somit ein Ereignis - ist eingetreten, wenn sich beide Merkmalswerte voneinander unterscheiden. Handelt es sich bei dem Objektmerkmal um ein nominal skaliertes Merkmal, lässt sich der Ereigniseintritt auf zweierlei Art in der Datenbasis abbilden: Die erste Möglichkeit besteht darin, dass man für jede Zustandsänderung des nominal skalierten Objektmerkmals ein eigenes Ereignismerkmal bildet. Jedem dieser Ereignismerkmale ordnet man einen binären Wertebereich zu, dessen Werte anzeigen, ob sich das entsprechende Ereignis ereignet hat oder nicht. Als zweite Möglichkeit lassen sich sämtliche Merkmalsänderungen eines nominal skalierten Objektmerkmals mit nur einem Ereignismerkmal beschreiben. Der Wertebereich des Ereignismerkmals muss dann entsprechend erweitert werden, so dass jede mögliche Zustandsänderung durch einen eigenen Merkmalswert codiert wird. Differenziert man beispielsweise seine Kunden in A-, B- und C-Kunden, können insgesamt sechs verschiedene Zustandsänderungen unterschieden werden: ein Wechsel von A nach B, von A nach C, von B nach A, von B nach C, von C nach A sowie von C nach B.

Besitzt ein Objektmerkmal kein nominales, sondern ein ordinales oder metrisches Skalenniveau, lässt sich mit jedem Ereignisseintritt auch die *Ereignisintensität* bestimmen. Die Intensität eines Ereignisses ist identisch mit dem Ausmaß der Zustandsänderung und errechnet sich aus der Differenz der beiden Merkmalswerte. Dabei ist zu beachten, dass das Ausmaß der Zustandsänderung von der Wahl der Vergleichszeitpunkte abhängt. Die Zustandsänderung selbst sagt nichts darüber aus, wie sich der Merkmalswert in der Zeitspanne dazwischen entwickelt hat. Möchte man zum Beispiel den Zu- oder Abgang an gelagerten Produkten beschreiben, kann als Ereignismerkmal die Differenz zwischen dem aktuellen und einem früheren Lagerbestand verwendet werden. Doch selbst wenn beide Lagerbestände identisch sind und den Augenschein nach keine Zustandsänderung stattgefunden hat, kann der Lagerbestand zwischenzeitlich dennoch auf null gesunken oder sogar auf ein Vielfaches des aktuellen Lagerbestands gestiegen sein. Die Ereignisintensität kann entweder mit absoluten Zahlenwerten oder als prozentuale Veränderung angegeben werden.

Auch der *Ereigniszeitpunkt* kann häufig nur näherungsweise bestimmt werden. Denn selbst wenn man in dem obigen Beispiel einen Anstieg des Lagerbestands feststellen würde, könnte sich der Lagerbestand erst am Ende des Zeitintervalls, also kurz vor dem zweiten Zeitpunkt, erhöht haben.

Ebenso wie der tatsächliche Ereigniszeitpunkt nicht mit dem Zeitpunkt des ersten Merkmalswertes zusammenfallen muss, muss auch die tatsächliche *Ereignisdauer* nicht mit dem Zeitintervall zwischen den Messpunkten übereinstimmen. Die Ereignisdauer gibt an, über welchen Zeitraum man den Zustandswechsel beobachtet hat. Da bei nominal skalierten Objektmerkmalen nur ein diskreter Zustandsübergang möglich ist, kann eine Ereignisdauer nur für Veränderungen von numerischen oder ordinal skalierten Objektmerkmalen bestimmt werden.

Um Intensität, Zeitpunkt und Dauer eines Ereignisses präzise zu bestimmen, dürfen die Zeitpunkte der verglichenen Merkmalswerte nicht willkürlich ausgewählt werden. Stattdessen müssen sie im Hinblick auf den bisherigen Zeitreihen- bzw. Sequenzverlauf bestimmt werden. In Abschnitt 5.3.1.2 werden später Verfahren vorgestellt, mit denen sich Veränderungen und Strukturbrüche in Zeitreihen und Sequenzen automatisch entdecken lassen.

Analog zur Unterscheidung auf der Objektebene, kann auch auf der Ereignisebene zwischen auf einen *Zeitpunkt bezogenen Ereignisdaten* und den *Zeitverlauf beschreibenden Ereignisdaten* differenziert werden. Insgesamt stehen für die datenzentrierte Kausalanalyse vier verschiedene Arten von Daten zur Verfügung.

- *Ereignisdaten*, die die Ereignisse auf einen Zeitpunkt bezogen beschreiben,

- *Ereignisdaten*, die die Ereignisse im Zeitverlauf beschreiben,
- *Objektdaten*, die die Objektzustände Zeitpunkt bezogen beschreiben,
- *Objektdaten*, die die Entwicklung der Objektzustände im Zeitverlauf beschreiben.

Die grundlegenden Verfahren, mit denen sich die Daten der instanzbezogenen Kausalarchitektur für die Kausalanalyse nutzen lassen, werden im dritten und letzten Abschnitt dieses Kapitels vorgestellt.

5.3 Datenzentrierte Analyseverfahren

Bei der datenzentrierten Kausalanalyse untersucht man die Ereignis- und Objektdaten der instanzbezogenen Kausalarchitektur. Je nachdem, ob neue Kausalhypothesen entwickelt oder bereits vorhandene Hypothesen überprüft werden sollen, lassen sich unterschiedliche Analyseverfahren einsetzen. Während sich mit *hypothesengetriebenen Analyseverfahren* eine bereits vorhandene Hypothese überprüfen lässt, verfolgt man mit *datengetriebenen Analyseverfahren* das umgekehrte Ziel: Die Frage lautet nicht mehr, ob die Daten eine bestimmte Hypothese stützen oder widerlegen, sondern welche Hypothesen die Daten überhaupt stützen können (vgl. [Drei94, S. 33], [Pyle99, S. 31]).

Diese Umkehrung der Zielsetzung hat zur Folge, dass der Raum möglicher Analyseergebnisse ungleich größer ist als bei der Hypothesenprüfung; in der Regel kommen nicht nur zwei oder drei, sondern eine Vielzahl an Hypothesen als Analyseergebnis infrage. Da sich der Ergebnisraum bei einer derart offenen Fragestellung nicht eindeutig bestimmen lässt, kann mit hypothesengetriebenen Verfahren nur ein kleiner Teil des gesamten Hypothesenraums erkundet werden: zum einen, weil man möglicherweise bestimmte Hypothesen unbewusst außer Acht lässt, zum anderen, weil die manuelle Überprüfung sämtlicher Hypothesen schlicht zu aufwändig wäre.

Aus diesem Grund benötigt man für die Aufgabe der Hypothesenentwicklung eine andere Klasse von Analyseverfahren; man benötigt Verfahren, die die Defizite einer manuellen Analyse ausgleichen, indem sie den Datenbestand automatisiert nach Datenmustern durchsuchen und somit den Raum möglicher Hypothesen ungerichtet und ergebnisoffen explorieren. Da man sich bei der Auswahl und Anwendung der Verfahren nicht mehr an vorgegebenen Hypothesen orientieren kann, prägen stattdessen die verfügbaren Analysedaten den Analyse-

verlauf. Aus diesem Grund werden diese Verfahren als datengetrieben charakterisiert.

Im folgenden Abschnitt 5.3.1 werden zunächst die datengetriebenen Analyseverfahren erläutert, bevor in Abschnitt 5.3.2 die hypothesengetriebenen Analyseverfahren vorgestellt werden.

5.3.1 Datengetriebene Analyseverfahren

In der Literatur wird die datengetriebene Analyse vor allem mit den Verfahren des Data-Minings gleichgesetzt, während man das Online-Analytical-Processing (OLAP) sowie die Verfahren der traditionellen Statistik zur hypothesengetriebenen Analyse rechnet. Die Grenze zwischen einer daten- und hypothesengetriebenen Analyse entpuppt sich allerdings als eine idealtypische; zumindest dann, wenn man versucht, diese Grenze auf der Ebene der Analysemethoden zu ziehen. Gegen eine solche Grenzziehung spricht zweierlei: Zum einen beruhen viele der zum Data-Mining gerechneten Verfahren auf Methoden der traditionellen Statistik (vgl. [KrWZ98, S. 89], [HaMS01, S. 18]), zum anderen verfügt auch die Statistik über Verfahren, die eine hypothesenfreie, explorative Datenanalyse erlauben (vgl. [Homb88]).

Um die datengetriebene Data-Mining-Analyse von der explorativen Datenanalyse abzugrenzen, muss man den Blick auf die Analysedaten und den Automatisierungsgrad der Verfahren richten. Die statistischen Methoden des Data-Minings sind algorithmisch so optimiert, dass sie auf viel größeren und umfangreicheren Datenbeständen operieren können, als dies im Rahmen der traditionellen Statistik üblich, aber auch möglich ist (vgl. [Pyle99, S. 31], [HaMS01, S. 19]).¹ Hinzu kommt, dass das Data-Mining neben statistischen Methoden auch Ansätze aus anderen Disziplinen integriert, etwa aus dem Bereich des maschinellen Lernens oder der Künstlichen Intelligenz (vgl. [FaPS96, S. 12]). Aufgrund seines interdisziplinären Charakters kann das Data-Mining nicht auf eine bestimmte Methodengruppe eingeschränkt werden (vgl. [Küpp99, S. 20]). Auch entstehen häufig erst durch die Verknüpfung verschiedener Methoden neue Data-Mining-Verfahren. Solche hybriden Verfahren würden bei einer derartigen Data-Mining-Definition zwangsläufig fehlen (vgl. [Knob00, S. 4]).

¹ Die Frage, „Was ist neu am Data Mining?“ [Klad01, S. 455] wird im Fachbereich der Statistik kontrovers diskutiert. So wundert sich beispielsweise Krämer: „Warum sich den Kopf zerbrechen, um das letzte Quantum an Information aus einem festen Datensatz herauszuziehen, wenn der gleiche Informationsgewinn viel schneller, quasi per Knopfdruck durch Vergrößerung der Datenbasis gleichfalls zu erzielen wäre“ [Kräm01, S. 197].

Eine mittlerweile akzeptierte und in der Literatur vielfach zitierte Definition verzichtet daher auf die Angabe einer Methodengruppe und bezieht sich nur auf die Zielsetzung und die Ergebnisse der Analyse. In Anlehnung an die von Fayyad et al. vertretene Auffassung zum *Knowledge Discovery in Databases* (siehe Abschnitt 6.2; vgl. [FaPS96, S. 6]) wird Data-Mining im Folgenden als „die nicht-triviale Entdeckung gültiger, neuer, potenziell nützlicher und verständlicher Muster in Datenbeständen“ [Knob00, S. 14] bezeichnet.

Ein Muster ist eine Aussage über eine Teilmenge von Daten, die einfacher ist, als es die Aufzählung der einzelnen Daten wäre (vgl. [FrPM91, S. 3], [Biss96, S. 6], [Mult00, S. 48]). Obwohl dieser Musterbegriff „jedwede Beziehung zwischen Datensätzen, einzelnen Feldern, den Daten innerhalb eines Satzes und bestimmte Regelmäßigkeiten“ [Biss96, S. 6] einschließt, lassen sich vier verschiedene Mustertypen abgrenzen. Da ein Datenmuster das Ergebnis einer durchgeführten Data-Mining-Aufgabe ist, korrespondiert jeder Mustertyp mit einem Data-Mining-Aufgabentyp (vgl. [PiMe03, S. 63]). Jeder Aufgabentyp besitzt eine eigene Klasse von Data-Mining-Verfahren, die jeweils einen bestimmten Mustertyp erzeugen. Jedes dieser Data-Mining-Verfahren kann wiederum mit unterschiedlichen Analysemethoden implementiert werden. Folgende vier Data-Mining-Aufgabentypen lassen sich unterscheiden:

- *Segmentierung* (siehe Abschnitt 5.3.1.1): Bei der Segmentierung werden Datenobjekte mit ähnlichen Merkmalsausprägungen zu homogenen Gruppen - so genannten Segmenten oder Clustern - zusammengefasst.
- *Abweichungsanalyse* (siehe Abschnitt 5.3.1.2): Bei der Abweichungsanalyse werden diejenigen Datenobjekte identifiziert (und gegebenenfalls anhand ihrer Merkmale charakterisiert), deren Merkmalswerte von einem bestimmten Referenzwert abweichen oder deren zeitlicher Werteverlauf ein erwartetes Verlaufsmuster durchbricht.
- *Assoziationsanalyse* (siehe Abschnitt 5.3.1.3): Bei der Assoziationsanalyse werden Abhängigkeits- oder Assoziationsbeziehungen aufgedeckt, die zwischen den Merkmalswerten nominal oder ordinal skaliert Merkmale bestehen.
- *Prognose und Klassifikation* (siehe Abschnitt 5.3.1.4): Bei der Prognose oder Klassifikation versucht man, speziell solche Assoziations- und Abhängigkeitsbeziehungen zwischen den Merkmalen aufzudecken, mit denen sich entweder ein numerischer (Prognose) oder ein klassifikatorischer Merkmalswert (Klassifikation) vorhersagen bzw. bestimmen lässt.

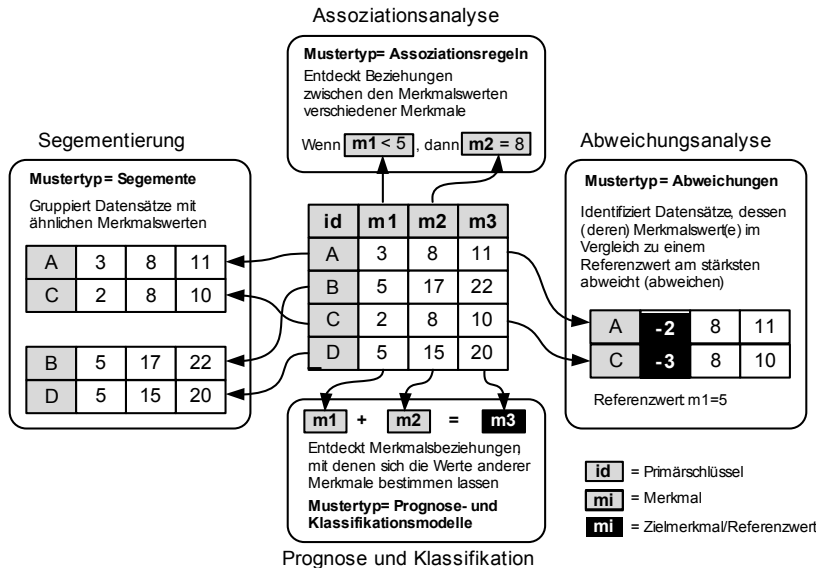


Abbildung 46: Datenmuster und Aufgabentypen des Data-Minings

Die von den Data-Mining-Verfahren erzeugten Muster können in zwei weitere Gruppen eingeteilt werden: Ein Datenmuster charakterisiert entweder die Beziehungen zwischen Datenobjekten, das sind in einer Datentabelle die Datensätze bzw. die Zeilen (vgl. [OtOK04, S. 149]), oder es beschreibt die Beziehungen zwischen den Werten mehrerer Merkmale, das sind die Spalten einer Datentabelle. Während die *Segmentierung* und die *Abweichungsanalyse* die Beziehungen zwischen den Datenobjekten offenlegen, untersucht man bei der *Abweichungsanalyse* und der *Prognose und Klassifikation* die Beziehungen zwischen den Merkmalswerten (siehe Abbildung 46).

Im Folgenden werden die vier Aufgaben- und Mustertypen näher erläutert und zusammen mit den bedeutendsten Verfahren aus der jeweiligen Verfahrensklasse vorgestellt. Da sich jedes Analyseverfahren mit verschiedensten Methoden realisieren lässt und auch die Entwicklung der Methoden stetig fortschreitet, wird nur punktuell auf die Analysemethoden einzelner Verfahren verwiesen.

5.3.1.1 Segmentierung

Die Segmentierung untersucht die Beziehung zwischen den Datenobjekten. Diese Beziehung beruht auf dem Grad der Ähnlichkeit zweier Datenobjekte hinsichtlich der Merkmalsausprägungen ihrer Merkmale. Ziel der Segmentierung ist es, ähnliche Datenobjekte zu identifizieren und diese in Gruppen zusammenzufassen. Hierbei sollen die Datenobjekte eines Segments ähnliche Merkmalswerte aufweisen, während sich die Datenobjekte verschiedener Segmente durch möglichst unterschiedliche Merkmalswerte auszeichnen sollen (vgl. [Biss96, S. 52], [CHS + 98, S. 66]).

Die dem Data-Mining zuzurechnenden Verfahren der Segmentierung können nach verschiedenen Kriterien differenziert werden, beispielsweise nach der Anzahl der vorzugebenden Segmente, dem Skalenniveau der Analysemerkmale oder danach, ob die Segmentzuordnung eindeutig ist oder auf Basis von Wahrscheinlichkeitswerten vorgenommen wird. Die in der Literatur am häufigsten anzutreffende Differenzierung erfolgt jedoch nach der Struktur der erzeugten Segmenteinteilung in hierarchische und partitionierende Verfahren. Im Gegensatz zu partitionierenden Verfahren erzeugen *hierarchische Verfahren* nicht nur eine Segmenteinteilung, sondern eine Hierarchie aus alternativen Segmenteinteilungen, die sich entweder durch die sukzessive Aufspaltung (Top-Down-Vorgehen) oder die Vereinigung von Segmenten (Bottom-Up-Vorgehen) ergeben (vgl. [Grab00, S. 341]). Bei einer sukzessiven Aufspaltung spricht man von *divisiven Verfahren*, im umgekehrten Fall von *agglomerativen Verfahren*.

Divisive Verfahren beginnen mit nur einem Segment, das zunächst alle Datenobjekte enthält. Dieses Segment wird so lange in disjunkte Teilsegmente aufgespalten, bis entweder eine vorher spezifizierte Abbruchbedingung erfüllt ist, oder bis keine weitere Aufspaltung mehr möglich ist, etwa wenn sich jedes Segment nur noch aus Datenobjekten zusammensetzt, deren Merkmalswerte vollständig übereinstimmen. Auf diese Weise entsteht ein Baum, bei dem jeder Knoten einem Segment entspricht und die Knoten einer Hierarchieebene eine vollständige Segmenteinteilung bilden.

Agglomerative Verfahren arbeiten in entgegengesetzter Richtung: Beginnend mit der maximal möglichen Anzahl der Segmente, werden bei jedem Schritt zwei Segmente zu einem neuen Segment verschmolzen. Sofern keine Abbruchbedingung spezifiziert wurde, münden agglomerative Verfahren ebenfalls in einen Baum, dessen Wurzelknoten am Ende des Verfahrens alle Datenobjekte enthält.

Ob ein hierarchisches Verfahren eine grob- oder feinmaschige Segmentierung erzeugt, hängt von der Hierarchieebene ab, auf der das Verfahren abgebrochen wird. Als einfache Abbruchbedingung lässt sich zum Beispiel die gewünschte Anzahl der Segmente angeben (vgl. [Biss96, S. 53], [Mult00, S. 84]). Fehlt eine solche Abbruchbedingung, so ist der Anwender nach der Analyse gezwungen, diejenige Hierarchieebene auszuwählen, deren Segmentierung ihm im Hinblick auf das Analyseziel als am interessantesten und nützlichsten erscheint.

Im Gegensatz zu den hierarchischen Segmentierungsverfahren, die ihre Segmentierung ausschließlich durch Aufspaltung (divisive Verfahren) oder Vereinigung von Segmenten (agglomerative Verfahren) erzeugen, optimieren *partitionierende Verfahren* eine initiale Segmentierung. Diese initiale Segmentierung wird entweder vom Verfahren selbst oder vom Anwender festgelegt. Im Anschluss wird für jedes Datenobjekt geprüft, ob es aufgrund seiner Ähnlichkeitsbeziehung nicht einem anderen Segment zugeordnet werden kann. Zusätzlich wird bei jedem Schritt auch die Generierung eines neuen Segments in Erwägung gezogen. Dies wird so lange wiederholt, bis das Optimum einer vorher festgelegten Zielfunktion erreicht ist oder sich keine bessere Segmentierung mehr erzeugen lässt. Die partitionierenden Verfahren unterscheiden sich einerseits darin, wie die initiale Segmentierung erzeugt wird, andererseits in den Kriterien, nach denen sie die Güte alternativer Segmentierungen beurteilen (vgl. [NeKn05, S. 278]). Die drei Hauptvertreter der partitionierenden Segmentierung sind

- die K-Means-Segmentierung,
- die demografische Segmentierung und
- die Segmentierung mithilfe eines künstlichen neuronalen Netzes.

Im Gegensatz zu den K-Means-Verfahren ermittelt die demografische Segmentierung die Anzahl der Segmente erst im Laufe des Verfahrens (vgl. [Küst01, S. 113]). Beide Verfahren besitzen den Vorteil, dass sie die Datenobjekte einer Segmentierung zwischen den Segmenten austauschen können. Nachteilig ist allerdings, dass selbst dann, wenn eine stabile Segmentierung erreicht wurde, nicht sicher ist, ob es sich um ein lokales oder globales Optimum handelt (vgl. [NeKn05, S. 279]). Im Folgenden wird speziell die Funktionsweise der K-Means-Segmentierung näher erläutert, da diese später auch im Rahmen der Fallstudie angewandt wird (siehe Abschnitt 7.2.2).

Den K-Means Verfahren muss mit der Variable k die Segmentanzahl vorgegeben werden. Ihre initiale Segmenteinteilung bestimmen diese Verfahren selbst, indem sie aus der Menge der Datenobjekte für jedes Segment ein Objekt nach dem Zufallsprinzip auswählen, das als Keimzellenobjekt das vorläufige Zentrum des jeweiligen Segments bildet (vgl. [BeLi04, S. 354], [WiEi05, S. 137]). Im zweiten Schritt wird jedes Datenobjekt dem Segment zugeordnet, dessen Keimzellenobjekt ihm am ähnlichsten ist. Sind alle Datenobjekte aufgeteilt, wird versucht, für jedes inzwischen befüllte Segment ein neues Datenobjekt als Keimzellenobjekt zu bestimmen, das aufgrund seiner Ähnlichkeitswerte die geringste Distanz zu den anderen Datenobjekten des eigenen Segments aufweist. Schritt zwei wird nun wiederholt, indem abermals die Ähnlichkeit sämtlicher Datenobjekte mit den Keimzellenobjekten geprüft wird. Auf diese Weise können einzelne Datenobjekte ihre aktuelle Segmentzuordnung verlieren und in ein anderes Segment verschoben werden. Das Verfahren bricht entweder nach einer bestimmten Anzahl von Durchläufen ab, oder wenn keine Umverteilung mehr erfolgt, da eine stabile Segmenteinteilung erreicht wurde (vgl. [BeLi04, S. 356]).

Anders als die K-Means- und die demografische Segmentierung sind neuronale Netze nicht nur für die Segmentierung, sondern auch für andere Aufgabentypen von Bedeutung. Künstliche neuronale Netze bilden die Informationsverarbeitung des menschlichen Gehirns nach, indem sie die Erregungszustände und Verknüpfungen von Nervenzellen simulieren. Eine Nervenzelle wird durch die Impulse anderer Nervenzellen erregt, die mit dieser verknüpft sind. Wie stark ein Neuron erregt wird, hängt von der Gewichtung der Neuronenverbindung ab. Eine Verbindung ist umso höher gewichtet, je stärker und häufiger die Reizübertragung zwischen den beiden Neuronen ist. Die Verbindung schwächt sich ab, wenn nur wenige oder gar keine Impulse übertragen werden.

Die Kerneigenschaft eines neuronalen Netzes ist es, dass sich die gewünschte Verbindungsstruktur zwischen der Ein- und Ausgabeschicht im Laufe des Verfahrens selbst herausbildet. Dies geschieht, indem die Verbindungsgewichte nach einem bestimmten Lernverfahren automatisch verändert und angepasst werden. Das Herausbilden der „richtigen“ Verbindungsgewichte erfolgt entweder mit einem überwachten oder unüberwachten Lernverfahren.

Überwachte Lernverfahren wendet man an, wenn dem neuronalen Netz ein bestimmtes Input-Output-Verhalten antrainiert werden soll, etwa um Merkmalswerte zu prognostizieren (siehe Abschnitt 5.3.1.4). In einer Trainingsphase sind dem Netz die Input-Daten sowie die damit zu assoziierenden Output-Werte vorzugeben. Input- und Output-Daten bilden zusammen die Trainingsdaten. Wäh-

rend der Trainingsphase passt das Netz die Verbindungsgewichte so an, dass es zu einer schrittweisen Annäherung an die gewünschte Input-Output-Relation kommt. Nach der Trainingsphase kann das neuronale Netz dazu verwendet werden, die Output-Werte der Zieldaten abzuschätzen, deren Input-Output-Relation noch unbekannt ist. Auf *unüberwachte Lernverfahren* greift man zurück, wenn es nicht darum geht, bereits bekannte Strukturen nachzubilden, sondern - wie bei der Segmentierung - neue Strukturen zu entdecken (vgl. [PoSi01, S. 366]). Ein unüberwachtes Lernverfahren nutzt auch eine *Selbstorganisierende Merkmalskarte* (Self-Organizing-Feature-Map), die sich ebenfalls für die Segmentierung eignet (vgl. [PoSi98, S. 394]).

5.3.1.2 Abweichungsanalyse

Ebenso wie der Aufgabentyp der Segmentierung untersucht auch die Abweichungsanalyse die Beziehungen zwischen den Datenobjekten, den Zeilen einer Datentabelle (siehe Abbildung 21, Seite 139). Anders als bei der Segmentierung, bei der sich die Ähnlichkeit der Datenobjekte aus dem Vergleich mehrerer Merkmalswerte ergibt, nutzt die Abweichungsanalyse in ihrer einfachsten Form nur ein einziges Zielmerkmal zur Gruppenbildung. Zwei Datenobjekte sind sich ähnlich, wenn die Merkmalswerte dieses Zielmerkmals ähnlich stark von einem vorher festgelegten Referenzwert abweichen. Auf diese Weise lassen sich die am stärksten abweichenden Datenobjekte identifizieren und gegebenenfalls von weniger stark oder nicht abweichenden Datenobjekten abgrenzen. Abhängig von dem Zeitpunkt, auf den sich der Referenzwert des Zielmerkmals bezieht, lassen sich zwei Arten von Abweichungen unterscheiden (vgl. [HiWi01, S. 64]):

- Die *Längsschnittabweichung* beschreibt die Veränderung eines Merkmalswertes im Zeitverlauf. Sie resultiert aus der Differenz zwischen einem Merkmals- und einem Referenzwert, die sich auf jeweils unterschiedliche Zeitpunkte t_0 und t_1 beziehen.
- Die *Querschnittsabweichung* beschreibt die Differenz eines Merkmalswertes von einem Referenzwert. Referenz- und Merkmalswert beziehen sich auf denselben Zeitpunkt t_0 .

Spezielle Verfahren der Abweichungsanalyse versuchen nicht nur die abweichenden Datenobjekte zu identifizieren, sondern zusätzlich die Ähnlichkeiten zwischen den abweichenden Datenobjekten zu beschreiben. Ziel ist es, in der Gruppe der abweichenden Datenobjekte möglichst große und homogene Seg-

mente zu finden, deren Merkmalswerte sich ähneln oder identisch sind. Diese Ähnlichkeiten können dann ggf. als Hinweis auf die Abweichungsursachen interpretiert werden. Ein solches Verfahren ist die von Hagedorn vorgeschlagene *Top-Down-Navigation* (vgl. [Hage96, S. 22]), deren Funktionsweise im Folgenden kurz erläutert wird.

Die Motivation für die Top-Down-Navigation entspringt einer aus dem Controlling bekannten Fragestellung: Wie lassen sich bei einer Fülle von Bezugsobjekten und Zeitpunkten die unterschiedlichen Kennzahlenentwicklungen und -abweichungen im Auge behalten, die sich angesichts der zahlreichen Vergleichsmöglichkeiten zwischen Ist-, Plan-, Soll- und Prognosewerten ergeben (vgl. [Küpp97, S. 171])? Anstatt auffällige Abweichungen zu analysieren und deren Ursachen zu bestimmen, verbringen nicht wenige Controller einen Großteil ihrer Zeit mit der Suche nach diesen Auffälligkeiten (vgl. [Hage96, S. 1]). Zudem besteht speziell in einem multidimensionalen Datenraum (siehe Abschnitt 5.3.2.1) die Gefahr, dass Kennzahlenabweichungen auf unteren Aggregationsebenen aufgrund von Kompensationseffekten unentdeckt bleiben (vgl. [Hage96, S. 63], [Oehl06, S. 88]). Dies ist beispielsweise der Fall, wenn sich die negativen und positiven Deckungsbeiträge einzelner Produkte auf der Ebene der Produktparten ausgleichen.

Als Lösung für dieses Problem schlägt Hagedorn eine Art automatisiertes Lotensystem vor, das den Nutzer innerhalb der Kennzahlenhierarchie genau zu den Datenobjekten führt, die die bedeutendsten Abweichungen aufweisen. Anschließend analysiert das System die Datenobjekte autonom anhand ihrer Kennzahlenwerte, indem es diese mit den Werten von übergeordneten und benachbarten Objekten vergleicht (vgl. [Hage96, S. 22-23]). Ziel derartiger Lotensysteme ist es, dem Anwender „den richtigen Weg durch immense Datenbestände zu weisen“ [MeBH95, S. 234]. Ausgehend von einer Gesamtabweichung werden dem Anwender dann diejenigen Dimensionen und Merkmale vorgeschlagen, die die Abweichung aufgrund ihrer Signifikanz am besten erklären. Obwohl sich die Top-Down-Navigation sowohl für die Analyse von Längs- als auch Querschnittsabweichungen eignet, wird der zugrunde liegende Mechanismus am Beispiel einer Längsschnittabweichung erläutert (siehe Abbildung 47):

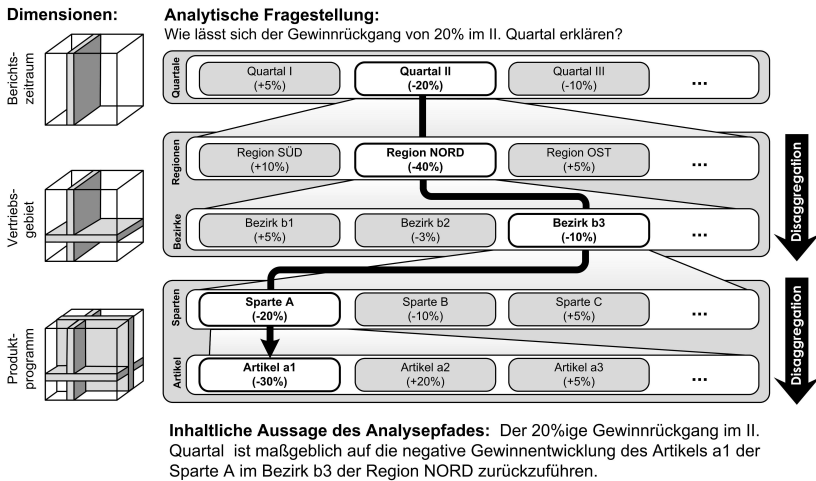


Abbildung 47: Beispiel eines Analysepfades der Top-Down-Navigation

Um den 20%igen Gewinnrückgang des zweiten Quartals zu erklären, konkurrieren verschiedene Dimensionen um die höchste Erklärungswahrscheinlichkeit: Der Berichtszeitraum, das Vertriebsgebiet und das Produktprogramm. Dem Controller wird in dem Beispiel zunächst die Dimension *Vertriebsgebiet* mit der Hierarchieebene *Region* vorgeschlagen, da der Gewinneinbruch hauptsächlich aus der 40%igen Abweichung in der Region Nord resultiert. Diese regionale Abweichung würde dann automatisch bis auf die Hierarchieebene *Bezirk* disaggregiert und in einem nächsten Schritt mit der Dimension des *Produktprogramms* verknüpft werden. Die Abweichung ist zwar zunächst auf der Hierarchieebene *Sparte* ausgewiesen, lässt sich aber anschließend auf die Ebene der einzelnen *Artikel* disaggregieren. Fazit der automatischen Top-Down-Navigation wäre, dass der 20%ige Gewinnrückgang im zweiten Quartal hauptsächlich auf die negative Gewinnentwicklung des Artikels a1 der Sparte A im Bezirk b3 in der Region Nord zurückzuführen ist (siehe Abbildung 47).

Während die Top-Down-Navigation die auf einen Zeitpunkt bezogene Abweichung von einem Referenz- oder Zielwert analysiert, ermöglicht die *Zeitreihenanalyse* die Identifikation abweichender Werteverläufe. Eine Zeitreihe ist „eine Sequenz von Zahlenwerten (...), die in einer zeitlichen Reihenfolge geordnet sind“ [Mult00, S. 104] Die Zeitreihenanalyse ist eine spezielle Form der Längsschnittanalyse (vgl. [HiWi01, S. 39]), die aber auf einem weiter gefassten

Abweichungsbegriff beruht: Die Zeitreihenanalyse betrachtet Abweichungen als Bruch einer Zeitreihe mit einem bestimmten Verlaufsmuster. In Anlehnung an Küsters und Bell können insgesamt sechs Arten von Zeitreihenabweichungen entdeckt werden (vgl. [KüBe01, S. 282-283]), deren charakteristischer Werteverlauf in Abbildung 23 skizziert ist:

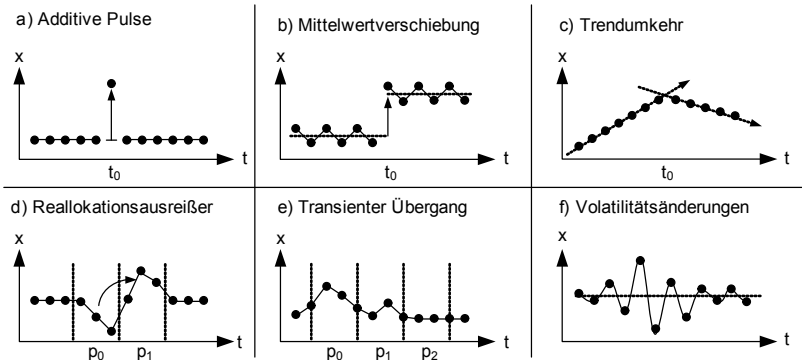


Abbildung 48: Charakteristischer Werteverlauf von Zeitreihenabweichungen

- a) *additive Pulse* sind einzelne Ausreißerwerte zu einem Zeitpunkt t_0 , die sich stark von den Werten benachbarter Zeitpunkte unterscheiden.
- b) *Mittelwertverschiebungen* beschreiben eine zum Zeitpunkt t_0 auftretende systematische Erhöhung bzw. Senkung des Zeitreihenmittelwerts.
- c) *Trendänderungen* beschreiben den Richtungswechsel eines lokalen Auf- oder Abwärtstrends zum Zeitpunkt t_0 .
- d) *Reallokationsausreißer* ähneln einer Stauwelle, indem sich die kumulierten Werte einer Periode p_0 in die Folgeperiode p_1 verschieben und sich dort, einer Welle gleich, anhäufen.
- e) *Transiente Übergänge* beschreiben punktuelle Störungen, die sich in den Folgeperioden sukzessiv abschwächen und schließlich wieder ganz zurückbilden.
- f) *Volatilitätsänderungen* bezeichnen Veränderungen hinsichtlich der Schwankung eines Wertes um einen Mittelwert. Der Mittelwert selbst wird von den Schwankungsänderungen aber nicht verändert.

Bevor sich derartige Strukturbrüche in einer Zeitreihe identifizieren lassen, muss zunächst das stabile Verlaufsmuster entdeckt werden, das als Referenzmuster „den ungestörten Normalfall“ [KüBe01, S. 282] beschreibt. Zu diesem Zweck können die Komponenten einer Zeitreihe getrennt voneinander beschrieben werden. Eine Zeitreihe setzt sich typischerweise aus mindestens einer der folgenden Komponenten zusammen:

- einem Trend;
- einem oder mehreren überlappenden Zyklen;
- einer Rauschkomponente bestehend aus unregelmäßigen, zufälligen Störungen.

Zu den Verfahren, mit denen man das Referenzmuster einer Zeitreihe beschreiben und Strukturbrüche entdecken kann, zählen neben einer rein visuellen Zeitreiheninspektion auch rechnerische Verfahren, wie zum Beispiel die exponentielle Glättung, ARIMA-, Box-Jenkins- oder dynamische Regressionsmodelle (vgl. [KüBe01]). Verglichen mit anderen Data-Mining-Verfahren nimmt die Zeitreihenanalyse im Data-Mining bislang nur eine Nebenrolle ein. Während die Anwendung der Top-Down-Navigation bislang vor allem im Controlling geschildert wurde (vgl. [Hage96]), ist die Zeitreihenanalyse selbst im bedeutendsten Anwendungsbereich des Data-Minings, dem Marketing, nur selten dokumentiert (vgl. [KüBe01, S. 291]). Doch wie Kapitel 6 noch zeigen wird, ist die Zeitreihenanalyse gerade für die Kausalanalyse von Bedeutung, da sich mit ihrer Hilfe das Ereignisvokabular erweitern lässt. Denn abhängig von der Periodenlänge können beispielsweise konjunkturelle, saisonale oder kalenderbedingte Schwankungen entdeckt werden (vgl. [Spet04, S. 1]).

5.3.1.3 Assoziationsanalyse

Im Gegensatz zu den bislang vorgestellten Verfahren, bei denen die Beziehungen zwischen den *Datenobjekten* beschrieben werden, untersucht die Assoziationsanalyse die Beziehungen zwischen den Merkmalen der Datenobjekte (vgl. [HiWi01, S. 43]). Eine Merkmalsbeziehung ist entweder

- eine ungerichtete Verknüpfung,
- eine gerichtete Abhängigkeit oder
- ein zeitlich gerichtetes Sequenzmuster.

Zwei Merkmale sind über eine *Verknüpfung* verbunden, wenn bei mehreren Datenobjekten die gleiche Kombination von Merkmalswerten auftritt. Um eine Verknüpfung herstellen zu können, müssen die Merkmalswerte einer gemeinsamen Bezugsgröße zuordenbar sein, die als eine Art logische Klammer die Merkmalswerte zu einer Gruppe zusammenfasst (vgl. [NeKn05, S. 222]). Auf diese Weise verknüpft etwa ein Flug zwei Flughäfen miteinander, während sich die Kunden eines Mobilfunkanbieters aufgrund ihrer Anrufe einander zuordnen lassen (vgl. [BeLi97, S. 216-217]).

Im Gegensatz zur Verknüpfung beschreibt eine *Abhängigkeit* die Richtung einer Merkmalsbeziehung. Dies ist zum Beispiel der Fall, wenn in einer Datenbank die Flugbewegungen von Fluggästen verzeichnet sind und der Flughafen Bamberg ausschließlich zusammen mit dem Flughafen Nürnberg auftaucht, während der Flughafen Nürnberg aber noch zahlreiche andere Flugverbindungen zu anderen Flughäfen besitzt. Die Beziehung zwischen den Flughäfen Bamberg und Nürnberg ist deshalb nicht mehr symmetrisch, sondern asymmetrisch. Vergleicht man nämlich die bedingten Häufigkeiten der Flugverbindungen, lässt sich folgende Abhängigkeitsbeziehung formulieren: *Wenn* der Abflughafen eines Passagiers Bamberg ist, *dann* ist Nürnberg mit 100%iger Sicherheit sein Zielflughafen.

Ein *Sequenzmuster* beschreibt die zeitlichen Abhängigkeiten, die zwischen zwei oder mehreren Elementen bestehen. Eine zeitliche Abhängigkeit liegt dann vor, wenn zwei oder mehrere Elemente häufig in der gleichen Reihenfolge auftreten. Voraussetzung für die Bildung von Sequenzmustern ist, dass sich die Elemente unterschiedlichen Zeitpunkten zuordnen lassen. Untersucht man zum Beispiel das Bestellverhalten von Versandhandelskunden, könnte folgende charakteristische Bestellsequenz entdeckt werden: Wenn ein Kunde einen Staubsauger kauft, dann wird er in den nächsten vier Monaten auch einen Staubsaugerbeutel kaufen. Im Bereich des Internets lassen sich mittels Sequenzanalyse auffällige Navigationsmuster entdecken, die angeben, welche Internetseiten von den Besuchern einer Homepage typischerweise nacheinander besucht werden.

Die Aussagekraft und Interessantheit der gefundenen Merkmalsbeziehungen lässt sich anhand verschiedener Gütemaße beurteilen. Der *Support*, auch als Abdeckungsgrad (vgl. [OtOK04, S. 187]) oder Reichweite (vgl. [NeKn05, S. 225]) bezeichnet, gibt an, wie viele Datenobjekte in der Datenbasis die jeweilige Verknüpfung, Abhängigkeit oder Sequenz unterstützen (vgl. [HeHi01, S. 429]).

Speziell für die Abhängigkeitsbeziehung kann zusätzlich der *Confidence* und *Lift*-Wert betrachtet werden.¹ Die *Confidence* setzt die Datenobjekte, deren Merkmalswerte der Wenn-Dann-Regel folgen, zu den Datenobjekten ins Verhältnis, die nur den Dann-Teil erfüllen (vgl. [HeHi01, S. 445]). Der *Lift*-Wert gibt an, wie viel Mal häufiger Datenobjekte, die die Wenn-Bedingung erfüllen, auch den Dann-Teil erfüllen, als es im Vergleich mit allen anderen Datenobjekten zu erwarten gewesen wäre (vgl. [HeHi01, S. 447]). Ein *Lift*-Wert von drei, der einen Verbundkauf zwischen Biogemüse und fair gehandeltem Kaffee beschreibt, würde beispielsweise anzeigen, dass Käufer von Biogemüse dreimal so häufig fair gehandelten Kaffee kaufen wie alle übrigen Käufer.

Um die Zahl der Assoziationsregeln zu begrenzen, erlauben die Verfahren das Setzen von Schwellwerten für die Gütemaße. Bei der Interpretation der *Support*-, *Confidence*- oder *Lift*-Werte lassen sich keine allgemeingültigen Regeln angeben (vgl. [OtOK04, S. 189]). So weist eine Regel mit einem niedrigen *Support*-Wert zwar auf einen geringen Anwendungsbereich hin, kann aber dennoch einen für die Beantwortung der analytischen Fragestellung bedeutsamen Zusammenhang abbilden (vgl. [HeHi01, S. 445]). Grundsätzlich empfiehlt es sich zumindest bei der Abhängigkeitsanalyse nicht nur eine, sondern stets mehrere Kenngrößen zu berücksichtigen (vgl. [HeHi01, S. 445], [NeKn05, S. 239]). Abbildung 49 veranschaulicht die Berechnung der verschiedenen Kenngrößen anhand des Flugdatenbeispiels.

Flugdaten		Abhängigkeits- beziehungen	Gütemaße		
			Support	Confidence	Lift
Abflughafen (AF)	Zielflughafen (ZF)	Wenn AF = Bamberg, dann ZF = Nürnberg	3/6 = 50%	3/3 = 100%	3/4 = 75%
Bamberg	Nürnberg				
Frankfurt	Nürnberg	Wenn AF = Frankfurt, dann ZF = Nürnberg	1/6 ≈ 17%	1/2 = 50%	1/4 = 25%
Frankfurt	Stuttgart				
Bamberg	Nürnberg	Wenn AF = Frankfurt, dann ZF = Stuttgart	1/6 ≈ 17%	1/2 = 50%	1/1 = 100%
Bamberg	Nürnberg				
Stuttgart	Frankfurt	Wenn AF = Stuttgart, dann ZF = Frankfurt	1/6 ≈ 17%	1/1 = 100%	1/1 = 100%

Abbildung 49: Beispiel zur Berechnung der Gütemaße einer Assoziationsbeziehung

Für die Assoziationsanalyse stehen unterschiedliche Methoden zur Verfügung, die sich wiederum in mehrere Methodenvarianten verzweigen. Die bekannteste Methode zur Abhängigkeitsanalyse ist der Apriori-Algorithmus, der bereits 1993

¹ Hettich und Hippner führen noch eine Reihe anderer Kenngrößen an, wie zum Beispiel *Improvement*, *Conviction*, die *Gain*- oder *Laplace-Funktion* (vgl. [HeHi01, S. 446-449]).

von Agrawal et al. in seinen Grundzügen vorgestellt wurde (vgl. [AgIS93]). Zusammen mit den 1994 ergänzten Algorithmen AprioriTid und AprioriHybrid (vgl. [AgSr94]) bilden die Apriori-Algorithmen „bis heute den Ausgangspunkt für die Entwicklung zahlreicher Varianten“ [HeHi01, S. 429].

Neben den Apriori-Algorithmen gehören auch die so genannten Bayes-Netze zur Abhängigkeitsanalyse. Mit diesen Methoden untersucht man Häufigkeitsverteilungen von Merkmalen, um diese auf Basis ihrer statistischen Abhängigkeiten in Form eines azyklisch gerichteten Graphen zu verknüpfen (vgl. [Coop99, S. 3], [BaGr04, S. 137]). Einige Algorithmen, wie etwa der IC*-Algorithmus von Pearl (vgl. [Pear00, S. 52-54]), wurden speziell für die Kausalanalyse entwickelt. Allerdings können die Knoten und Kanten des erzeugten Graphen nur unter bestimmten Voraussetzungen als Kausalhypothesen interpretiert werden (vgl. [Coop99, S. 30-35], [Pear00, S. 61-64], [BoKr02, S. 268]). Eine weitere Einschränkung von Bayes-Netzen ist, dass sich eine analysierte Häufigkeitsverteilung zuweilen durch alternative Kausalstrukturen erklären lässt und folglich das Ergebnis nicht immer eindeutig ist (vgl. [Pear00, S. 59], [BoKr02, S. 265]).

Hauptanwendungsgebiet der Assoziationsanalyse, speziell der Analyse von Abhängigkeitsbeziehungen, ist die Analyse von Warenkorbdaten zur Aufdeckung von Verbundkäufen. Zu diesem Zweck wurden Algorithmen entwickelt, die auch die hierarchisch angeordneten Elemente einer Taxonomie miteinander verknüpfen können (vgl. [HeHi01, S. 438-441]). So lassen sich beispielsweise innerhalb einer Produkthierarchie nicht nur Abhängigkeitsbeziehungen zwischen einzelnen Produkten (Pflegecreme, Gurken) entdecken, sondern auch zwischen Produktarten (Kosmetikartikel, Gemüse) oder zwischen Produkten und Produktarten (Kosmetikartikel, Gurken).

Die Methoden zur Entdeckung von Sequenzmustern leiten sich überwiegend aus der Methodenfamilie der Apriori-Algorithmen ab und können ebenfalls auf Taxonomien angewandt werden (vgl. [HeHi01, S. 443], [Mörc06, S. 17-18]). Ferner lässt sich bei einigen Varianten der Sequenzanalyse eine Zeitspanne vorgeben, innerhalb derer die Elemente einer Sequenz aufeinander folgen müssen, damit die gefundene Sequenz als gültiges Sequenzmuster infrage kommt (vgl. [HaMS01, S. 436], [HeHi01, S. 443]).

5.3.1.4 Prognose und Klassifikation

Anders als bei der Assoziationsanalyse, mit der sich beliebige Beziehungen zwischen den Merkmalen entdecken lassen, interessiert man sich bei der Prognose

und Klassifikation nur für solche Merkmalsbeziehungen, mit denen sich der Wert eines vorher festgelegten Zielmerkmals bestimmen lässt. Bei der Klassifikation wird aus den Merkmalswerten eines noch nicht klassifizierten Datenobjekts ein *kategorialer* Merkmalswert abgeleitet, der das Datenobjekt einer Klasse von Datenobjekten zuordnet (vgl. [CHS+98, S. 65], [BeLi00, S. 8]). Statt einen diskreten Klassenwert zu bestimmen, leitet die Prognose aus den Merkmalen einen *numerischen* Merkmalswert ab, der das zukünftige Verhalten bzw. den erwarteten Zustand der Datenobjekte beschreiben soll (vgl. [AlNi00b, S. 10]).

Zur Ermittlung der klassifikatorischen und prognostischen Zielwerte ist ein Klassifikations- bzw. Prognosemodell nötig. Dieses Modell besteht aus Klassifikations- und Prognoseregeln, die aber nur auf Basis einer repräsentativen Menge an Trainingsdatensätzen zu erzeugen sind. Um die Klassifikations- und Prognoseregeln zu generieren, muss den Datenobjekten der Trainingsdaten bereits der Wert des Zielmerkmals zugeordnet sein (vgl. [Knob00, S. 17]). Erst wenn nach der Analyse der Trainingsdaten die Klassifikations- oder Prognoseregeln vorliegen, können diese Regeln auf unbekannte Zieldaten angewandt und zur Klassifikation bzw. Prognose genutzt werden. Klassifikations- und Prognoseverfahren sind deshalb dem überwachten Lernen zuzuordnen (vgl. [NeKn05, S. 315]; siehe Abschnitt 5.3.1.1).

Entscheidungsbäume sind nach einer Studie von Säuberlich das am häufigsten eingesetzte Data-Mining-Verfahren zur Entwicklung von Klassifikationsmodellen (vgl. [Säub00, S. 53]). Ihr Funktionsprinzip beruht darauf, dass eine Menge an bereits klassifizierten Datenobjekten (Trainingsdaten) sukzessive in disjunkte Teilmengen aufgespaltet wird. Auf diese Weise verästeln sich die Knoten des Entscheidungsbaums so lange, bis entweder die einzelnen Teilmengen nur noch aus Datensätzen bestehen, die bezogen auf die Ausprägung ihres Klassifikationsmerkmals derselben Klasse angehören, oder ein Abbruchkriterium erfüllt ist (vgl. [NeKn05, S. 315]). Als Abbruchkriterium für die Aufspaltung können statistische Kenngrößen oder die Mindestanzahl der in einer Partition enthaltenen Datenobjekte angegeben werden (vgl. [Säub00, S. 96-97]).

Die Aufspaltung einer Menge an Datenobjekten erfolgt anhand eines Merkmals M_i , für das ein Schwellwert s_i bestimmt wird. Datenobjekte, deren Merkmalswert m_i die Ungleichung $m_i < s_i$ erfüllt, werden von denjenigen Datenobjekten getrennt, deren Merkmalswert die komplementäre Bedingung $m_i \geq s_i$ erfüllt (vgl. [Küst01, S. 109]). Der Mechanismus, mit dem das Aufspaltungsmerkmal und der Schwellwert s_i jeweils bestimmt wird, orientiert sich an der mit dem Schwellwert s_i erzielbaren Klassifikationsgüte und Trennschärfe. Es

wird stets das Merkmal ausgewählt, für das ein Schwellwert existiert, der die Menge der Datenobjekte - bezüglich des klassifikatorischen Zielmerkmals - in möglichst homogene Teilmengen einteilt. Im CHAID-Algorithmus erfolgt die Aufteilung beispielsweise mithilfe von Chi-Quadrat-Unabhängigkeitstests (vgl. [KrWZ98, S. 70-71]). Andere Methoden, wie etwa die CART- oder C4.5-Methode, nutzen davon abweichende Mechanismen zur Bestimmung der Aufspaltungsmerkmale (vgl. [NeKn05, S. 316]).

Abbildung 50 zeigt einen einfachen Entscheidungsbaum, der erfolgreiche und nicht erfolgreiche Projekte voneinander trennt. Der Durchmesser der Knoten symbolisiert jeweils die Größe der jeweiligen Teilmenge an Datenobjekten. Das Tortendiagramm informiert über die Homogenität der Teilmenge, die sich im Mengenverhältnis zwischen erfolgreichen und nicht erfolgreichen Projekten widerspiegelt. Jeder bei der Baumwurzel beginnende und bei einem Blattknoten endende Pfad stellt eine Entscheidungsregel im Sinne einer Wenn-Dann-Regel dar. In Abbildung 50 sind die beiden Entscheidungsregeln formuliert, die einem Projekt einen positiven Projekterfolg attestieren.

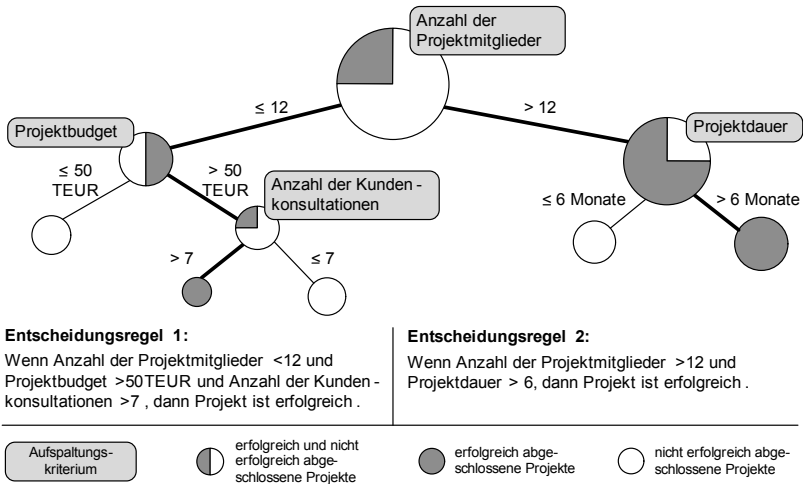


Abbildung 50: Beispiel eines Entscheidungsbaums

Anders als bei der Klassifikation wird bei der Prognose kein diskreter und kategorialer, sondern ein stetiger und numerischer Wert vorausgesagt. Küsters und Bell unterscheiden bei der Prognose zwischen autoprojektiven Verfahren und Verfahren auf Basis von Regressionsmodellen (vgl. [KüBe01, S. 262]).

Autoprojektive Verfahren prognostizieren die zukünftigen Werte einer Zeitreihe auf der Grundlage der vergangenen Werte des Zielmerkmals (vgl. [Küst01, S. 111]). Dies geschieht entweder mittels Komponentenerlegung (siehe Abschnitt 5.3.1.2), oder indem gezielt nach Autokorrelationen gesucht wird (vgl. [KüBe01, S. 262]).

Bei der Komponentenerlegung wird die Zeitreihe des Zielmerkmals zunächst in ihre einzelnen Komponenten zerlegt, zum Beispiel in saisonale Zyklen sowie eine Trend- und eine Rauschkomponente. Für jede Komponente lässt sich dann der Werteverlauf in die Zukunft fortschreiben, bevor die einzelnen Zeitreihen anschließend wieder zu einem gemeinsamen Verlaufsmuster zusammengesetzt werden. Die Methoden der Box-Jenkins- und ARIMA-Familie prognostizieren zukünftige Werte mittels Autokorrelation, indem sie in der Zeitreihe eines Merkmals nach korrelativen Zusammenhängen zwischen den Merkmalswerten suchen, die durch ein bestimmtes, zu fixierendes Zeitintervall i voneinander getrennt sind (vgl. [KüBe01, S. 262]). Eine solche Autokorrelation liegt vor, wenn sich sämtliche Werte zum Zeitpunkt t_n aus den vergangenen Werten der Zeitpunkte t_{n-i} errechnen lassen.

Während autoprojektive Verfahren die vergangenen Werte des Zielmerkmals für die Prognose nutzen, stützen sich bivariate oder multiple Regressionsmodelle auf Korrelationsbeziehungen, die zwischen verschiedenen Merkmalen bestehen (vgl. [KüBe01, S. 262]). Kombiniert man autoprojektive Verfahren mit Regressionsmodellen, erhält man dynamische Regressionsmodelle, die neben den Werten der erklärenden Merkmale zusätzlich die vergangenen Werte des Zielmerkmals berücksichtigen (vgl. [KüBe01, S. 280]).

Autoprojektive oder regressionsanalytische Prognosen lassen sich zum einen mit den Methoden der Statistik, zum anderen auch mithilfe neuronaler Netze realisieren. Anders als bei der Segmentierung, die mithilfe von Self-Organizing-Feature-Maps umgesetzt wird (siehe 5.3.1.1), verwendet man für die Prognose Feed-Forward-Multilayer-Perceptrons (vgl. [KüBe01, S. 285]). Diese enthalten neben der obligatorischen Ein- und Ausgabeschicht mindestens eine weitere, verdeckte Zwischenschicht (vgl. [PoSi01, S. 380]). Bei der Prognose besteht der Vorteil von neuronalen Netzen vor allem darin, dass sie nicht nur lineare, sondern auch nicht-lineare Merkmalszusammenhänge nachbilden können (vgl. [KüBe01, S. 285]).

5.3.2 Hypothesengetriebene Analyseverfahren

Analog zum realen Bergbau greift man beim Data-Mining auf schweres Gerät in Form automatisierter Suchverfahren zurück. Im Gegensatz dazu gleichen die hypothesengetriebenen Analyseverfahren einer Spitzhacke, die zwar eine manuelle Suche nach Informationen bedeutet, aber dafür eine umso gezieltere Suche nach Datenmustern ermöglicht. Treibende Kraft der hypothesengetriebenen Analyse ist nicht mehr der Datenbestand, sondern eine zu überprüfende Hypothese bzw. eine vage Annahme.¹ Damit lässt sich schon im Vorfeld der Analyse bestimmen, welches Datenmuster die Hypothese stützen bzw. diese widerlegen würde. Da man das gesuchte Datenmuster bereits kennt, lassen sich somit auch die benötigten Daten und Analyseverfahren entsprechend konkretisieren. Obwohl die Verfahren der traditionellen Statistik ebenfalls zu den hypothesengetriebenen Analyseverfahren zählen, wird als zentrale Analysemethode im Folgenden nur das Online-Analytical-Processing (OLAP) vorgestellt. Für diese Fokussierung auf OLAP-Verfahren sprechen drei Gründe:

- **Flexibilität:** OLAP-Verfahren lassen sich sehr viel flexibler einsetzen als statistische Standardmethoden zum Testen von Hypothesen. Es können sowohl einfache ad-hoc Analysen als auch komplexere Untersuchungen durchgeführt werden (vgl. [Cham01, S. 544]).
- **Einfachheit:** Mit OLAP-Verfahren kann auf den gesamten Datenbestand der Datenbasis zugegriffen werden. Daher entfällt eine aufwändige Stichprobenziehung, weshalb die OLAP-Analyse ohne spezielle statistische Methodenkenntnisse und somit vom Informationsempfänger selbst durchgeführt werden kann (vgl. [Nölk02, S. 235]).
- **Praxisrelevanz:** OLAP-Verfahren sind - nicht zuletzt wegen ihrer Flexibilität und Einfachheit - zu einem de-facto Standard der betrieblichen Daten- und Kennzahlenanalyse geworden. Viele Unternehmen haben mit der Einführung eines Data-Warehouse bereits die infrastrukturellen Voraussetzungen für die OLAP-Analyse geschaffen und bereits Erfah-

¹ In Abschnitt 5.1.2 wurde eine Hypothese als eine begründete Vermutung definiert, die sich bereits auf erste konkrete Gültigkeitshinweise stützen kann (siehe Seite 97). Eine Annahme ist hingegen das Ergebnis intuitiver bzw. assoziativer Spekulation. Selbstverständlich lassen sich mit OLAP-Verfahren sowohl Hypothesen als auch noch völlig unbegründete Annahmen überprüfen. Der Begriff *hypothesengetrieben* wird in dieser Arbeit aber dennoch beibehalten, da er in diesem Sinne auch in der Literatur verwendet wird (vgl. [GrGe00, S. 98], [KnWe00, S. 4], [PiMe03, S. 117], [NeKn05, S. 78-79]).

rungen mit dieser Form der Analyse gesammelt (vgl. [Mart03b, S. 19], [Alex07]).

Ihre flexible und einfache Anwendung verdanken OLAP-Verfahren insbesondere dem zugrunde liegenden Modellsystem und dessen besonderer Datenstruktur. Während den datengetriebenen Verfahren des Data-Minings eine denormalisierte Datentabelle genügt, operieren OLAP-Verfahren auf einem multidimensionalen Datenraum. Im folgenden Abschnitt 5.3.2.1 werden die Grundlagen des Online-Analytical-Processings vorgestellt, bevor in Abschnitt 5.3.2.2 erläutert wird, wie sich ein multidimensionaler Datenraum mithilfe eines Data-Warehouse realisieren lässt.

5.3.2.1 Online-Analytical-Processing

Die Kernidee eines multidimensionalen Datenraums ist die Differenzierung in quantitative Messgrößen und qualitative Bezugsgrößen. Da die isolierte Betrachtung einer quantitativen Messgröße keine „semantisch wertvolle Information zur Verfügung stellt“ (vgl. [Böhn01, S. 129]), sind Messgrößen stets auf andere Größen zu beziehen. Um die Kosten-, Umsatz- und Gewinngrößen eines Unternehmens sinnvoll auswerten zu können, müssen diese beispielsweise erst auf Kundengruppen, Produktparten oder Ländergesellschaften bezogen werden. Je nachdem, mit welcher Bezugsgröße man eine Messgröße verknüpft, lassen sich die Merkmalswerte einer Messgröße aus verschiedenen Perspektiven betrachten. Hierbei begründet jede Bezugsgröße eine eigene Dimension, die zusammen mit den anderen Bezugsgrößen einen multidimensionalen Datenraum aufspannt. Abbildung 51 skizziert einen solchen Datenraum in Form eines dreidimensionalen Hyperwürfels.

Der von einem Unternehmen generierte Umsatz wird in Abbildung 51 auf die drei Bezugsgrößen Produktprogramm, Berichtszeitraum und Vertriebsgebiet bezogen. Jede dieser drei Dimensionen gliedert sich gemäß den Merkmalsausprägungen ihrer Bezugsgröße in mehrere Dimensionselemente: das Produktprogramm in die vier Produkte A, B, C und D, das Vertriebsgebiet in die vier Regionen Süd, Ost, West und Nord sowie der Berichtszeitraum in die vier Quartale des Jahres 2004. Der Datenraum setzt sich somit aus $4 \times 3 \times 4 = 48$ Datenzellen zusammen. Jede Datenzelle wird durch ein Tripel aus drei Dimensionselementen unterschiedlicher Dimensionen indiziert.

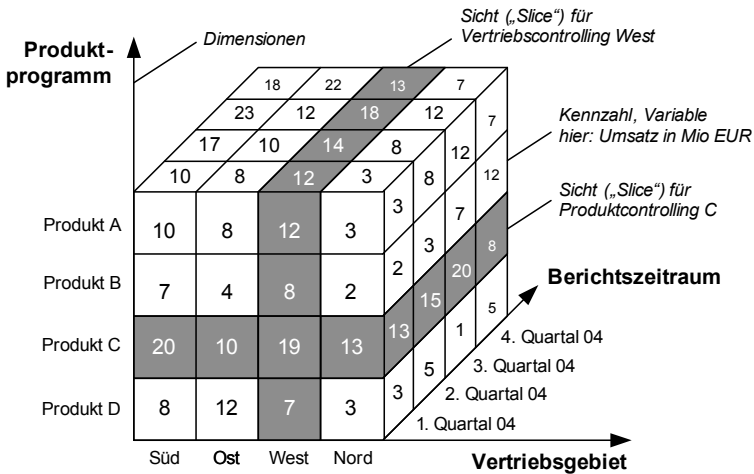


Abbildung 51: Beispiel eines dreidimensionalen Hyperwürfels¹ (in Anlehnung an [Balz00, S. 241])

Mithilfe von OLAP-Verfahren können die Nutzer flexibel und dynamisch auf die Datenzellen zugreifen. Der Nutzer kann nicht nur die Dimensionselemente, sondern auch die Dimensionen des Datenraums flexibel festlegen und kombinieren. Zudem lassen sich die Dimensionselemente einzelner Dimensionen auch hierarchisch anordnen. Zum Beispiel könnten die Umsatzdaten des in Abbildung 51 skizzierten Datenraums entlang der Dimensionen Berichtszeitraum oder Vertriebsgebiet zusätzlich disaggregiert werden: Quartale ließen sich in Monate oder Tage, Vertriebsgebiete in Regionen und Bezirke aufspalten. Das Aggregationsniveau kann der Nutzer entlang der Hierarchieebenen einer Dimension festlegen.

Da sich unterschiedliche Dimensionen, Hierarchieebenen und Dimensionselemente flexibel kombinieren lassen, kann sich der Nutzer dynamisch durch den multidimensionalen Datenraum navigieren (vgl. [Oehl06, S. 26]). Hierfür stehen ihm folgende OLAP-Operatoren zur Verfügung (vgl. [Böhn01, S. 143-148]):

¹ Die Würfelmetapher impliziert, dass sich der Datenraum aus drei Dimensionen mit gleich vielen Dimensionselementen zusammensetzt. Da ein solch würfelförmiger Datenraum eher der Sonderfall als die Regel ist, müsste streng genommen von einem Quader gesprochen werden. In der Literatur hat sich jedoch die Bezeichnung Hypercube bzw. Hyperwürfel durchgesetzt. Das Präfix Hyper verdeutlicht, dass es sich nicht nur um einen dreidimensionalen, sondern auch um einen mehr als drei Dimensionen umfassenden Datenraum handeln kann (vgl. [Oehl06, S. 126]).

-
- **Drill-Down:** Beschreibt den Wechsel innerhalb einer Dimension von einer Hierarchieebene auf die nächst *tiefer* liegende Ebene.
Beispiel: Umsätze werden nicht mehr pro Quartal, sondern wochenweise betrachtet.
 - **Roll-Up:** Beschreibt den Wechsel innerhalb einer Dimension von einer Hierarchieebene auf die nächst *höher* liegende Ebene.
Beispiel: Die erzielten Gewinne werden nicht quartalsweise, sondern auf Jahresbasis betrachtet.
 - **Selection:** Beschreibt die Auswahl eines Teilbereichs des Datenraums. Hierbei können zwei Varianten unterschieden werden:
 - **Slice:** Man reduziert die Anzahl der Dimensionen, indem nicht alle Elemente einer Dimension, sondern nur ein einziges Dimensionselement als Filterkriterium ausgewählt wird.
Beispiel: Die nach Vertriebsgebieten differenzierten Quartalsumsätze werden nicht mehr für alle Produktgruppen, sondern nur noch für eine Produktgruppe betrachtet (siehe Abbildung 51).
 - **Dice:** Anstatt eine Dimension auf nur ein Dimensionselement einzuschränken, reduziert man die Zahl der Dimensionselemente auf wenigstens zwei. Die Dimensionsanzahl selbst bleibt unverändert.
Beispiel: Es werden nur die Umsätze des ersten und zweiten Quartals für die Produktgruppen B und C und die Vertriebsgebiete Süd und Nord betrachtet.
 - **Rotate:** Ermöglicht das Drehen des Hyperwürfels, indem man die Reihenfolge der Dimensionen vertauscht. Dadurch kann das Datenmaterial aus verschiedenen Blickwinkeln betrachtet und grafisch aufbereitet werden. Die Anzahl der Dimensionen, Dimensionselemente und Datenzellen ändert sich nicht.
 - **Nesting:** Ermöglicht die Darstellung eines multidimensionalen Datenraums in Form einer zweidimensionalen Tabelle. Dabei können mehrere Dimensionen und Hierarchieebenen sowohl zeilen- als auch spaltenweise ineinander geschachtelt werden.
 - **OLAP-Join:** Ermöglicht die Verknüpfung zweier Hyperwürfel. Voraussetzung ist, dass sich die beiden Datenräume mindestens eine Dimension teilen. Abhängig von der Anzahl der gemeinsamen Dimensionen entsteht ein neuer Datenraum, der mindestens so viele Dimensionen besitzt, wie

der Datenraum mit den meisten Dimensionen.

Beispiel: Verknüpft man den in Abbildung 51 dargestellten dreidimensionalen Datenraum mit einem zweidimensionalen Datenraum, der die Umsätze der Produktgruppen nach Kundengruppen differenziert, entsteht ein vierdimensionaler Datenraum: Die drei ursprünglichen Dimensionen Produktgruppe, Vertriebsgebiet und Berichtszeitraum werden um die neue Dimension Kundengruppe ergänzt.

Damit die OLAP-Operatoren einen flexiblen Datenzugriff ermöglichen können, bedarf es einer anderen Art der Datenverarbeitung als es für den Betrieb operativer Anwendungssysteme der Fall ist. Der Begriff OLAP wurde 1993 von Codd et al. bewusst als Gegensatz zur Datenverarbeitung operativer Anwendungssysteme eingeführt: dem Online-Transaction-Processing (OLTP) (vgl. [CoCS93, S. 6]). OLTP steht für eine „hochgradig normalisierte, weitestgehend redundanzfreie Datenhaltung“ [NöFo99, S. 88]. Diese transaktionsorientierte Datenhaltung gewährleistet zwar auf operativer Ebene einen effizienten Geschäftsbetrieb, allerdings sind mit der Bereitstellung und Analyse entscheidungsunterstützender Daten enorme Anstrengungen verbunden (vgl. [Cham01, S. 544], [Wild01, S. 2]). Die operativen Daten müssen für jede Analyse aufs Neue gesammelt und anschließend verdichtet werden. Hinzu kommt, dass die Daten der OLTP-Systeme nur das auf den aktuellen Zeitpunkt bezogene Tagesgeschäft abbilden, weshalb sich historische Zusammenhänge in der Datenbasis nicht mehr nachvollziehen lassen (vgl. [Wild01, S. 7]). Aus diesem Grund ist es notwendig, die entscheidungsrelevanten Daten von den OLTP-Systemen zu lösen und speziell im Hinblick auf Entscheidungsaufgaben und dem daraus resultierenden Analysebedarf zu verwalten und zu archivieren (vgl. [WeGS99, S. 20]). Diesen Zweck erfüllt ein Data-Warehouse, dessen Konzept im folgenden Abschnitt vorgestellt wird.

5.3.2.2 Data-Warehouse

Das Konzept des Data-Warehouses geht zurück auf eine Initiative der IBM, die 1988 die Daten der drei Vertriebsregionen Europa, Mittlerer Osten und Afrika zusammenführen wollte (vgl. [Böhn01, S. 36]). Ziel war es, den Nutzern die aufwändige Suche und Extraktion der Daten aus unterschiedlichen Quellsystemen zu ersparen und ihnen stattdessen eine einheitliche, gemeinsame Datenbasis bereitzustellen (vgl. [DeMu88, S. 61]). Einer breiten Öffentlichkeit wurde der Begriff Data-Warehouse aber erst bekannt, als Inmon 1992 sein Buch „Building

the Data-Warehouse“ veröffentlichte (vgl. [Böhn01, S. 36]). Inmon definiert ein Data-Warehouse als „subject oriented, integrated, nonvolatile and time variant collection of data in support of management’s decision-making process“ [Inmo05, S. 33]. Diese Eigenschaften werden im Folgenden kurz erläutert, bevor im Anschluss die einem Data-Warehouse zugrunde liegende Systemarchitektur vorgestellt wird.

Die zuerst genannte Eigenschaft der *Themenorientierung* weist darauf hin, dass sich die in einem Data-Warehouse „eingelagerten“ Daten auf einen klar abgegrenzten Themenbereich beziehen sollen. Solche Themenbereiche sind zum Beispiel Kunden oder Produkte, deren Umsatz-, Kosten- oder Gewinngrößen ausgewertet werden sollen (vgl. [Böhn01, S. 37]).

Die zweite Eigenschaft, die Forderung nach *Integration*, verweist auf die Datenheterogenität der Quellsysteme. Da sich ein Data-Warehouse nicht nur aus den Daten der internen Anwendungssysteme, sondern auch aus den Daten unternehmensexterner Quellen zusammensetzen kann, unterscheiden sich die Quelldaten bezüglich Datenqualität und Format. Um dem Nutzer trotz dieser Heterogenität eine konsistente Datenbasis bereitzustellen, müssen die Daten aus den Quellsystemen extrahiert, anschließend transformiert und vereinheitlicht werden, bevor sie schließlich zusammengeführt und in das Data-Warehouse geladen werden können. Diese Aufgaben bündelt der so genannte ETL-Prozess, der sich entsprechend in drei Phasen gliedert: die Extraktions-, die Transformations- und die Ladephase. Die Prozessschritte des ETL-Prozesses werden in Abschnitt 6.4.2 erläutert.

Als dritte Eigenschaft fordert Inmon die *dauerhafte Speicherung* der Daten. Im Gegensatz zu den operativen Anwendungssystemen, deren Datenbestände fortlaufend aktualisiert werden und deshalb nur das gegenwärtige Geschäftsgeschehen abbilden, archivieren die Daten eines Data-Warehouse das vergangene Geschäftsgeschehen. Die einmal in ein Data-Warehouse geladenen Daten werden nicht mehr überschrieben, sondern für eine nachträgliche Analyse des vergangenen Geschäftsgeschehens bereitgehalten.

Die vierte Eigenschaft, der *Zeitraumbezug*, resultiert aus der dauerhaften Speicherung der Daten. Da sämtliche in das Data-Warehouse geladenen Daten mit einem Zeitstempel versehen werden, schreibt jeder Ladevorgang das Geschäftsgeschehen in seinem zeitlichen Verlauf fort. Mit jedem Ladevorgang verlängert sich der Zeitraum, den die Daten eines Data-Warehouse abdecken. Auf diese Weise entsteht nach und nach eine umfangreichere Datenbasis, die sich speziell für Zeitreihenanalysen sehr gut eignet (vgl. [Böhn01, S. 38]).

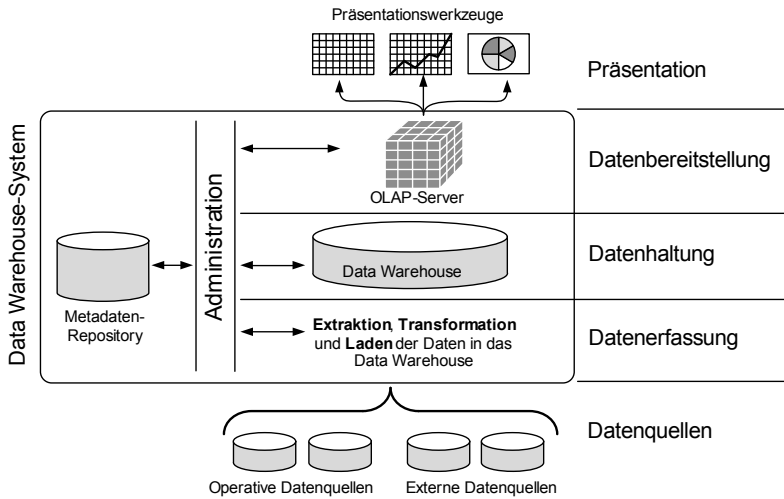


Abbildung 52: Data-Warehouse-Systemarchitektur (in Anlehnung an [BöUI00, S. 17])

Um den Zusammenhang zwischen dem Online-Analytical-Processing, dem zugrunde liegenden Data-Warehouse und den operativen Quellsystemen zu verdeutlichen, können insgesamt fünf verschiedene Ebenen unterschieden werden (siehe Abbildung 52).

Auf der untersten Ebene der *Datenquellen* befinden sich die internen und externen Quelldaten. Auf der darüber liegenden Ebene der *Datenerfassung* werden die Daten aus den Quellsystemen extrahiert, transformiert und schließlich in das Data-Warehouse geladen (ETL-Prozess). Das Data-Warehouse selbst befindet sich auf der Ebene der *Datenhaltung*. Auf der Ebene der *Datenbereitstellung* realisiert ein OLAP-Server die verschiedenen OLAP-Operatoren, indem er in entsprechender Weise auf die Daten des Data-Warehouses zugreift. Auf der Ebene der *Präsentation* können die vom OLAP-Server bereitgestellten Daten mithilfe verschiedenster Präsentationswerkzeuge grafisch aufbereitet und ausgewertet werden. Zum Data-Warehouse-System selbst zählen jedoch nur die drei Ebenen der Datenerfassung, Datenhaltung und Datenbereitstellung. Zur Verwaltung des Data-Warehouse-Systems existiert zudem ein Metadaten-Repository, das zum Beispiel die Datenstrukturen des Data-Warehouses oder die Daten zur Steuerung des ETL-Prozesses speichert (vgl. [BöUI00, S. 30]).

6 Gestaltungsoptionen für einen Analyseprozess zur Entwicklung und Überprüfung von Kausalhypothesen

Ausgehend von den konzeptionellen und methodischen Grundlagen des Kapitels 5 werden nun die vier Gestaltungsoptionen des Analyseprozesses vorgestellt. Jede Gestaltungsoption ist als modellgestützte Untersuchungssituation für eines der beiden Untersuchungsprobleme des Analyseprozesses konzipiert: für das Problem der Entwicklung von Kausalhypothesen und das Problem ihrer Überprüfung (siehe Abschnitt 5.1.4.1). Während das Modellsystem der beiden modellzentrierten Gestaltungsoptionen der typbezogenen Kausalarchitektur entspricht (siehe Abschnitt 5.2.1), operieren die datenzentrierten Gestaltungsoptionen auf einem Modellsystem, das der instanzbezogenen Kausalarchitektur folgt (siehe Abschnitt 5.2.2). Jede der vier Gestaltungsoptionen wird als ein eigener, modellgestützter Analyseprozess beschrieben, der sich gemäß der modellgestützten Untersuchungssituation in mehrere Phasen unterteilen lässt (siehe Abschnitt 5.1.4.2). In den folgenden Abschnitten 6.1 bis 6.4 werden zunächst die Phasen und Prozessschritte der vier Gestaltungsoptionen erläutert. Das Kapitel schließt mit Abschnitt 6.5, der zeigt, wie sich die vier Gestaltungsoptionen zu einem integrierten Analyseprozess zusammenfügen lassen und welche Kombinationsmöglichkeiten hierbei bestehen.

6.1 Modellzentrierte Entwicklung von Kausalhypothesen

Anstatt Kausalhypothesen ausschließlich intuitiv und auf Basis assoziativer Gedankengänge zu formulieren, sollen diese systematisch und evidenzbasiert entwickelt werden. In diesem Abschnitt wird die erste Gestaltungsoption vorgestellt, mit der dieses Ziel erreicht werden soll: die modellzentrierte Entwicklung von Kausalhypothesen. Die Grundüberlegung ist, dass sich durch eine Analyse von Objekttypen und Objektbeziehungen nicht nur die Bedingungskonstellation einer Kausalbeziehung erschließt, sondern dass man diese Kenntnisse auch zur Entwicklung neuer Kausalhypothesen nutzen kann. Zu diesem Zweck ist die ursprüngliche Untersuchungssituation in eine modellgestützte Untersuchungssituation zu transformieren. Der Prozess der modellzentrierten Entwicklung von

Kausalhypothesen gliedert sich somit in vier Prozessphasen (siehe Abschnitt 5.1.4.2):

- die Zieltransformation (Phase I),
- die Modellkonstruktion (Phase II),
- die Verfahrensanwendung (Phase III) sowie
- die Lösungstransformation (Phase IV).

In den folgenden vier Abschnitten werden die einzelnen Prozessschritte der vier Phasen erläutert.

6.1.1 Zieltransformation

Bei der Zieltransformation ersetzt man das originäre Untersuchungsziel durch ein neues Untersuchungsziel. Für die Hypothesenentwicklung bedeutet dies, dass man die Suche nach Ursachen- bzw. *Wirkungsereignissen* durch eine Suche nach potenziellen Ursachen- bzw. *Wirkungsobjekten* ersetzt. Anstatt Kausalhypothesen nur auf der Ereignissebene und auf Basis assoziativer Gedankengänge zu entdecken, verlagert man die Suche auf die Objektebene. Dort können dann diejenigen Objekte identifiziert werden, die als potenzielle Ereignisträger für ein Ursachen- oder Wirkungsereignis infrage kommen. Die modellzentrierte Hypothesenentwicklung nutzt also die Erkenntnis, dass der Ursachen- und der Wirkungsobjekttyp einer Kausalhypothese entweder

- a) *identisch* sind - dann handelt es sich um einen typologischen Kausalzusammenhang (siehe Abschnitt 5.2.1.2), oder
- b) über mindestens eine *Teil-Ganzes-* oder *Interaktionsbeziehung* miteinander in Beziehung stehen, damit das Ursachenereignis das Wirkungsereignis hervorrufen kann (siehe Abschnitt 5.1.3.1).

Die Suche nach Kausalhypothesen beschränkt sich von vornherein nur auf solche Kausalzusammenhänge, die Punkt a oder b erfüllen und denen die erforderliche kausale Infrastruktur - und somit die Bedingtheit - nachgewiesen werden konnte. Dies verleiht den entwickelten Kausalhypothesen die in Abschnitt 5.1.2 geforderte Anfangsplausibilität. Die Modellierung der kausalen Infrastruktur geschieht allerdings erst in der zweiten Phase, der Modellkonstruktion. Abbildung 28 skizziert zunächst die beiden Prozessschritte, die in der Phase der Zieltransformation durchzuführen sind.

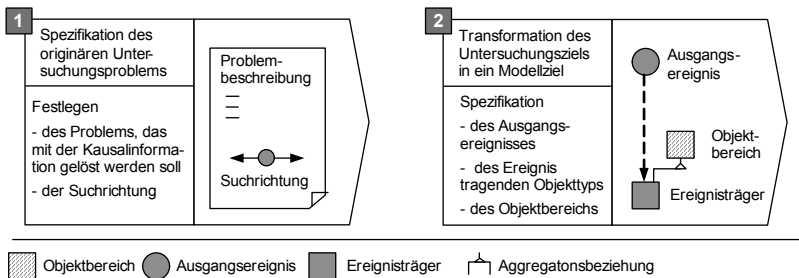


Abbildung 53: Prozessschritte der Zieltransformation

Um das originäre Untersuchungsziel in ein Modellziel zu transformieren, ist in einem *ersten Prozessschritt* das Untersuchungsproblem zu spezifizieren. Zum einen muss die Suchrichtung geklärt werden, also ob es sich um eine Ursachen- oder Wirkungsforschung handelt (siehe Abschnitt 5.1.4.1). Zum anderen muss festgelegt werden, welches Ereignis den Ausgangspunkt der Analyse bildet und ob es sich hierbei um ein zukünftiges oder vergangenes Ereignis handelt. Das Ausgangsereignis kann entweder als ein einzelnes, singuläres Ereignis vorliegen, oder eine Verallgemeinerung davon sein. Denn unabhängig davon, ob das Ausgangsereignis der originären Untersuchungssituation aus Typ- oder Instanzsicht beschrieben ist, ist es Ziel der modellzentrierten Untersuchungssituation, Kausalhypothesen aus Typsicht zu entwickeln.

In einem *zweiten Prozessschritt* transformiert man das originäre Untersuchungsziel in ein Modellziel. Hierzu muss zunächst das Ausgangsereignis in der Objektebene verortet werden, indem man es einem Objekttyp zuordnet, der als Ereignisträger fungiert. Gemäß den in Abschnitt 5.2.1.2 vorgestellten Ereignisarten lässt sich das Ausgangsereignis entweder als Eigenschafts- oder Beziehungereignis charakterisieren. Handelt es sich um ein Beziehungereignis, kann dieses ferner als Typwechsel-, Interaktions- oder Aggregationsereignis beschrieben werden (siehe Abschnitt 5.2.1.2).

Bei einem *Eigenschaftsereignis* ist das zugrunde liegende Eigenschaftsmerkmal zu bestimmen und einem Objekttyp zuzuordnen. Im Falle eines *Interaktions-* oder *Aggregationsereignisses* muss das Ausgangsereignis über ein Interaktions- bzw. Aggregationsmerkmal an den ereignistragenden Objekttyp geknüpft werden. Zusätzlich ist neben dem Ereignisträger selbst auch die von dem Merkmal referenzierte Objektbeziehung sowie der interagierende bzw. Teilobjekttyp anzugeben.

Ob das Beziehungsmerkmal ein originäres oder abgeleitetes Merkmal ist, spielt an dieser Stelle keine Rolle.

Bei einem *Typwechselereignis* sind nicht nur zwei, sondern drei Objekttypen zu identifizieren: Neben den an dem Typwechsel beteiligten Subobjekttypen muss auch der gemeinsame Superobjekttyp angegeben werden. Um den Superobjekttyp mit den beiden Subobjekttypen über eine Typbeziehung zu verknüpfen, sind die typbildenden Merkmale der Subobjekttypen zu spezifizieren. Welcher dieser drei Objekttypen als Ereignisträger für das Ausgangsereignis fungiert, hängt davon ab, ob man das Ereignis als ein uni- oder bidirektionales Typwechselereignis formuliert. Während sich ein bidirektionales Typwechselereignis dem Superobjekttyp zuordnen lässt, tritt bei einem unidirektionalen Typwechselereignis ein Subobjekttyp als Ereignisträger auf, und zwar derjenige, dessen Instanzen beim Ereigniseintritt eine andere Typzuordnung erhalten (siehe Abschnitt 5.2.1.2).

Die Zieltransformation ist abgeschlossen, wenn auch der Objektbereich der Untersuchung festgelegt ist. Der Objektbereich bestimmt, wie weit man sich bei der Suche nach potenziellen Ursachen- oder Wirkungsobjekttypen vom ereignisstragenden Objekttyp wegbewegen möchte. Um den Objektbereich zu spezifizieren, gibt man einen Objekttyp an, auf dessen Teilobjekttypen man die Suche nach potenziellen Ursachen- oder Wirkungsobjekttypen beschränken möchte. Dieser Objekttyp ist im einfachsten Fall mit dem Ereignisträger identisch oder ein aggregierter Objekttyp (siehe Abbildung 53). Möchte man beispielsweise untersuchen, weshalb sich die Durchlaufzeit eines Fertigungsprozesses im letzten Quartal erhöht hat (Eigenschaftsereignis), so kann man sich bei der Suche nach Erklärungen entweder ausschließlich den Objekttyp FERTIGUNGSPROZESS beschränken, oder man weitet den Objektbereich aus und schließt in die Analyse auch den übergeordneten Geschäftsprozess ein, der den Fertigungsprozess als Teilprozess enthält. Dann kommen vor- und nachgelagerte Prozesse als Träger eines Ursachenerignisses infrage, sofern diese ebenfalls Teilprozesse des aggregierten Geschäftsprozesses sind.

6.1.2 Modellkonstruktion

In der zweiten Phase, der Modellkonstruktion, muss der Objektbereich des originären Untersuchungsproblems in ein Modellsystem überführt werden. Ziel ist es, ein Objektmodell zu konstruieren, das die Komplexität des Objektbereichs als eine Art Hilfsregelstrecke reduziert (siehe Abschnitt 3.1.1.2), indem es nur die

für einen Kausalzusammenhang bedeutsamen Objekttypen und Objektbeziehungen abbildet. Die Modellkonstruktion geschieht in zwei Prozessschritten, die in Abbildung 54 dargestellt sind:

1. *Präzisierung des Ausgangsereignisses*: Handelt es sich bei dem Ausgangsereignis um ein Aggregations- oder Interaktionsereignis, sollte die Ereignisaussage auf ein oder mehrere Typwechsel- oder Eigenschaftsereignisse zurückgeführt werden.
2. *Modellierung des Objektbereichs*: Ausgehend von dem ereignistragenden Objekttyp des präzisierten Ausgangsereignisses kann der Objektbereich entweder auf Basis von Objektbeziehungen oder auf Basis von Objekttypen erschlossen werden.

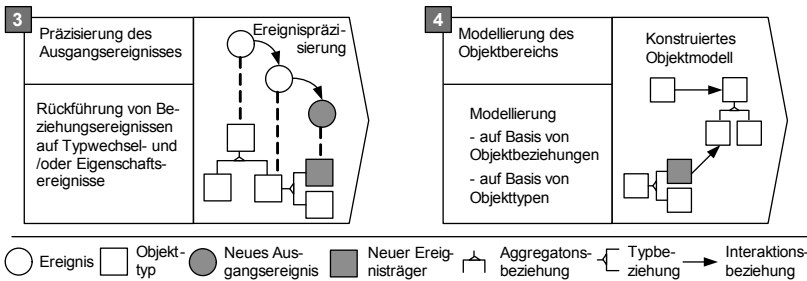


Abbildung 54: Prozessschritte der Modellkonstruktion

Da sich die in Abschnitt 5.2.1.2 vorgestellten Ereignisarten hinsichtlich ihres Aussagegehalts unterscheiden, lässt sich ein unpräzises Ausgangsereignis durch ein präziseres Ereignis ersetzen. Denn je präziser die Zustandsänderung auf der Objektebene beschrieben ist, desto leichter fällt es im zweiten Prozessschritt, die Objekttypen und -beziehungen des Objektbereichs zu modellieren und in der Phase der Verfahrensanwendung die potenziellen Ursachen- bzw. Wirkungsojekttypen zu bestimmen.

Eigenschafts- und Typwechselereignisse beschreiben die Zustandsänderungen auf der Objektebene am präzisesten. Beziehungsereignisse, die insbesondere Veränderungen im Mengenverhältnis der Objektinstanzen beschreiben (siehe Abschnitt 5.2.1.1), können weiter präzisiert werden, indem man sie durch das zugrunde liegende Typwechsel- oder Eigenschaftsereignis ersetzt. Angenommen, man würde die Kunden, mit denen ein Händler in Beziehung steht, anhand der Anzahl ihrer Bestellungen einem der beiden Subobjekttypen PREMIUMKUNDE und

NORMALER KUNDE zuordnen, dann ließe sich folgendes Interaktionsereignis formulieren: „Der Anteil der Premiumkunden steigt“. Abbildung 55 zeigt, welche Ereignisse dieses Ausgangsereignis präzisieren können.

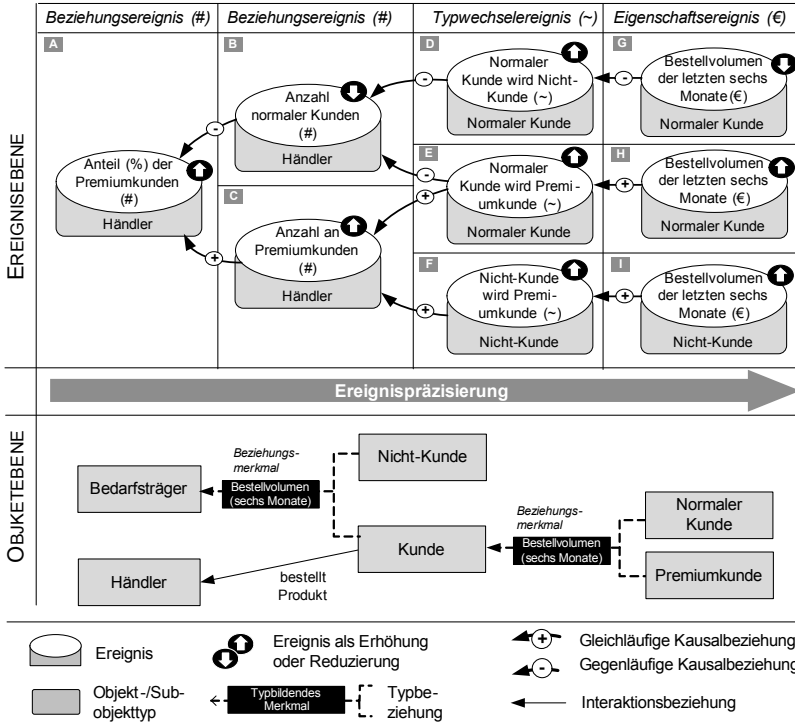


Abbildung 55: Beispiel zur Präzisierung eines Interaktionsereignisses

Das Ausgangsereignis (siehe Abbildung 55: A) ist vor allem deshalb unpräzise, weil es offen lässt, welches von zwei Interaktionsereignissen sich dahinter verbirgt. Denn die Erhöhung des Anteils der Premiumkunden könnte sowohl durch einen Verlust normaler Kunden (B) als auch durch einen Zuwachs an Premiumkunden (C) verursacht worden sein. Doch selbst ein Interaktionsereignis, das genau angibt, bei welchem Objekttyp es zu einer Zu- oder Abnahme an Objektinstanzen gekommen ist, lässt sich noch präzisieren. Ein absoluter Zuwachs an Premiumkunden (C) könnte auf zwei unidirektionale Typwechselereignisse zurückgeführt werden: Normale Kunden könnten zu Premiumkunden geworden sein (E), oder es ist gelungen, neue Premiumkunden zu akquirieren, die vorher

noch keine Kunden waren (F). Das zweite Beziehungsereignis, der Verlust an normalen Kunden, könnte ebenfalls damit erklärt werden, dass diese zu Premiumkunden geworden sind (E). Zusätzlich könnten normale Kunden ihren Kundenstatus auch verloren haben, weil sie beispielsweise zur Konkurrenz abgewandert sind und dort ihren Bedarf decken (D).

Da ein Typwechselereignis bedeutet, dass sich die typbildenden Merkmale verändern, kann ein solches Ereignis durch ein entsprechend spezifischeres Ereignis ersetzt werden, das die mit dem Typwechsel einhergehende Merkmalsänderung konkret beschreibt. Zur Abgrenzung von normalen und Premiumkunden wurde das Bestellvolumen der letzten sechs Monate verwendet. Folglich steht hinter einer Abwanderung normaler Kunden zur Konkurrenz (D) immer auch eine Reduzierung ihrer Bestellvolumina (G). Umgekehrt können normale Kunden Premiumkunden werden (E), wenn ihr Bestellvolumen ansteigt (H). In gleicher Weise wird ein Nicht-Kunde zu einem Premiumkunden (F), falls sein Bestellvolumen von Beginn an dem eines Premiumkunden entspricht (I).

Der Vorteil dieser tautologischen Ereignispräzisierung liegt darin, dass man sich bei der nun folgenden Modellierung des Objektbereichs nicht mehr am ursprünglichen Ereignisträger orientieren muss, in diesem Beispiel am Objekttyp HÄNDLER, sondern stattdessen den Ereignisträger eines präziseren Typwechsel- oder Eigenschaftsereignisses als Ausgangspunkt für die Modellierung nutzen kann. Hat man beispielsweise die Abwanderung von normalen Kunden (D) als Ausgangsereignis identifiziert, ist der Ereignisträger der Subobjekttyp NORMALER KUNDE, da dessen Instanzen von dem Rückgang der Bestellvolumina (G) betroffen sein müssen. Ausgehend von diesem Objekttyp kann man im *zweiten Prozessschritt* den Objektbereich auf Basis von Objektbeziehungen erschließen.

Bei einer Modellkonstruktion auf Basis von Objektbeziehungen nutzt man die Teil-Ganzes-, Typ- und Interaktionsbeziehungen, um die Objekttypen des Objektbereichs zu identifizieren. Den drei Beziehungsarten kommt daher eine Art Kompassfunktion zu: Ebenso wie man sich bei einer Wanderung an den Himmelsrichtungen orientiert, ist das systematische Denken in Teil-Ganzes-, Interaktions- und Typbeziehungen eine Orientierungshilfe bei der Erfassung und Modellierung des Objektbereichs (siehe Abbildung 56).

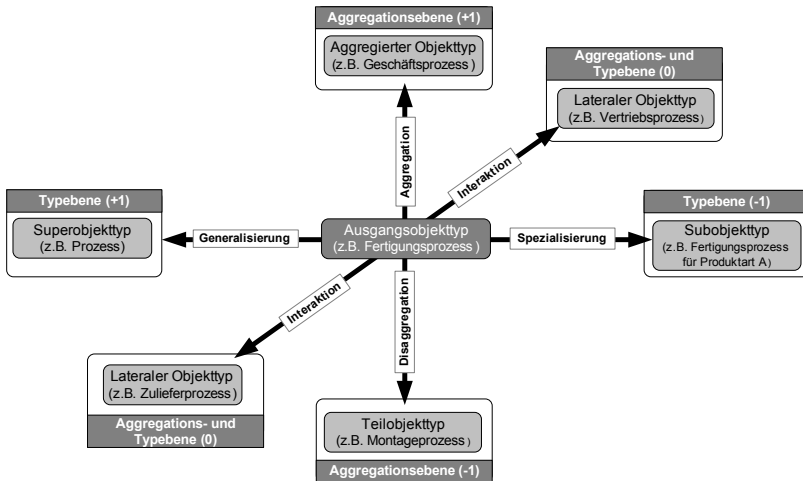


Abbildung 56: Modellkonstruktion auf Basis von Objektbeziehungen

So lässt sich der ereignistragende Objekttyp zum Beispiel anhand der *Teil-Ganzes-Beziehung* disaggregieren und in Teilobjekttypen aufsplitten. Alternativ kann man auch auf eine höhere Aggregationsebene wechseln und den aggregierten Objekttyp identifizieren. Für den Objekttyp FERTIGUNGSPROZESS würde dies zum Beispiel bedeuten, dass man entweder auf die einzelnen Teilprozesse stoßen würde, zum Beispiel auf einen Dreh- oder Schleifprozess, oder zu dem übergeordneten Geschäftsprozess gelangen würde, der den Fertigungsprozess als Teilprozess enthält.

Mit einer *Typbeziehung* lässt sich das Objektmodell erweitern, indem man das Ausgangsobjekt entweder differenziert und in Subobjekttypen unterteilt oder es generalisiert und den Superobjekttyp ins Modellsystem aufnimmt. Bei einer Generalisierung des Objekttyps FERTIGUNGSPROZESS träfe man beispielsweise auf den Superobjekttyp PROZESS, der dann nicht nur Fertigungsprozesse, sondern Prozesse jeglichen Typs zu einer Klasse zusammenfasst. Bei einer Differenzierung ließen sich spezialisierte Fertigungsprozesse unterscheiden, etwa anhand der Produkte, die sie fertigen.

Schließlich kann auch die *Interaktionsbeziehung* zur Modellkonstruktion verwendet werden, indem man gezielt interagierende Objekttypen identifiziert. Für den Fertigungsprozess wären dies zum Beispiel Zuliefer- oder Serviceprozesse,

die eine Leistung an den Fertigungsprozess abgeben, oder ein Versandprozess, der die vom Fertigungsprozess gefertigten Produkte als Leistung entgegennimmt. Die Modellkonstruktion auf Basis von Objektbeziehungen kann dann bei jedem der identifizierten Objekttypen fortgesetzt werden.

Das zweite Verfahren zur Modellierung des Objektbereichs ist die Modellkonstruktion auf Basis von *Objekttypen*. Anstatt den Objektbereich über Objektbeziehungen zu erschließen, verfährt man umgekehrt: Zuerst werden die relevanten Objekttypen des Objektbereichs ermittelt, bevor man im Anschluss die Objektbeziehungen ergänzt, die die Objekttypen verbinden.

Zur Identifikation relevanter Objekttypen und Beziehungen sollte das Objektvokabular der Mitarbeiter für die Modellkonstruktion genutzt werden, indem diese die aus ihrer Sicht relevanten Objekttypen benennen. Zu diesem Zweck lassen sich verschiedene Methoden zur Wissensakquisition einsetzen, wie zum Beispiel das strukturierte oder freie Experteninterview, aber auch Text- und Protokollanalysen (vgl. [Fric98, S. 240-251]). Dies bietet die Möglichkeit, den Informationsstand des Informationsempfängers von Beginn an in die Analyse einzubeziehen. Zusätzlich können bereits vorhandene Modellsysteme genutzt werden, etwa Prozess- oder Datenmodelle. Existiert beispielsweise ein Prozessmodell, das die Teilprozesse samt ihrer Aktivitäten und zuständigen Organisationseinheiten erfasst, lassen sich diese Informationen zur Identifikation der relevanten Objekttypen verwenden.

Die Modellkonstruktion auf Basis von Objekttypen erscheint auf den ersten Blick zwar weniger systematisch als die Modellkonstruktion auf Basis von Objektbeziehungen, zumal sich die Objekttypen auch assoziativ und intuitiv identifizieren lassen. Jeder dieser Objekttypen muss jedoch im Anschluss über eine oder mehrere Objektbeziehungen mit dem ereignistragenden Objekttypen verknüpft werden. Um diese Verknüpfungen herzustellen, kann auf das erste Verfahren, die Modellkonstruktion auf Basis von Objektbeziehungen, zurückgegriffen werden. Hier ist die Wahl des richtigen Auflösungsgrades entscheidend. Denn die „unbekannten Beziehungen zwischen den Variablen eines Systems sind oft ermittelbar, wenn man sich nach den Bestandteilen eines Systemelements fragt und sich überlegt, in welcher Beziehung diese Bestandteile wiederum zu der Umgebung stehen“ [Dörn03, S. 115].

Bei Anwendung beider Verfahren ist darauf zu achten, dass man den abgegrenzten Objektbereich nicht verlässt; es können nur die Objekttypen in das Modellsystem aufgenommen werden, die innerhalb des Objektbereichs liegen. Bei der Modellkonstruktion auf Basis von Objektbeziehungen läuft man bei einer

Interaktionsbeziehung sowie einer Aggregation oder Generalisierung Gefahr, den Objektbereich zu verlassen. Eine Spezialisierung ist hingegen ebenso unbedenklich wie eine Disaggregation. Trifft man bei der Modellkonstruktion auf einen Objekttyp, der außerhalb des Objektbereichs liegt, aber dennoch in das Modellsystem aufgenommen werden soll, muss der Objektbereich entsprechend erweitert werden. Dies erfordert einen Rücksprung in die Phase der Zieltransformation.

6.1.3 Verfahrensanwendung

Nach der Zieltransformation und der Modellkonstruktion folgt als dritte Phase die Verfahrensanwendung. Man wechselt nun von der Objektebene wieder zurück auf die Ereignisebene, indem man die Objekttypen und Beziehungen des Objektmodells zur Entwicklung neuer Kausalhypothesen nutzt. Hierfür sind zwei Prozessschritte nötig (siehe Abbildung 57):




Abbildung 57: Prozessschritte der Verfahrensanwendung

1. *Ableitung einer Kausalhypothese aus dem Objektmodell:* Aus dem Objektmodell werden zunächst Objekttypen ausgewählt, die als Ursachen- oder Wirkungsobjekttypen infrage kommen. Für diese Objekttypen sind dann Ereignistypen anzugeben, die sich mit dem (präzisierten) Ausgangsereignis zu einer Kausalhypothese verknüpfen lassen.
2. *Plausibilisierung der Kausalhypothesen:* Der Ursache-Wirkungs-Zusammenhang muss sich anhand der Objekttypen und Beziehungen der kausalen Infrastruktur nachvollziehen lassen. Zur Plausibilisierung können auf der Objektebene Infrastrukturbeziehungen hinzugefügt, präzisiert sowie der kausale Geltungsbereich angepasst werden.

Die Suche nach potenziellen Ursachen- bzw. Wirkungsobjekten beginnt bei dem Objekttyp, der bei der Ereignispräzisierung als neuer Ereignisträger bestimmt wurde (siehe Abschnitt der Modellkonstruktion). Das Objektmodell übernimmt an dieser Stelle dieselbe Funktion wie ein U-Bahn-Plan für einen Touristen, der sich in einer neuen Stadt Orientierung verschafft: Ebenso wie sich mit einem Blick auf den Netzplan sämtliche Umsteige- und Anschlussmöglichkeiten zu anderen U-Bahn-Stationen erfassen lassen, kann man das Objektmodell dazu nutzen, die Objekttypen zu identifizieren, die aufgrund ihrer Aggregations- oder Interaktionsbeziehungen als Träger eines Ursachen- oder Wirkungsereignisses infrage kommen. Doch genauso, wie ein Tourist nur solche Stationen anfahren wird, an deren Oberfläche sich lohnenswerte Besichtigungsziele bieten, lohnt sich nicht bei jedem Objekttyp der Wechsel auf die Ereignisebene.

Bei der Auswahl der Objekttypen ist es deshalb ratsam, sich zunächst auf die unmittelbar benachbarten Objekttypen zu konzentrieren und sich erst im Anschluss schrittweise in die „Außenbezirke“ des Objektmodells vorzutasten. Zwar können Ursache und Wirkung sowohl zeitlich als auch räumlich weit auseinander liegen, allerdings ist ein Ursachen- oder Wirkungsobjekttyp, der nur transitiv mit dem Träger des Ausgangsereignisses verbunden ist, auf einen direkt benachbarten Objekttyp angewiesen, der seinen kausalen Einfluss weitergeben muss. Gelingt es, für einen benachbarten Objekttyp ein lokales Ursachen- oder Wirkungsereignis zu formulieren, kann man die Suche nach weiter entfernten Ursachen- oder Wirkungsobjekttypen von diesem Objekttyp aus fortsetzen.

Hat man sich für einen oder mehrere Objekttypen als Ereignisträger entschieden, stehen für die Formulierung eines Ursachen- bzw. Wirkungsereignisses sämtliche in Abschnitt 5.2.1.2 vorgestellten Ereignistypen zur Verfügung. Doch auch hier gilt: Je präziser das Ereignis die Zustandsänderung auf der Objektebene beschreibt, desto präziser lässt sich der Kausalzusammenhang nachvollziehen und erklären. Möglicherweise kann anstatt eines Interaktions- oder Aggregationsereignisses ein Typwechsel- oder Eigenschaftsereignis formuliert werden (siehe Abbildung 55).

Welche Art von Kausalhypothese man entwickelt, hängt von dem ausgewählten Objekttyp ab. Steht dieser mit dem Ausgangsobjekttyp in einer Interaktions- oder einer Teil-Ganzes-Beziehung, lässt sich entweder ein interaktiver oder ein aggregativer bzw. disaggregativer Kausalzusammenhang formulieren. Ein typologischer Kausalzusammenhang liegt vor, falls der ausgewählte Objekttyp mit dem Ausgangsobjekttyp identisch ist.

Das kausale Wesensmerkmal der Bedingtheit ist erst dann nachgewiesen, wenn der Kausalzusammenhang auf der Objektebene über eine belastbare Infrastruktur verfügt. Im *zweiten Prozessschritt folgt* daher die Plausibilisierung der Kausalhypothese. Es muss geprüft werden, ob sich die Objekttypen und Beziehungen der kausalen Infrastruktur als tragfähig erweisen, wenn man versucht zu erklären, auf welchem Weg die Ursache die Wirkung hervorruft. Lässt sich der Kausalzusammenhang auf der Objektebene nur unzureichend nachvollziehen, kann dieser auf drei Arten plausibilisiert werden:

- Hinzufügen einer alternativen Infrastrukturbeziehung
- Präzisierung einer bereits vorhandenen Infrastrukturbeziehung
- Einschränkung oder Erweiterung des kausalen Geltungsbereichs

Hat man zum Beispiel die Hypothese entwickelt, dass ein Rückgang der Kundenzufriedenheit durch den Händler selbst, insbesondere durch eine Verkürzung der gewährten Garantiezeit, verursacht sein könnte, muss auf der Objektebene erklärt werden, auf welchem Weg eine Garantiezeitverkürzung die Kundenzufriedenheit beeinflussen kann. Ein Kunde kann sich nämlich erst dann über eine Garantiezeitverkürzung ärgern und als Folge sein Bestellverhalten ändern, wenn er von dieser Änderung - dem Ursachenereignis - erfährt. Die kausale Infrastruktur muss deshalb Auskunft darüber geben, auf welche Weise ein Kunde diese Information erhält. Würde ein Händler zum Beispiel seinen Premiumkunden besonderes Augenmerk schenken, indem er ihnen einen aktualisierten Produktkatalog zuschickt, der unter anderem auf die Garantiezeitverkürzung hinweist, sollte das Objektmodell um diese Interaktionsbeziehung erweitert werden.

Abbildung 58 zeigt beispielhaft, wie durch das Hinzufügen der alternativen Infrastrukturbeziehung auf der Objektebene ein differenzierteres Kausalverständnis auf der Ereignisebene gebildet werden konnte.

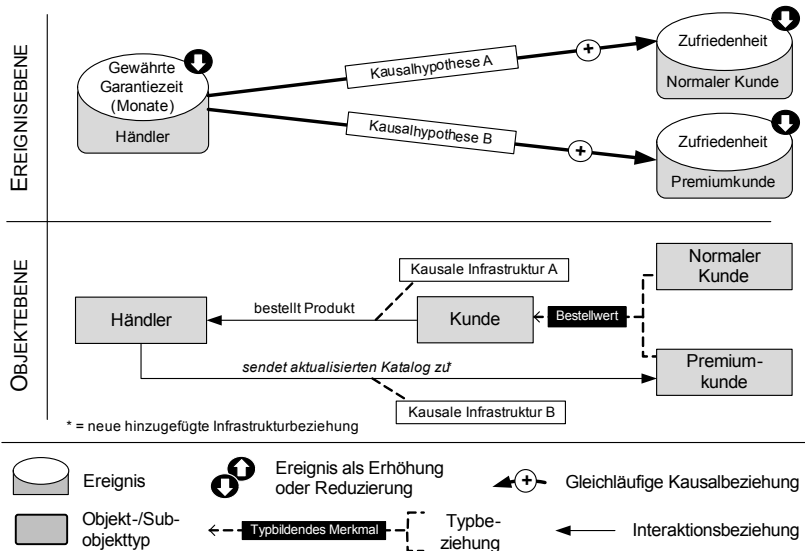


Abbildung 58: Plausibilisierung einer Kausalhypothese durch Hinzufügen einer alternativen Infrastrukturbeziehung

Diese Erweiterung auf der Objektebene bietet nun die Möglichkeit, den Kausalzusammenhang auf der Ereignisebene zu präzisieren: Während Premiumkunden die Garantiezeitverkürzung aus dem aktualisierten Katalog entnehmen können, erfahren normale Kunden dies erst bei ihrer nächsten Bestellung. Mit dieser zusätzlichen Infrastrukturbeziehung ließe sich erklären, weshalb sich eine Garantiezeitverkürzung bei normalen Kunden anders auswirkt als bei Premiumkunden. Der Ärger über eine Garantiezeitverkürzung könnte bei normalen Kunden deshalb größer sein, weil diese später davon erfahren, nämlich erst bei ihrer nächsten Bestellung.

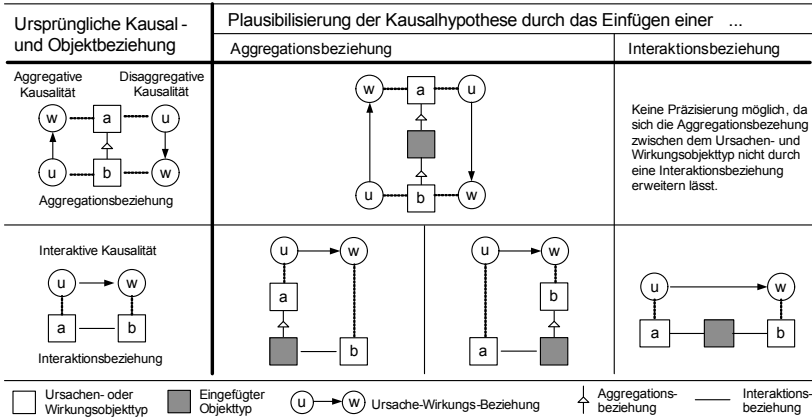


Abbildung 59: Plausibilisierung einer Kausalhypothese durch die Präzisierung der kausalen Infrastruktur

Neben der Erweiterung des Objektmodells um neue Infrastrukturbeziehungen lässt sich ein Kausalzusammenhang auch dadurch plausibilisieren, indem man eine bereits vorhandene Infrastrukturbeziehung präzisiert (siehe Abbildung 59). Zu diesem Zweck fügt man in die Infrastrukturbeziehung einen neuen Objekttyp ein. Dieser erweitert die kausale Infrastruktur dann entweder um eine Aggregations- oder Interaktionsbeziehung. Der eingefügte Objekttyp sorgt dafür, dass die beiden Objekttypen, die zuvor in einer direkten Beziehung standen, nur noch transitiv miteinander verbunden sind. Der eingefügte Objekttyp kann dann als Träger eines Zwischenereignisses ausgewählt werden, das den Ursache-Wirkungs-Zusammenhang darüber hinaus auch auf der Ereignisebene präzisiert. Anstatt das Wirkungsereignis direkt hervorzurufen, verursacht das Ursachenereignis das Wirkungsereignis dann nur noch mittelbar: Das Ursachenereignis ruft das Zwischenereignis hervor, welches wiederum das Wirkungsereignis verursacht. Das Zwischenereignis überbrückt somit die Distanz zwischen Ursache und Wirkung. Dadurch lassen sich auf der Ereignisebene etwaige Verständnislücken schließen und man kann den Kausalzusammenhang leichter erklären.

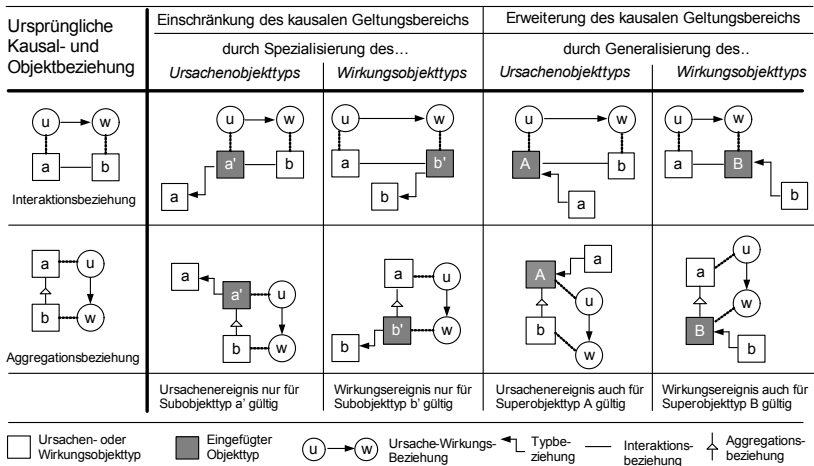


Abbildung 60: Plausibilisierung einer Kausalhypothese durch Einschränkung oder Erweiterung des kausalen Geltungsbereichs

Die dritte Möglichkeit zur Plausibilisierung einer Kausalhypothese besteht darin, den kausalen Geltungsbereich anzupassen. Im Gegensatz zur Präzisierung einer Infrastrukturbeziehung kommt es nun zu einem Wechsel des Ereignisträgers. Hierzu wird zwar ebenfalls ein neuer Objekttyp eingefügt, dieser Objekttyp ersetzt jedoch den ursprünglichen Ereignisträger, indem er diesen spezialisiert oder generalisiert. Je nachdem, ob ein Sub- oder Superobjekttyp eingefügt wird, schränkt dieser Objekttyp den kausalen Geltungsbereich der Kausalhypothese entweder ein oder erweitert diesen. Voraussetzung ist, dass der eingefügte Objekttyp sämtliche Infrastrukturbeziehungen des ursprünglichen Ereignisträgers übernimmt. Abbildung 60 zeigt, wie sich der kausale Geltungsbereich einer Kausalhypothese durch eine Spezialisierung und Generalisierung einschränken und erweitern lässt.

Nachdem man verschiedene Kausalhypothesen aus Typsicht formuliert und plausibilisiert hat, sind diese in der letzten Prozessphase in eine Lösung für das ursprüngliche Untersuchungsproblem zu transformieren.

6.1.4 Lösungstransformation

Hat man mehrere, alternative Kausalhypothesen entwickelt, muss entschieden werden, mit welcher dieser Kausalhypothesen sich das Untersuchungsproblem

am besten lösen lässt. Hierzu muss die Neuheit, Verständlichkeit, Gültigkeit und Nützlichkeit der Kausalhypothesen bewertet werden. Es richtet sich der Blick sowohl auf die Kausalbeziehungen der Ereignisebene als auch auf die zugrunde liegende kausale Infrastruktur der Objektebene. Abbildung 61 skizziert das Vorgehen bei der Lösungstransformation.




Abbildung 61: Prozessschritt der Lösungstransformation

Die *Verständlichkeit* der Kausalhypothese bemisst sich am Informationsstand des Informationsempfängers. Verständlich ist ein Kausalzusammenhang dann, wenn der Wirkmechanismus sowohl auf der Ereignis- als auch auf der Objektebene nachvollzogen werden kann. Wie in Abschnitt 5.1.2 gefordert, sollen sich neben dem Informationsstand des Empfängers auch die Evidenzen, die auf die Gültigkeit des Kausalzusammenhangs hinweisen, zur Erklärung des Zusammenhangs nutzen lassen. Dies ist nun der Fall, da sich jetzt beurteilen lässt, inwieweit sich das Objektvokabular der kausalen Infrastruktur mit dem des Informationsempfängers deckt. Dasselbe gilt für das auf dem Objektvokabular aufbauende Ereignisvokabular. Je nachdem, wie groß die Lücke zum Ereignis- und Objektvokabular des Informationsempfängers ausfällt, ist ein Rücksprung in die Phase der Verfahrensanwendung nötig, um die Kausalhypothesen zu plausibilisieren.

Neu ist eine Kausalhypothese in erster Linie dann, wenn auf der Ereignisebene ein bislang unbekannter Ereigniszusammenhang formuliert wurde. Eine neue Kausalinformation liegt aber auch dann vor, wenn auf der Objektebene neue Erkenntnisse über die kausale Infrastruktur gewonnen wurden. In beiden Fällen dient der Informationsstand des Informationsempfängers als Maßstab. So kann dem Informationsempfänger zwar bekannt sein, dass eine Garantiezeitverkürzung zu einem Rückgang der Kundenzufriedenheit führt, möglicherweise wusste er aber nicht, dass dieser Kausalzusammenhang auch davon abhängt, welcher Kundengruppe ein Kunde angehört (siehe Abbildung 58).

Indem man die kausale Infrastruktur eines Kausalzusammenhangs offen gelegt hat, ist damit zunächst nur die Möglichkeit eines Kausalzusammenhangs nachgewiesen. Um die Gültigkeit der Hypothese zu bewerten, muss geprüft werden, ob der Ereigniszusammenhang auch unter den Gegebenheiten der realen Untersuchungssituation so zustande kommen kann, wie er modelliert wurde. Dies ist der Fall, wenn es im Objektbereich tatsächlich Objekte gibt, die die Objekttypen der kausalen Infrastruktur instanzieren und in der erforderlichen Infrastrukturbeziehung stehen. Obwohl das kausale Wesensmerkmal der Chronologie datenzentriert nachzuweisen ist, kann die zeitliche Reihenfolge der Interaktionen ebenfalls berücksichtigt werden. So kann eine Interaktionsbeziehung einen Kausalzusammenhang nur dann stützen und erklären, wenn die Interaktionsbeziehung zwischen dem Ursachen- und Wirkungsobjekt nach Eintritt des Ursachenereignisses, aber vor Eintritt des Wirkungsereignisses bestand. Zum Beispiel kommt die Zusendung des Produktkatalogs (siehe Abbildung 58) nur dann als kausale Infrastruktur infrage, wenn der Händler den Katalog nach der Kürzung der Garantiezeit an die Premiumkunden verschickt hat und diese ihr Bestellverhalten nicht schon vor Erhalt des Katalogs geändert haben.

Ist man zu dem Ergebnis gelangt, dass eine Kausalhypothese verständlich, neu und gültig ist, muss zuletzt noch deren Nützlichkeit geprüft werden. Dies geschieht in zwei Schritten: Zuerst muss die Erklärungskraft der Hypothese beurteilt werden, bevor aus der restlichen Hypothesenmenge die Hypothesen ausgewählt sind, die dem Informationsempfänger den größeren Handlungsspielraum zur Problemlösung und Zielerreichung verschaffen.

Je nachdem, ob die Untersuchung als Ursachen- oder Wirkungsforschung durchgeführt wurde (siehe Abschnitt 5.1.4.1), sind die Kausalhypothesen zu bestimmen, die das Ausgangsereignis am besten erklären oder dessen Auswirkungen vorhersagen. So könnte eine Garantiezeitverkürzung zwar einen Rückgang der Kundenzufriedenheit verursacht haben, aber möglicherweise nicht in dem Ausmaß, dass damit eine Kundenabwanderung zur Konkurrenz erklärt werden könnte. In einem solchen Fall müsste geprüft werden, ob sich das Ausgangsereignis durch eine andere Hypothese besser erklären lässt, oder ob nicht ein Zusammenwirken mehrerer Ursachen für die Zustandsänderung des Ausgangsereignisses verantwortlich sein könnte.

Um den Handlungsspielraum abzuschätzen, den eine Kausalhypothese dem Informationsempfänger verschafft, ist zwischen erwünschten und unerwünschten Kausalwirkungen zu differenzieren. Ist die Kausalwirkung einer Hypothese erwünscht, zeigt das Objektmodell die infrastrukturellen Voraussetzungen an,

die die Ursache benötigt, um die Wirkung hervorzurufen. Die Frage lautet dann, ob die Objektinstanzen tatsächlich über die modellierten Infrastrukturbeziehungen verbunden sind oder ob diese Beziehungen erst etabliert bzw. stabilisiert werden müssen. Im Falle einer unerwünschten Kausalwirkung informiert die kausale Infrastruktur darüber, wie sich der Kausaleinfluss verhindern lässt. Darüber hinaus muss das Ursachenereignis erst eintreten, um die Wirkung verursachen zu können. Hier stellt sich nicht nur die Frage, womit und mit welchem Aufwand sich der Eintritt eines Ursachenereignisses sicherstellen bzw. verhindern lässt, sondern auch, welche unbeabsichtigten Nebenwirkungen sich daraus ergeben. Derartige Fragen können dann eine Suche nach weiteren Kausalhypothesen anstoßen und somit eine neue Untersuchungssituation begründen.

6.2 Datenzentrierte Entwicklung von Kausalhypothesen

Neben der modellzentrierten Hypothesenentwicklung können Kausalhypothesen noch auf eine weitere Art evidenzbasiert entwickelt werden: mit datenzentrierten Analyseverfahren. Während die modellzentrierte Kausalanalyse die Bedingtheit eines Kausalzusammenhangs untersucht, lässt sich mit den datenzentrierten Verfahren die Gesetzmäßigkeit und Chronologie nachweisen.

Analog zur modellzentrierten Hypothesenentwicklung ist auch die datenzentrierte Entwicklung von Kausalhypothesen als modellgestützte Untersuchungssituation konzipiert. Es können ebenfalls die vier Phasen der Zieltransformation, Modellkonstruktion, Verfahrensanwendung und Lösungstransformation unterschieden werden. Im Gegensatz zur modellzentrierten Kausalanalyse, deren Modellsystem der typbezogenen Kausalarchitektur folgt, beruht das Modellsystem der datenzentrierten Verfahren auf einer instanzbezogenen Kausalarchitektur. Die datenzentrierten Analyseverfahren werten die Datenspuren aus, die einzelne Ereignisse bei ihrem Auftreten in der Datenbasis hinterlassen. Ziel ist es, die von den Ereignissen hervorgerufenen Merkmalsänderungen zu analysieren und nach Merkmalskorrelationen zu suchen, die auf einen gültigen Kausalzusammenhang hinweisen.

Anders als bei der datenzentrierten Überprüfung einer Kausalhypothese, bei der man hypothesengetrieben vorgeht und das gesuchte Datenmuster vor der Analyse spezifiziert, greift man für die Entwicklung einer Hypothese auf datengetriebene Analyseverfahren zurück. Um allerdings mit den datengetriebenen Verfahren des Data-Minings aussagekräftige und verwertbare Ergebnisse zu erhalten, müssen zusätzlich Aufgaben zur Vor- und Nachbereitung der Analyse

durchgeführt werden. Zusammen mit der eigentlichen Datenanalyse lassen sich diese Aufgaben zu einem umfassenden Wissensentdeckungsprozess zusammenfassen (vgl. [NeKn05, S. 152]). Dieser Wissensentdeckungsprozess wird in der englischsprachigen Data-Mining-Literatur auch als *Knowledge Discovery in Databases* (KDD) bezeichnet.

Der KDD-Begriff wurde erstmals 1989 offiziell verwendet, als er zum Gegenstand eines Workshops über Künstliche Intelligenz in Detroit wurde (vgl. [Biss96, S. 5]). Obwohl englische Autoren frühzeitig zwischen KDD und Data-Mining differenziert hatten, verwendeten einige deutschsprachige Autoren, wie zum Beispiel Küppers (vgl. [Küpp99, S. 24]), beide Begriffe synonym (vgl. [Mult00, S. 47]). In dieser Arbeit werden beide Begriffe voneinander abgegrenzt und die Auffassung von Fayyad et al. geteilt (vgl. [FaPS96, S. 4]). Demnach bezeichnet Data-Mining lediglich die Anwendung von Verfahren zur Entdeckung von Datenmustern und ist lediglich ein Teilprozessschritt des KDD-Prozesses. Dieser Prozess wird in der Literatur traditionell in mehrere Phasen unterteilt (vgl. [FaPS96, S. 10], [EsSa00, S. 2-6], [Säub00, S. 22-39]), die sich wie folgt den vier Phasen der modellgestützten Untersuchungssituation zuordnen lassen:

1. Problemanalyse (Zieltransformation),
2. Datenvorverarbeitung und -transformation (Modellkonstruktion),
3. Datenanalyse (Verfahrensanwendung),
4. Ergebnisinterpretation (Lösungstransformation).

Im Folgenden werden die vier Phasen sowie die darin enthaltenen Teilprozessschritte vorgestellt. Die Prozessphasen sind allerdings nicht als ein starres und fest vorgegebenes Vorgehensmodell, sondern vielmehr als „Empfehlungen zur Strukturierung idealtypischer Untersuchungsvorgänge“ [Knob00, S. 28] zu interpretieren (vgl. [Resc05, S. 64]). Rücksprünge in vorherige Prozessabschnitte sind jederzeit möglich und - wie die folgenden Abschnitte zeigen werden - auch unvermeidlich.

6.2.1 Zieltransformation

Ebenso wie bei der modellzentrierten Hypothesenentwicklung besteht der *erste Prozessschritt* darin, das originäre Untersuchungsproblem zu spezifizieren, zu dessen Lösung die zu entwickelnde Kausalinformation beitragen soll. Hierbei ist insbesondere zu klären, für welches Ereignis man eine Kausalhypothese ent-

wickeln möchte und ob dies im Rahmen einer Ursachen- oder Wirkungsforschung geschehen soll (siehe Abschnitt 5.1.4.1).

Im Gegensatz zur modellzentrierten Hypothesenentwicklung, bei der die Suche nach Kausalhypothesen in eine Suche nach Ursachen- bzw. Wirkungsobjekten transformiert wurde (siehe Abschnitt 6.1.1), sucht man nun nach aussagekräftigen Datenmustern, die sich als Hinweis auf einen Kausalzusammenhang interpretieren lassen. Das ursprüngliche Untersuchungsziel muss daher im *zweiten Prozessschritt* in eine Fragestellung transformiert werden, die sich mithilfe der in Abschnitt 5.3.1 vorgestellten Data-Mining-Verfahren beantworten lässt. Zuvor ist allerdings erst der Objektbereich zu definieren, auf den man sich bei der Datenanalyse und der Suche nach Kausalhypothesen beschränken möchte. Der Objektbereich beschreibt den betrieblichen Kontext, aus dem man in der Phase der Modellkonstruktion die Ereignis- und Objektdaten entnimmt. Abbildung 62 fasst die beiden Prozessschritte der Zieltransformation zusammen.

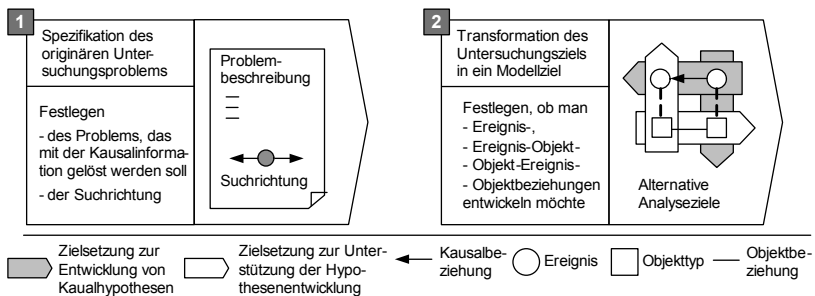


Abbildung 62: Prozessschritte der Zieltransformation

Im Rahmen der Zieltransformation sollte auch kritisch hinterfragt werden, ob sich die analytische Fragestellung nicht auch mit alternativen und weniger aufwändigen Analyseverfahren, etwa SQL-Anfragen, statistischen Standardverfahren oder einer OLAP-Analyse beantworten lässt (vgl. [KrWZ98, S. 40]). Verfügt man bereits über vage Kausalannahmen oder glaubt man zu wissen, durch welche charakteristischen Eigenschaften sich die von dem Ereignis betroffenen Objektinstanzen besonders auszeichnen, sollten diese Vermutungen mit hypothesengetriebenen Analyseverfahren überprüft werden.

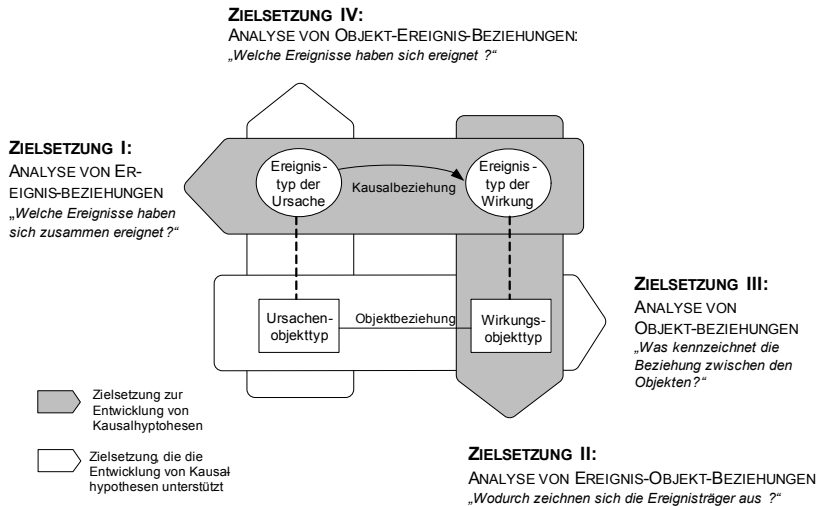


Abbildung 63: Generische Zielsetzungen der datenzentrierten Entwicklung einer Kausalhypothese

Das Untersuchungsobjekt der Datenanalyse sind die Daten einer instanzbezogenen Kausalarchitektur, die die Ereignis- und Objektinstanzen beschreiben, die sich wiederum auf die Ereignis- und Objekttypen der typbezogenen Kausalarchitektur beziehen (siehe Abschnitt 5.2.2, Abbildung 38). Aufgrund dieser Bezüge zwischen der Ereignis- und der Objektebene ergeben sich für die Datenanalyse vier generische Zielsetzungen: Es können die Beziehungen zwischen Ereignistypen, zwischen Objekttypen oder zwischen Ereignis- und Objekttypen analysiert werden (siehe Abbildung 63).

Obwohl jede der vier möglichen Zielsetzungen in eine eigene Untersuchungssituation mündet, erhält man nur mit den Zielsetzungen I und II ein Analyseergebnis, das sich direkt für die Entwicklung neuer Kausalhypthesen nutzen lässt. Das ursprüngliche Untersuchungsziel muss deshalb in eine analytische Fragestellung transformiert werden, bei der entweder Ereignisbeziehungen (Zielsetzung I) oder die ereignistragenden Objekte (Zielsetzung II) Gegenstand der Analyse sind. Wie allerdings die Kombination der Gestaltungsoptionen in Abschnitt 6.5 zeigen wird, lässt sich die Entwicklung von Kausalhypthesen mit einer Analyse von Objekt-Ereignis- und Objektbeziehungen (Zielsetzungen III und IV) unterstützen. Die vier Zielsetzungen werden im Folgenden einzeln vorgestellt.

Die Analyse von *Ereignisbeziehungen* ist die Zielsetzung, deren Ergebnis unmittelbar auf potenzielle Kausalbeziehungen hindeutet. Für einen Ereignistyp sollen andere Ereignistypen identifiziert und beschrieben werden, die sich mit diesem kausal verknüpfen lassen. In der Datenbasis analysiert man die Ereignisinstanzen dieser Ereignistypen und sucht nach Merkmalskorrelationen, die auf Kausalbeziehungen hinweisen.

Die zweite Zielsetzung ist die Analyse von *Ereignis-Objekt-Beziehungen*. Ausgehend von einem Ereignistyp versucht man die Typmerkmale eines ereignistragenden Objekttyps so präzise wie möglich zu bestimmen. In der Datenbasis müssen hierzu die Objektinstanzen, die von einem Ereignis des Ereignistyps betroffen waren, anhand ihrer Merkmale und Merkmalswerte charakterisiert werden. Sollen neue Kausalhypothesen entwickelt werden, lässt sich mit dieser Analyse die Heuristik der Differenzmethode nach John Stuart Mill nachbilden (vgl. [Mack74, S. 73], [Mill75], [BaGr04, S. 204]).¹ Bei dieser Methode sucht man gezielt nach Unterschieden zwischen den Objektinstanzen, die von einem Ereignis des Ereignistyps betroffen waren, und denen, die kein Ereignisträger sind. Die gefundenen Merkmalsunterschiede können dann auf potenzielle Ursachen- oder Wirkungsereignisse hinweisen. Verbirgt sich hinter einer charakteristischen Eigenschaft ein abgeleitetes Objektmerkmal, so verweist dieses auf einen anderen Objekttyp, nämlich auf den Objekttyp, dessen originäres Merkmal über die Objektbeziehungen vererbt wurde (siehe Abschnitt 5.2.1.1, Abbildung 42). Dieser Objekttyp käme dann als Träger eines Ursachen- oder Wirkungsereignisses infrage.

Kommt es zum Beispiel in der Fahrzeugflotte einer Mietwagenfirma wiederholt zu Kupplungsschäden, kann bei der Ursachenanalyse gezielt nach Gemeinsamkeiten zwischen den schadhafte Autos gesucht werden. Fehlt es allerdings an solchen Gemeinsamkeiten bezüglich der objekteigenen Merkmale der Autos, etwa hinsichtlich Baujahr oder Motorisierung, können zusätzlich Merkmale der Fahrer in die Analyse einbezogen werden. Stellt man dann fest, dass 80% aller Autos mit Kupplungsschäden von amerikanischen Kunden gefahren wurden, kommen diese als Ursachenobjekt infrage. Eine mögliche Erklärung wäre, dass in Amerika überwiegend Autos mit Automatikgetriebe gefahren werden und deshalb amerikanische Kunden das Kuppeln mit manuellem Getriebe nicht gewohnt sind.

¹ Mackie verwendet in diesem Zusammenhang auch den Begriff des kausalen Feldes (*causal field*), vor dessen Hintergrund sich kausal relevante Unterschiede erkennen lassen (vgl. [Mack74, S. 35]).

Die Analyse von Ereignisbeziehungen (Zielsetzung I) lässt sich mit der Analyse von *Objekt-Ereignis-Beziehungen* (Zielsetzung IV) unterstützen. Für die Objektinstanzen eines Objekttyps werden neue, noch unbekannte Ereignisinstanzen gesucht, die sich zu einem neuen Ereignistyp zusammenfassen lassen. In der Datenbasis analysiert man hierzu die Daten über die Objektinstanzen und sucht nach Merkmalsänderungen, die sich als Zustandsänderungen von Ereignissen interpretieren lassen. Im Anschluss können dann die Ereignisbeziehungen zum Ausgangsereignis analysiert werden (Zielsetzung I), indem man nach Merkmalskorrelationen zwischen den Ereignismerkmalen sucht. Vermutet man beispielsweise, dass ein Verlust an Kunden durch ein produktbezogenes Ereignis ausgelöst worden sein könnte, kann man mit einer Analyse der Objekt-Ereignis-Beziehungen (Zielsetzung IV) nach auffälligen Merkmalsänderungen in den Produktdaten suchen. Hat man auf diese Weise zum Beispiel Qualitätsabweichungen entdeckt, kann anschließend mit einer Analyse der Ereignisbeziehungen (Zielsetzung I) untersucht werden, welche dieser Qualitätsveränderungen am stärksten mit den Merkmalen des Ausgangsereignisses, dem Kundenverlust, korreliert.

Bei einer Analyse von *Objektbeziehungen* (Zielsetzung III) versucht man Strukturhypothesen zu entwickeln. Korrespondierend mit den drei Arten von Objektbeziehungen lassen sich drei Arten von Strukturhypothesen unterscheiden:

- Eine *Aggregationshypothese* trifft eine Aussage über die Typmerkmale von Teilobjektinstanzen. Beispiel: In erfolgreichen Projekten arbeiten überwiegend ältere und erfahrene Mitarbeiter.
- Eine *Interaktionshypothese* trifft eine Aussage über die Typmerkmale von interagierenden Objektinstanzen. Beispiel: Biolebensmittel werden überwiegend von alleinstehenden Frauen zwischen 30 und 40 gekauft.
- Eine *Typhypothese* impliziert, dass Objektinstanzen eines bestimmten Subobjekttyps existieren oder in einem bestimmten zahlenmäßigen Verhältnis zu einem benachbarten Subobjekttyp oder übergeordneten Superobjekttyp stehen. Beispiel: Unter den männlichen Kunden ist der Anteil der Familienväter am größten.

Die bei der Formulierung einer Strukturhypothese gebildeten Subobjekttypen können bei einer Analyse von *Ereignis-Objekt-Beziehungen* (Zielsetzung II) als potenzielle Ereignisträger berücksichtigt werden. Versucht man zum Beispiel einen Umsatzrückgang zu erklären, kann geprüft werden, ob sich die von dem Umsatzrückgang besonders betroffenen Lebensmittel dadurch auszeichnen, dass

sie zuvor überwiegend von alleinstehenden Frauen zwischen 30 und 40 gekauft wurden. Falls dies zutrifft, ließe sich als Ursache für den Umsatzrückgang eine Abwanderung alleinstehender Frauen zwischen 30 und 40 vermuten.

Die Wahl der Zielsetzung entscheidet darüber, welche Daten in der zweiten Phase, der Modellkonstruktion, bereitgestellt und aufbereitet werden müssen. So benötigt man für die Analyse von Ereignisbeziehungen (Zielsetzung I) eine andere Datenbasis als für die Analyse von Ereignis-Objekt-Beziehungen (Zielsetzung II). In der Praxis wird man häufig gezwungen sein, die Zielsetzung mit Blick auf die verfügbaren Daten auszuwählen.

6.2.2 Modellkonstruktion

Ziel der Modellkonstruktion ist es, das Modellsystem einer instanzbezogenen Kausalarchitektur zu erstellen, dessen Ereignis- und Objekt Daten in der darauf folgenden Phase der Verfahrensanwendung analysiert werden sollen. In Anlehnung an das KDD-Prozessmodell lässt sich die Phase der Modellkonstruktion in folgende Prozessschritte unterteilen (vgl. [FaP596, S. 10], [Düsi99, S. 348]): die Selektion der Daten sowie deren Exploration und Manipulation. Abbildung 64 skizziert das Vorgehen der beiden Prozessschritte.




Abbildung 64: Prozessschritte der Modellkonstruktion

Im *ersten Prozessschritt* sind die Datenquellen danach auszuwählen, ob ihre Daten etwas zur Beantwortung der analytischen Fragestellung beitragen können (vgl. [BeLi00, S. 49]). Die Daten lassen sich ihrer Herkunft nach in unternehmensexterne und -interne Daten differenzieren. Ferner kann unterschieden werden, ob die Daten bereits verfügbar oder speziell für die jeweilige Untersuchung zu generieren sind (vgl. [Pyle03, S. 221]). Unabhängig davon muss für die Anwendung von Data-Mining-Verfahren auf ein ausreichend hohes Datenvolumen geachtet werden. Prinzipiell gilt, dass so viele Datensätze wie möglich in die Analyse einbezogen werden sollten (vgl. [Knob00, S. 30]), da dies die Zuverlässigkeit

sigkeit und Aussagekraft der Ergebnisse erhöht. Ist es notwendig, die Anzahl der Datensätze zu beschränken, zum Beispiel um eine bessere Performance bei der Verfahrensanwendung zu erzielen, sollte auf eine hinreichend repräsentative Stichprobe geachtet werden (vgl. [HiWi01, S. 47]).

Aus welchen Daten das Modellsystem zu konstruieren ist, hängt sowohl von dem verwendeten Analyseverfahren als auch von der gewählten Zielsetzung ab. Mit welcher Kombination aus Analyseverfahren und Daten sich welche der vier Zielsetzungen verfolgen lässt, wird deshalb erst im folgenden Abschnitt, bei der Verfahrensanwendung, erläutert. Bis auf die Analyse von Objektbeziehungen können jedoch alle Zielsetzungen sowohl mit Ereignis- als auch Objektdaten durchgeführt werden. Speziell für Objektdaten gilt, dass sich die relevanten Datenobjekttypen aus dem Objektmodell der typbezogenen Kausalarchitektur ableiten lassen (siehe Abschnitt 5.2.2.1). Dies setzt allerdings voraus, dass ein derartiges Objektmodell bereits vorliegt. Dies wäre der Fall, falls zuvor Kausalhypothesen modellzentriert entwickelt wurden. Die Synergieeffekte zwischen modell- und datenzentrierten Gestaltungsoptionen werden am Ende des Kapitels, in Abschnitt 6.5, vorgestellt.

Nach der Selektion der Daten sollte man sich im *zweiten Prozessschritt* mit den verfügbaren Daten und ihren spezifischen Datenmängeln und -fehlern vertraut machen. Dies geschieht bei der Exploration der Daten, die sich bereits mit einfachen SQL-Anfragen oder Werkzeugen zur visuellen Dateninspektion durchführen lässt (vgl. [AdZa96, S. 47]). Ergänzend können statistische Häufigkeitsverteilungen auf fehlende oder mit Fehlern behaftete Merkmalswerte hinweisen (vgl. [BeLi97, S. 67]). Setzen sich die Analysedaten aus mehreren Datenquellen zusammen, erhöht sich die Gefahr, auf semantische und syntaktische Inkonsistenzen sowie redundante Datensätze oder Datenfelder zu stoßen. Bei der Bewertung der Quelldaten sollte auch der Zweck ihrer Erfassung berücksichtigt werden, da dieser darüber entscheidet, welche Ereignis- und Objektinstanzen in der Datenquelle erfasst werden (vgl. [Pyle03, S. 68]).

Data-Warehouse-Daten weisen in der Regel eine höhere Datenqualität auf als Daten, die direkt aus operativen Anwendungssystemen entnommen sind (vgl. [Küpp99, S. 44]). Dennoch können sich Data-Warehouse-Daten für bestimmte Zielsetzungen als untauglich erweisen, da diese Daten zum Teil nur in aggregierter, grobgranularer oder normalisierter Form vorliegen (vgl. [BeLi00, S. 17]). Dies kann die Anzahl der potenziell zu entdeckenden Datenmuster empfindlich einschränken (vgl. [Mult00, S. 59]).

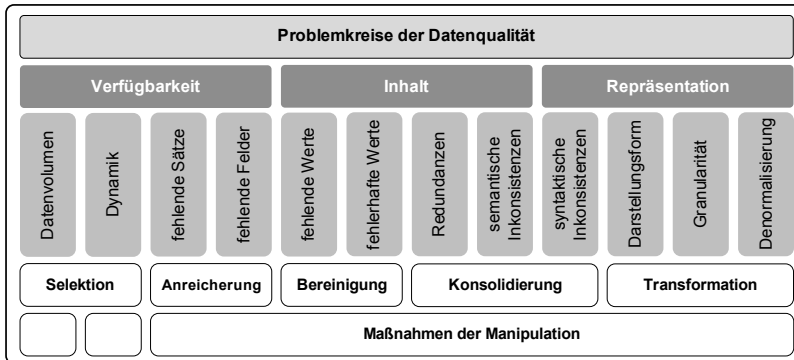


Abbildung 65: Datenqualitätsprobleme und Möglichkeiten ihrer Behebung (in Anlehnung an [Knob00, S. 32])

Bevor mit der Analyse begonnen werden kann, müssen die identifizierten Datenqualitätsprobleme behoben werden. Dies erfolgt bei der Manipulation der Daten. Laut Knobloch treten Datenqualitätsprobleme entweder hinsichtlich der Verfügbarkeit, des Inhalts oder der Repräsentation der Daten auf. Abbildung 65 fasst die insgesamt zwölf Problemkreise der Datenqualität zusammen. Während man einem zu geringen Datenvolumen oder Datensätzen mit einer hohen Änderungsdynamik nur mit einer anderen Datenselektion begegnen kann, lassen sich die weiteren zehn Problemkreise durch eine gezielte Datenmanipulation beheben. Hierzu zählt die Anreicherung, die Bereinigung, die Konsolidierung sowie die Transformation der Daten (vgl. [Knob00, S. 33-37]).

6.2.3 Verfahrensanwendung

Die Phase der Verfahrensanwendung gliedert sich in die drei Suchschritte der Verfahrens-, Methoden- und Parametersuche (vgl. [Küpp99, S. 121]) sowie die eigentliche Durchführung der Analyse (siehe Abbildung 66).




Abbildung 66: Prozessschritte der Verfahrensanwendung

Im *ersten Prozessschritt* muss zunächst bei der Verfahrenssuche das Analyseverfahren bestimmt werden, mit dem sich das Untersuchungsproblem lösen lässt. Jede Anwendung eines Verfahrens auf ein bestimmtes Untersuchungsproblem definiert eine eigene, modellgestützte Untersuchungssituation.¹ Da nicht jede Untersuchungssituation zu Ergebnissen führt, mit denen sich auch neue Kausalhypothesen entwickeln lassen, sind Analyseverfahren, Modellsystem und Zielsetzung sorgfältig aufeinander abzustimmen.

Hat man sich auf ein Analyseverfahren festgelegt, muss als Nächstes die Analysemethode festgelegt werden, mit der man die Daten analysieren möchte. Hippner und Wilde schlagen vor, bei der Auswahl der Analysemethode mehrere Kriterien zu berücksichtigen (vgl. [HiWi01, S. 66-70]): Da sich nicht alle Methoden für jede Problemstellung gleichermaßen eignen, sollten diese zum Beispiel hinsichtlich ihrer Anwendungsprämissen oder ihrer Robustheit gegenüber Datenfehlern ausgewählt werden. Unterschiede bestehen häufig auch bezüglich der erzielbaren Approximations- und Prognosefähigkeit. Darüber hinaus lassen sich die erzeugten Datenmuster oft verschieden leicht interpretieren. So kann der Anwender zum Beispiel das von Neuronalen Netzen verwendete Lösungsverfahren nicht mehr nachvollziehen, was die Akzeptanz der Ergebnisse, insbesondere bei der Beantwortung risikoreicher Fragestellungen, erheblich schmälern kann (vgl. [Mult00, S. 80]).

Im Anschluss an die Methodensuche muss die ausgewählte Analysemethode parametrisiert werden (vgl. [Küpp99, S. 121]). Die Methodenparameter steuern den algorithmisch-technischen Ablauf der Mustererkennung. Für die Methoden zur Abhängigkeitsanalyse können beispielsweise Schwellwerte für die Support-, Lift- oder Confidence-Werte der gefundenen Regeln angegeben werden (siehe

¹ Neckel und Knobloch sprechen in diesem Zusammenhang auch von verschiedenen Analysefällen, wobei ein Analysefall aus der Anwendung eines Analyseverfahrens auf ein Analyseproblem besteht, das sich wiederum aus einem Analyseziel und den Analysedaten zusammensetzt (vgl. [NeKn05, S. 172]).

Abschnitt 5.3.1.3). Mit welchen Parametern sich die Analyse steuern lässt, hängt maßgeblich von der verwendeten Analysesoftware ab, da die Hersteller oft proprietäre Methodenparameter anbieten.

Charakteristisch für den Einsatz von Data-Mining-Verfahren ist es, dass vor allem die Schritte der Methoden- und Parametersuche iterativ zu durchlaufen sind - so lange, bis eine geeignete Methode mit einer Erfolg versprechenden Parametrisierung gefunden ist (vgl. [Knob00, S. 37]). In vielen Fällen ist ein Rücksprung in die Phase der Modellkonstruktion nötig, da die Daten abhängig von der Analysemethode erneut aufbereitet werden müssen (vgl. [HiWi01, S. 70]).

Ist die ausgewählte Analysemethode parametrisiert, folgt schließlich der *zweite Prozessschritt*: die Durchführung der Analyse. Hierbei ist es ratsam, unterschiedliche Methoden auszuprobieren, da dies eine tiefgründigere Analyse ermöglicht als der Einsatz einer einzelnen Methode (vgl. [Küpp99, S. 99-100], [Mult00, S. 57]). Die Analyseergebnisse verschiedener Methoden können dann verglichen und gegebenenfalls zu einem aussagekräftigeren Gesamtergebnis kombiniert werden. Dadurch erhöht sich in der Regel die Zuverlässigkeit und Sicherheit der Ergebnisse (vgl. [Küpp99, S. 100], [BeLi00, S. 216]). Im Folgenden werden die Kombinationen aus Analyseverfahren, Modellsystem und Zielsetzung vorgestellt, die eine für die Kausalanalyse relevante Untersuchungssituation bilden.

Die Analyse von Ereignisbeziehungen (Zielsetzung I) kann mit Methoden aus jeder der vier Verfahrensklassen durchgeführt werden. Tabelle 1 fasst die insgesamt sechs verschiedenen Untersuchungssituationen zusammen.

Mit einer *Abhängigkeitsanalyse* (siehe Tabelle 1: a) lässt sich die Frage beantworten, welche Ereignisse besonders häufig zusammen auftreten. Hierfür benötigt man ein Modellsystem aus Ereignisdaten, das jede Objektinstanz anhand von Merkmalen verschiedener Ereignisse beschreibt. Die Ausprägungen der Ereignismerkmale geben an, welche Objektinstanzen innerhalb des betrachteten Zeitraums von welchen Ereignissen betroffen waren (siehe Abschnitt 5.2.2.2). Als Analyseergebnis erhält man Regeln, die die Abhängigkeitsbeziehungen zwischen den Ereignismerkmalen beschreiben. Auf diese Weise kann zum Beispiel für ein Produkt untersucht werden, welche Mängel abhängig von anderen Mängeln innerhalb der vom Händler gewährten Garantiezeit zusammen aufgetreten sind. Die Datenbasis muss zu diesem Zweck sämtliche für einen bestimmten Produkttyp reklamierten Mängel verzeichnen. Als Ergebnis würde man dann Regeln der folgenden Form erhalten: „In 80% der Fälle, in denen der Mangel A rekla-

miert wurde, ist auch Mangel B reklamiert worden; von beiden Mängeln waren 20% aller verkauften Produkte betroffen“. Dies deutet zwar auf eine Beziehung zwischen den beiden Mängeln hin, ob diese allerdings kausaler Natur ist, muss in der nächsten Prozessphase - bei der Interpretation der Analyseergebnisse - beurteilt werden.

Analyseverfahren	Analytische Fragestellung	Modellsystem
ASSOZIATIONSANALYSE (siehe Abschnitt 5.3.1.3)		
a) Abhängigkeitsanalyse	Welche Ereignisse treten stets gemeinsam auf?	Zeitpunkt bezogene Ereignisdaten
b) Sequenzanalyse	Welche Ereignisse ereignen sich regelmäßig in einer bestimmten Reihenfolge?	Zeitverlauf beschreibende Ereignisdaten
SEGMENTIERUNG (siehe Abschnitt 5.3.1.1)		
c) Segmentierende Verfahren	Welche Ereignisse treten in bestimmten Gruppen von Ereignisträgern gemeinsam auf?	Zeitpunkt bezogene Ereignisdaten
ABWEICHUNGSANALYSE (siehe Abschnitt 5.3.1.2)		
d) Top-Down-Navigation	Welche Ereignisse haben sich bei den Objekten ereignet, die als Ereignisträger am meisten zu einer Gesamtabweichung beigetragen haben?	Zeitpunkt bezogene Ereignisdaten
PROGNOSE BZW. KLASSIFIKATIONSVERFAHREN (siehe Abschnitt 5.3.1.4)		
e) Entscheidungsbaumverfahren	Anhand welcher Ereignisse lassen sich die Ereignisträger von den Objekten abgrenzen, die von dem Ausgangsereignis nicht betroffen sind?	Zeitpunkt bezogene Ereignisdaten
f) Regressionsanalyse	Zwischen welchen Ereignissen oder Objektmerkmalen besteht eine Korrelationsbeziehung?	Zeitpunkt bezogene oder den Zeitverlauf beschreibende Ereignis- oder Objektdaten

Tabelle 1: Analysefälle für die Analyse von Ereignisbeziehungen

Mit einer Sequenzanalyse (siehe Tabelle 1: b) kann untersucht werden, welche Ereignisse sich besonders häufig in einer bestimmten Reihenfolge ereignen. Im Gegensatz zur Abhängigkeitsanalyse benötigt man Ereignisdaten, die die Ereigniseintritte im Zeitverlauf beschreiben. Als Ergebnis erhält man eine Liste typischer Ereignissequenzen. Aus den Ereignistypen einer Sequenz können dann jeweils zwei Ereignistypen ausgewählt und zu einer Kausalhypothese verknüpft werden. Beide Ereignistypen müssen in der Sequenz nicht unmittelbar aufeinander folgen. Da sich jedoch die Ursache stets vor der Wirkung ereignet, kommt als Ursachenereignis nur das Ereignis infrage, das sich früher ereignet hat und deshalb in der Sequenz weiter vorne eingeordnet ist.

Die Anwendung *segmentierender Verfahren* (siehe Tabelle 1: c) kann ebenfalls Hinweise auf Ereignisbeziehungen liefern. Für die Segmentierung benötigt man analog zur Abhängigkeitsanalyse ein Modellsystem, das aus Zeitpunkt bezogenen Ereignisdaten besteht. Die Objektinstanzen werden bei der Segmentierung anhand der Ausprägungen ihrer Ereignismerkmale in Segmente eingeteilt. Als Ergebnis erhält man Segmente, deren Objektinstanzen von jeweils ähnlichen oder sogar identischen Ereignissen betroffen waren. Die Ereignisse eines Segments können dann möglicherweise kausal verknüpft werden. Dies ist vor allem dann der Fall, wenn sich die Objektinstanzen eines kleinen Segments durch sehr spezielle oder seltene Ereignisse auszeichnen.

Mit der *Top-Down-Navigation* (siehe Tabelle 1: d) ist es ebenfalls möglich, Hinweise auf Ereignisbeziehungen zu erhalten. Zu diesem Zweck müssen die Objektinstanzen, aus deren Einzelabweichungen sich die untersuchte Gesamtabweichung zusammensetzt (Ausgangsereignis), anhand von Ereignismerkmalen charakterisiert werden. Benötigt werden auf einen Zeitpunkt bezogene Ereignisdaten, die die Ereignisse beschreiben, von denen die Objektinstanzen neben dem Ereignis der Abweichung zusätzlich betroffen waren. Der von der Top-Down-Navigation erzeugte Analysepfad gibt dann die Ereignisse an, von denen diejenigen Objektinstanzen betroffen waren, deren Einzelabweichungen die Gesamtabweichung maßgeblich verursacht haben. Ein Beispiel für einen solchen ereignisbasierten Analysepfad wäre etwa die Aussage, dass 60% des im letzten Jahr festgestellten Umsatzrückgangs auf Produkten beruht, deren Preis sich erhöht hat und bei denen die Anzahl der Reklamationen im Vergleich zum Vorjahr gestiegen ist. Aufgrund eines solchen Analyseergebnisses kann vermutet werden, dass die Ereignisse Umsatzrückgang, Produktreklamation und Preiserhöhung zusammenhängen. Welche Kausalhypothese jedoch den Umsatzrückgang tatsächlich erklärt, muss in der nächsten Phase, bei der Lösungstransformation, beurteilt werden.

Eine weitere Analyseverfahren, mit der sich Ereignisbeziehungen entdecken lassen, sind *Entscheidungsbäume* (siehe Tabelle 1: e). Ein Entscheidungsbaum besteht aus Klassifikationsregeln, die anhand verschiedener Merkmale darüber entscheiden, ob eine Objektinstanz von einem bestimmten Ereignis betroffen sein wird. Besteht das Modellsystem aus Ereignisdaten, zeigen die Klassifikationsregeln die Ereignisse an, von denen die Ereignisträger neben dem Ausgangsereignis ebenfalls betroffen waren. Untersucht man den Umsatzrückgang von Produkten, erhält man etwa folgende Regeln: „Wenn Produktmangel A und Produktmangel B, dann Umsatzrückgang“; „Wenn Produktmangel B und Pro-

duktmangel C, dann kein Umsatzrückgang“. Auf Grundlage dieser Regeln können dann in der nächsten Phase Kausalhypothesen formuliert werden, die voraussagen, bei welchen Produktmängeln mit einem Umsatzrückgang zu rechnen ist. Hierbei ist zu beachten, dass der hierarchische Aufbau des Entscheidungsbaums bereits für eine Gewichtung der Ereignismerkmale sorgt: Je höher sich ein Ereignismerkmal im Baum befindet, desto besser eignet es sich zur Vorhersage, welche Objektinstanzen (Produkte) von dem Ausgangsereignis (Umsatzrückgang) betroffen sein werden.

Die letzte Analysemethode zur Entdeckung von Ereignisbeziehungen ist die *Regressionsanalyse* (siehe Tabelle 1: f). Im Vergleich zu den anderen Analysemethoden stellt sie einen Sonderfall dar, da das Modellsystem sowohl aus Zeitpunkt bezogenen als auch aus Zeitverlauf beschreibenden Ereignis- oder Objektdaten bestehen kann. Die Regressionsanalyse untersucht, ob zwischen den verschiedenen Ereignis- oder Objektmerkmalen Korrelationsbeziehungen bestehen. Ob man Daten analysiert, die den Zeitverlauf beschreiben oder sich auf einen Zeitpunkt beziehen, hängt vom jeweiligen Analyseproblem und den verfügbaren Analysedaten ab. Für eine Regressionsanalyse eignen sich ausschließlich metrisch skalierte Objekt- und Ereignismerkmale.

Mit der Analyse von Ereignis-Objekt-Beziehungen (Zielsetzung II) versucht man, für ein oder mehrere Ereignisse die jeweils betroffenen Objektinstanzen anhand ihrer spezifischen Objektmerkmale zu beschreiben. Hierfür benötigt man ein Modellsystem aus Ereignis- und Objektdaten, das einerseits die Objektinstanzen anhand ihrer Objektmerkmale beschreibt, andererseits aber auch anzeigt, von welchen Einzelereignissen sie betroffen waren. Da es für die Analyse von Ereignis-Objekt-Beziehungen nur von Bedeutung ist, ob und nicht wann sich ein Ereignis ereignet hat, benötigt man ausschließlich auf einen Zeitpunkt bezogene Analysedaten. Auf diese Weise werden zum Beispiel in der Versicherungsbranche attraktive Kundengruppen identifiziert, denen günstigere Beitragssätze angeboten werden, zum Beispiel „Motorradfahrer, die 30 Jahre oder älter sind, eine Universitätsausbildung haben, über einen bestimmten Grad an Kreditwürdigkeit verfügen und bisher unfallfrei gefahren sind“ [Dave06, S. 76].

Analyseverfahren	Analytische Fragestellung	Modellsystem
ASSOZIATIONSANALYSE (siehe Abschnitt 5.3.1.3)		
a) Abhängigkeitsanalyse	Durch welche Objektmerkmale zeichnen sich die von den Ereignissen betroffenen Objekte aus?	Zeitpunkt bezogene Ereignis- und Objektdaten
SEGMENTIERUNG (siehe Abschnitt 5.3.1.1)		
b) Segmentierende Verfahren	Durch welche Objektmerkmale und Ereignisse zeichnen sich bestimmte Gruppen von Objekten aus?	Zeitpunkt bezogene Ereignis- und Objektdaten
ABWEICHUNGSANALYSE (siehe Abschnitt 5.3.1.2)		
c) Top-Down-Navigation	Durch welche Objektmerkmale zeichnen sich die Objekte aus, die besonders zur Gesamtabweichung beigetragen haben?	Zeitpunkt bezogene Ereignis- und Objektdaten
PROGNOSE BZW. KLASSIFIKATIONSVERFAHREN (siehe Abschnitt 5.3.1.4)		
d) Entscheidungsbaumverfahren	Anhand welcher Objektmerkmale und -werte lassen sich die Ereignisträger von den Objekten abgrenzen, die von dem Ausgangsereignis nicht betroffen sind?	Zeitpunkt bezogene Ereignis- und Objektdaten

Tabelle 2: Analysefälle für die Analyse von Ereignis-Objekt-Beziehungen

Bei der *Abhängigkeitsanalyse* (siehe Tabelle 2: a) sucht man nach Wenn-Dann-Regeln, die einen Zusammenhang zwischen Ereignis- und Objektmerkmalen herstellen. Erfährt man zum Beispiel, dass 70% der Produkte, bei denen Mangel A reklamiert wurde (Ereignismerkmal), neu entwickelte Produkte sind (Objektmerkmal), und dass dies auf 30% aller reklamierten Produkte zutrifft, kann daraus die Kausalhypothese abgeleitet werden, dass der Mangel A möglicherweise auf einen Fehler bei der Entwicklung neuer Produkte zurückzuführen ist.

Wendet man *segmentierende Verfahren* (siehe Tabelle 2: b) sowohl auf Ereignis- als auch auf Objektdaten an, können die Segmentbeschreibungen ebenfalls auf Ereignis-Objekt-Beziehungen hinweisen. Besteht ein Segment zum Beispiel aus Produktinstanzen, die sich dadurch auszeichnen, dass sie in Werk II hergestellt wurden (Objektmerkmal) und von Mängeln des Typs A und B betroffen sind (Ereignismerkmal), lässt dies den hypothetischen Schluss zu, dass beide Mängel aufgrund der werkspezifischen Besonderheiten in Werk II auftreten. Mit einem solchen Ereignis ließe sich vermuten, dass Werk II der Ereignisträger eines noch unbekanntes Ursachenereignisses ist, das die Mängel vom Typ A und B hervorruft.

Um Ereignis-Objekt-Beziehungen mittels *Top-Down-Navigation* (siehe Tabelle 2: c) zu entdecken, benötigt man ebenfalls Ereignis- und Objektdaten. Während Ereignisdaten die Einzelereignisse beschreiben, aus denen sich die Gesamtabweichung

chung zusammensetzt, charakterisieren die Objektdaten die Objektinstanzen, die zur Gesamtabweichung maßgeblich beitragen. Als Ergebnis erhält man einen Analysepfad, der die spezifischen Objektmerkmale und Werte angibt, durch die sich die für die Gesamtabweichung verantwortlichen Objektinstanzen auszeichnen (siehe Abbildung 47). Anhand der Objektmerkmale lässt sich der ereignisstragende Objekttyp differenzieren, indem man mit den Merkmalen und Merkmalswerten einen neuen Subobjekttyp bildet. Dieser Subobjekttyp könnte dann den ursprünglichen Objekttyp als neuen, spezifischeren Ereignisträger ablösen (siehe Beispiel in Abschnitt 5.3.1.2, Abbildung 45).

Nutzt man das *Entscheidungsbaumverfahren* (siehe Tabelle 2: d) in Verbindung mit Ereignis- und Objektdaten, können Ereignisträger und Nicht-Ereignisträger anhand ihrer Objektmerkmale abgegrenzt werden. Man erhält Wenn-Dann-Regeln, die es erlauben, auf Basis der spezifischen Merkmalswerte zu entscheiden, ob eine Objektinstanz von einem Ausgangsereignis betroffen sein wird oder nicht. Mit den Objektmerkmalen und Merkmalswerten einer Wenn-Dann-Regel lassen sich dann unterschiedliche Subobjekttypen bilden, die die ereignisstragenden Objektinstanzen zu verschiedenen Klassen zusammenfassen und den ursprünglichen Ereignisträger differenzieren und ablösen.

Analyseverfahren	Analytische Fragestellung	Modellsystem
ABWEICHUNGSANALYSE (siehe Abschnitt 5.3.1.2)		
a) Zeitreihenanalyse	Kommt es zu Ereignissen in Form von Trendänderungen oder Zyklusabweichungen?	Zeitverlauf beschreibende Ereignis- oder Objektdaten
PROGNOSE BZW. KLASSIFIKATIONSVERFAHREN (siehe Abschnitt 5.3.1.4)		
b) Autoprojektive Methoden	Werden die aktuellen Merkmalsänderungen in der Zukunft zu Abweichungen führen?	Zeitverlauf beschreibende Ereignis- oder Objektdaten

Tabelle 3: Analysefälle für die Analyse von Objekt-Ereignis-Beziehungen

Sollen neue Ereignisse entdeckt werden, führt man eine Analyse der Objekt-Ereignis-Beziehungen durch (Zielsetzung IV). Da ein Ereignis eine Zustandsänderung im Zeitverlauf beschreibt, benötigt man zwingend Daten, die die Merkmalsänderungen im Zeitverlauf beschreiben. Mit einer *Zeitreihenanalyse* (siehe Tabelle 3: a) lässt sich die Trend-, Zyklus- und Rauschkomponente einer Zeitreihe identifizieren und beschreiben. Dadurch können Abweichungen von einem bisherigen Trend- oder Zyklusverlauf erkannt werden. Ein bestimmtes Ereignis lässt sich dann entweder als ein den Trend bzw. Zyklus bestätigendes Ereignis oder als ein vom Trend bzw. Zyklus abweichendes Ereignis klassifizieren. Auf

diese Weise können Ereignisse erkannt werden, die zu Strukturbrüchen in der Zeitreihe führen und die andernfalls in der zusammengesetzten Zeitreihe unentdeckt bleiben würden. Als Analysedaten kommen ausschließlich numerische Ereignis- oder Objektdaten infrage.

Autoprojektive Methoden (siehe Tabelle 3: b) werden ebenfalls auf Zeitverlauf beschreibende Ereignis- oder Objektdaten angewandt. Ist es gelungen, eine Zeitreihe anhand von Autokorrelationen zu beschreiben, können zukünftige Ereignis- oder Objektdaten auf Basis vergangener Werte prognostiziert werden. Auf diese Weise lassen sich bestimmte Ereignisse frühzeitig erkennen, da man für eine Merkmalsabweichung zum Zeitpunkt t_0 bereits prognostizieren kann, wie stark die Merkmalsabweichung zum Zeitpunkt t_{0+n} sein wird. Für dieses zu erwartende Abweichungsereignis können dann in Folgeanalysen die Ursachen oder Wirkungen untersucht werden.

Analyseverfahren	Analytische Fragestellung	Modellsystem
ASSOZIATIONSANALYSE (siehe Abschnitt 5.3.1.3)		
a) Abhängigkeitsanalyse	Welche Ausprägungen von Objektmerkmalen treten bei den Objekten besonders häufig gemeinsam auf?	Zeitpunkt bezogene Objektdaten
SEGMENTIERUNG (siehe Abschnitt 5.3.1.1)		
b) Segmentierende Verfahren	Welche Gruppen von Objekten lassen sich anhand welcher Objektmerkmale abgrenzen?	Zeitpunkt bezogene Objektdaten
PROGNOSE BZW. KLASSIFIKATIONSVERFAHREN (siehe Abschnitt 5.3.1.4)		
c) Entscheidungsbaumverfahren	Anhand welcher Objektmerkmale und -werte lassen sich die Objekte zweier Subobjekttypen voneinander abgrenzen?	Zeitpunkt bezogene Objektdaten

Tabelle 4: Analysefälle für die Analyse von Objektbeziehungen

Für die Analyse von Objektbeziehungen (Zielsetzung III) reicht es aus, wenn Zeitpunkt bezogene Objektdaten vorliegen. Mit *Abhängigkeitsanalysen* (siehe Tabelle 4: a) kann untersucht werden, welche Ausprägungen von Objektmerkmalen besonders häufig zusammen auftreten. Eine Regel, die besagt, dass 70% der von Premiumkunden gekauften Produkte Neuentwicklungen sind, ermöglicht es, die ursprüngliche Interaktionsbeziehung zwischen den Objekttypen KUNDE und PRODUKT zu differenzieren: Anstatt die Superobjekttypen KUNDE und PRODUKT zu verbinden, lassen sich nun die Subobjekttypen PREMIUMKUNDE und NEU ENTWICKELTES PRODUKT über die Interaktionsbeziehung „kauft“ verknüpfen. Eine solche Strukturhypothese drückt ein differenziertes Wissen über die kausale

Infrastruktur aus und ermöglicht es vorauszusagen, dass sich eine Abwanderung von Premiumkunden vor allem auf den Umsatz der neu entwickelten Produkte negativ auswirken wird. Beziehen sich die Objektmerkmale auf denselben Objekttyp, können die Ergebnisse der Abhängigkeitsanalyse dazu verwendet werden, eine Typhypothese zu formulieren und für einen bislang noch undifferenzierten Objekttyp Subobjekttypen zu bilden.

Die von *segmentierenden Verfahren* (siehe Tabelle 4: b) gebildeten Segmente können ebenfalls auf neue, noch unentdeckte Objektbeziehungen und Subobjekttypen hinweisen. Ergebnis einer Kundensegmentierung könnte etwa ein Segment sein, das sich aus Kunden zusammensetzt, die zwar überwiegend Markenartikel kaufen, sich dabei aber meist auf das jeweils günstigste Angebot beschränken. Angesichts einer solchen Segmentbeschreibung könnte der neue Subobjekttyp PREISBEWUSSTER MARKENKÄUFER gebildet werden.

Mit den Ergebnissen von *Entscheidungsbaumverfahren* (siehe Tabelle 4: c) kann geklärt werden, anhand welcher Objektmerkmale und -werte sich die Objektinstanzen zweier Subobjekttypen voneinander abgrenzen lassen. Wodurch unterscheiden sich erfolgreiche Produkte von weniger erfolgreichen Produkten? Welche weiteren Unterschiede lassen sich zwischen Kunden vom Typ PREISBEWUSSTER MARKENKÄUFER und DISCOUNTARTIKELKÄUFER erkennen?

Unabhängig davon, welche der in diesem Abschnitt beschriebenen Untersuchungssituationen man durchführt, die Analyse ist erst mit der vierten und letzten Phase abgeschlossen: der Lösungstransformation.

6.2.4 Lösungstransformation

Im Gegensatz zu den anderen Phasen besteht die Lösungstransformation aus nur einem Prozessschritt: der Bewertung der Analyseergebnisse (siehe Abbildung 67).

Bei der Bewertung der Analyseergebnisse sind sowohl die gefundenen Datenmuster als auch die daraus zu entwickelnden Kausalhypothesen im Hinblick auf ihre Interessanztheit zu bewerten und auszuwählen (vgl. [HiWi01, S. 82], [NeKn05, S. 188]). Ein Datenmuster ist dann interessant, wenn es verständlich, neuartig, gültig und nützlich ist (siehe Abschnitt 5.1.1). Eine automatisierte Filterung interessanter Ergebnisse ist nur ansatzweise möglich (vgl. [MüHS98, S. 248]). Obwohl sich einige Analysemethoden so parametrisieren lassen, dass ausschließlich Muster mit einer gewissen statistischen Signifikanz berücksichtigt




Abbildung 67: Prozessschritt der Lösungstransformation

werden, bleibt die Ergebnisbewertung dennoch eine Aufgabe, die vom Anwender manuell und unter Berücksichtigung seines domänenspezifischen Wissens durchzuführen ist (vgl. [MüHS98, S. 250], [Küpp99, S. 88], [Resc05, S. 63-64]). Im Folgenden werden die Kriterien erläutert, an denen sich die Interessantheit der Analyseergebnisse bemisst.

Um die *Verständlichkeit* der Analyseergebnisse sicherzustellen, müssen die Datenmuster, die zunächst nur Beziehungen zwischen Merkmalen, Merkmalswerten oder Datenobjekten beschreiben, in Aussagen über reale Ereignisse oder Objekte transformiert werden. Anders als den Datenmustern von Entscheidungsbäumen, Abhängigkeits- oder Sequenzanalysen mangelt es vor allem den Ergebnissen Neuroner Netze an Verständlichkeit. Dies ist dem speziellen Lösungsverfahren Neuroner Netze geschuldet, das einer Black Box gleicht und es dem Anwender nicht erlaubt nachzuvollziehen, warum gerade dieses Analyseergebnis zustande gekommen ist. So erzeugt zum Beispiel eine *Self Organizing Feature Map* (siehe Abschnitt 5.3.1.1) keine Segmentbeschreibung, aus der ersichtlich wird, in welchen Merkmalen und Merkmalswerten sich die Datenobjekte eines Segments ähneln. Um dies zu erfahren, bedarf es weiterer Analysen, etwa einer Abhängigkeitsanalyse.

Sind die Datenmuster in verständliche Aussagen transformiert worden, ist die *Neuheit* der Ergebnisse zu bewerten. Als Maßstab für den Neuigkeitswert gilt der Informationsstand des Informationsempfängers. Als neu sind vor allem solche Datenmuster zu bewerten, die entweder stark von dem erwarteten Analyseergebnis abweichen oder dem bis dato gültigem Domänenwissen widersprechen. Besonders auffällige Datenmuster können aber auch die Gültigkeit der Analyseergebnisse infrage stellen.

Um die *Gültigkeit* der Analyseergebnisse zu bewerten, empfiehlt es sich, die Analysedaten erneut auf Datenmängel zu überprüfen. Gültig sind die Analyseergebnisse nämlich nur, wenn die Analysedaten die Eigenschaften realer Objekte und Ereignisse korrekt wiedergeben. Besonders auffällige Analyseergebnisse lassen sich oft durch fehlende oder fehlerhafte Merkmalswerte erklären. Ob die Merkmale nur zufällig korrelieren, kann in der Regel nur mit einer gezielten Überprüfung der Kausalhypothese beantwortet werden.

Die *Nützlichkeit* der Analyseergebnisse hängt davon ab, ob sich diese unmittelbar für die Entwicklung von Kausalhypothesen eignen oder ob sie deren Entwicklung nur unterstützen. Die Hypothesenentwicklung wird lediglich unterstützt, wenn die Datenmuster entweder auf neue Ereignisse hinweisen (Zielsetzung III) oder Objektbeziehungen differenziert beschreiben (Zielsetzung IV) (siehe Abschnitt 6.2.1). Auf Kausalhypothesen hinweisen können Analyseergebnisse, die entweder Ereignisbeziehungen (Zielsetzung I) oder die ereignistragenden Objektinstanzen anhand ihrer spezifischen Objektmerkmale beschreiben (Zielsetzung II).

Welche Kausalhypothesen sich aus den Analyseergebnissen ableiten lassen, hängt zum einen von den gefundenen Datenmustern, zum anderen vom domänenspezifischen Wissen ab. Zunächst muss entschieden werden, ob die von einer Merkmalskorrelation implizierte Gesetzmäßigkeit ausreicht, um als Hinweis auf einen Kausalzusammenhang gelten zu können. Bewertet man die Gesetzmäßigkeit als ausreichend, kann mit Rückgriff auf das vorhandene Domänenwissen eine Kausalhypothese formuliert werden, die dann in der Lage sein muss, die gefundene Merkmalskorrelation zu erklären. Hierbei ist auch die Frage nach der Kausalrichtung zu beantworten. Um eine bestimmte Kausalrichtung mit Sicherheit auszuschließen, kann zusätzlich die Ereignischronologie betrachtet werden. Hierzu ist es notwendig, dass die Analysedaten auch über die Zeitpunkte der Ereigniseintritte informieren.

Hat man eine oder sogar mehrere alternative Kausalhypothesen aus dem Analyseergebnis abgeleitet, müssen diese in einem zweiten Schritt ebenfalls auf Neuheit, Verständlichkeit, Gültigkeit und Nützlichkeit geprüft werden (siehe Abschnitt 5.1.1). Da sich diese Bewertung weitgehend mit dem Vorgehen bei der modellzentrierten Hypothesenentwicklung deckt, werden an dieser Stelle nur die Unterschiede zwischen beiden Gestaltungsoptionen erläutert (siehe Abschnitt 6.1.4).

Verständlich ist eine Kausalhypothese dann, wenn sich der Zusammenhang zwischen Ursache und Wirkung plausibel erklären lässt. Anders als bei der modellzentrierten Hypothesenentwicklung steht zur Erklärung kein Modell der kausalen Infrastruktur zur Verfügung. Der Kausalzusammenhang lässt sich somit nur auf der Ereignisebene plausibilisieren, etwa indem man ad hoc Zwischenereignisse einfügt, die den kausalen Wirkmechanismus zwischen Ursache und Wirkung erklären.

Aus demselben Grund lässt sich auch die *Neuheit* der Kausalbeziehung nur auf der Ereignisebene bewerten. Neu ist der Kausalzusammenhang, wenn zum

Beispiel das Ursachen- oder das Wirkungsereignis nicht bekannt war oder wenn zwischen beiden Ereignissen bislang keine Kausalbeziehung gesehen wurde.

Die *Gültigkeit* des Kausalzusammenhangs resultiert aus der Gültigkeit der Analyseergebnisse und hängt somit von der Zuverlässigkeit der verwendeten Daten ab. Die Gültigkeit des Kausalzusammenhangs kann insbesondere durch eine nicht repräsentative Stichprobe eingeschränkt sein.

Die Bewertung der *Nützlichkeit* der Kausalhypothese erfolgt ebenfalls anhand der Erklärungskraft und dem Handlungsspielraum, den die Kausalinformation dem Informationsempfänger verschafft. Da die kausale Infrastruktur noch unbekannt ist, muss der Handlungsspielraum der Kausalhypothese allein auf der Ereignisebene bewertet werden. Die zentrale Fragestellung zur Bewertung der Nützlichkeit lautet: Wie lässt sich das Ursachenereignis hervorrufen bzw. verhindern und welche unbeabsichtigten Nebenwirkungen gilt es zu vermeiden?

Die Ergebnisinterpretation - und somit die datenzentrierte Hypothesenentwicklung - endet mit einer Bewertung des Prozessverlaufs. Die in den vier Phasen durchgeführten Prozessschritte sind konsequent auf „methodische Schwachstellen sowie auf Verbesserungs- und Rationalisierungsmöglichkeiten zu überprüfen“ [HiWi01, S. 84]. Alle prozessualen, verfahrenstechnischen, domänenspezifischen wie domänenübergreifenden Erkenntnisse sind nach Möglichkeit so weit zu explizieren und zu dokumentieren, dass man bei zukünftigen Analysen darauf zurückgreifen kann. Dies ist vor allem dann von Bedeutung, wenn im Laufe des Prozesses mehr Fragen aufgeworfen als beantwortet wurden und sich die Anwendung einer anderen Gestaltungsoption anbietet: die modellzentrierte Überprüfung von Kausalhypothesen.

6.3 Modellzentrierte Überprüfung von Kausalhypothesen

Die modellzentrierte Überprüfung einer Kausalhypothese basiert auf derselben Grundüberlegung wie die modellzentrierte Entwicklung: Jeder Kausalzusammenhang benötigt eine spezifische Bedingungskonstellation, damit das Ursachenereignis das Wirkungsereignis hervorrufen kann. Ziel der modellzentrierten Hypothesenprüfung ist es, diese Bedingungskonstellation in Form einer kausalen Infrastruktur nachzuweisen. Die kausale Infrastruktur soll die Objektbeziehungen zwischen dem Ursachen- und dem Wirkungsobjekt aufzeigen, auf denen der Ursache-Wirkungs-Zusammenhang beruht.

Ist es gelungen, die kausale Infrastruktur im Modell zu rekonstruieren, kann der Kausalzusammenhang erst dann als gültig betrachtet werden, wenn auch die

beiden anderen Wesensmerkmale, die Gesetzmäßigkeit und die Chronologie, nachgewiesen sind (siehe Abschnitt 5.1.3.1). Da die Chronologie und Gesetzmäßigkeit eines Kausalzusammenhangs mittels Datenanalyse nachzuweisen ist, eignet sich die modellzentrierte Überprüfung insbesondere im Anschluss an eine datenzentrierte Hypothesenentwicklung. Denn ist eine Kausalhypothese bereits modellzentriert entwickelt worden, erübrigt sich deren modellzentrierte Überprüfung, da die kausale Infrastruktur bereits nachgewiesen ist.

Ebenso wie die bereits vorgestellten Gestaltungsoptionen lässt sich auch die modellzentrierte Überprüfung einer Kausalhypothese als modellgestützte Untersuchungssituation beschreiben. Der Prozess gliedert sich deshalb ebenfalls in die vier Phasen der Zieltransformation, Modellkonstruktion, Verfahrens Anwendung und der Lösungstransformation. Wie sich eine Kausalhypothese modellzentriert überprüfen lässt und welche Prozessschritte in welcher Phase nötig sind, wird in den folgenden Abschnitten erläutert.

6.3.1 Zieltransformation

Das eigentliche Untersuchungsziel, die Gültigkeit einer Kausalhypothese zu überprüfen, wird transformiert in das Modellziel, die kausale Infrastruktur des vermuteten Kausalzusammenhangs offenzulegen. Während man bei der modellzentrierten Hypothesenentwicklung nach Objekttypen sucht, die als potenzielle Ereignisträger infrage kommen, analysiert man nun die Objektbeziehungen zwischen den Ereignisträgern des Ursachen- und Wirkungsereignisses. Die modellzentrierte Überprüfung einer Kausalhypothese ist stets auch eine Überprüfung des kausalen Geltungsbereichs. Denn abhängig davon, ob der Kausalzusammenhang nur für die Objektinstanzen eines Subobjekttyps gültig ist oder ob sich der Zusammenhang auch auf die Objektinstanzen des Superobjekttyps erstreckt, lässt sich der kausale Geltungsbereich im Zuge der Überprüfung entweder einschränken oder erweitern.

Analog zur modellzentrierten Hypothesenentwicklung beginnt auch die Hypothesenprüfung mit der Spezifikation des originären Untersuchungsproblems. Im Gegensatz zur modellzentrierten Entwicklung einer Kausalhypothese markiert nicht mehr ein einzelnes Ausgangsereignis den Ausgangspunkt der Untersuchung, sondern das Ursachen- und das Wirkungsereignis. Die Frage nach der Suchrichtung - ob man Ursachen- oder Wirkungsforschung betreiben möchte - stellt sich an dieser Stelle nicht mehr. Der *erste Prozessschritt* beginnt mit Spezifikation des originären Untersuchungsproblems. Hierzu beschreibt man die zu

überprüfende Kausalhypothese und das Problem, zu dessen Lösung die Kausalinformation beitragen soll.




Abbildung 68: Prozessschritte der Zieltransformation

Im zweiten Prozessschritt wird das Untersuchungsziel in ein Modellziel transformiert. Dies geschieht analog zur modellzentrierten Hypothesenentwicklung: Zunächst sind Ursachen- und Wirkungsereignis als Ereignistyp zu spezifizieren und gemäß der in Abschnitt 5.2.1.2 vorgestellten Ereignisarten zu charakterisieren. Beide Ereignistypen sind anschließend einem ereignistragenden Objekttypen als Ereignisträger zuzuordnen (siehe Abschnitt 7.2.3.1). Sind die Ereignisträger des Ursachen- und Wirkungsereignisses spezifiziert, muss zuletzt der Objektbereich der Untersuchung festgelegt werden. Bei der modellzentrierten Hypothesenprüfung gehört hierzu der Bereich, den die Kausalhypothese auf der Ereignissebene überspannt und den auf der Objektebene auch die kausale Infrastruktur überbrücken muss. Obwohl der Objektbereich von den beiden ereignistragenden Objekttypen begrenzt wird, sollte dennoch ein aggregierter Objekttyp angegeben werden, der die beiden Ereignisträger als Teilobjekttypen enthält und den Objektbereich der Untersuchung eindeutig begrenzt.

6.3.2 Modellkonstruktion

Ebenso wie bei der modellzentrierten Hypothesenentwicklung ist auch in dieser Phase ein Modellsystem zu konstruieren, das sämtliche Objekttypen und Beziehungen des Objektbereichs erfasst, aus denen sich die kausale Infrastruktur des Kausalzusammenhangs zusammensetzen kann. Dies geschieht in zwei Prozessschritten, die Abbildung 69 skizziert:

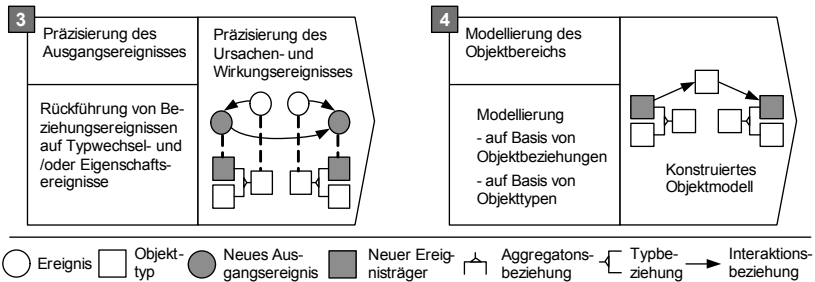


Abbildung 69: Prozessschritte der Modellkonstruktion

1. *Präzisierung der Ausgangsereignisse:* Handelt es sich bei dem Ursachen- und Wirkungsereignis um ein Aggregations- oder Interaktionsereignis, sollte man versuchen, dieses durch Typwechsel- oder Eigenschaftsereignisse zu ersetzen (siehe Abbildung 55).
2. *Modellierung des Objektbereichs:* Ausgehend von den ereignistragenden Objekttypen des präzierten Ursachen- und Wirkungsereignisses kann der Objektbereich entweder auf Basis von Objektbeziehungen (siehe Abbildung 56) oder auf Basis von Objekttypen erschlossen werden. Darüber hinaus können auch Zwischenereignisse formuliert und zur Identifikation von Objekttypen verwendet werden.

Da beide Prozessschritte bereits im Rahmen der modellzentrierten Hypothesenentwicklung vorgestellt wurden, wird an dieser Stelle auf eine erneute Beschreibung verzichtet (siehe Abschnitt 6.1.2). Im Folgenden wird daher nur auf die Unterschiede zur Modellkonstruktion der Hypothesenentwicklung eingegangen.

Im Gegensatz zur ersten Gestaltungsoption liegt ein vollständiger Kausalzusammenhang vor. Daher lässt sich möglicherweise sowohl das Ursachen- als auch das Wirkungsereignis präzisieren. Soll das Modellsystem auf Basis von *Objektbeziehungen* konstruiert werden, dann stehen als Ausgangspunkt für die Modellkonstruktion zwei Ereignisträger zur Verfügung: Anders als bei der modellzentrierten Hypothesenentwicklung lässt sich der Objektbereich sowohl vom Ursachen- als auch vom Wirkungsobjekttyp aus erschließen. Die Konstruktion des Objektmodells ähnelt daher dem Bau eines U-Bahn-Tunnels, der ebenfalls von zwei Stationen aus gleichzeitig begonnen werden kann. Es entstehen zunächst zwei voneinander getrennte Teilmodellsysteme, die sich aber zu einem

gemeinsamen Modellsystem verbinden müssen. Konstruiert man das Modellsystem auf Basis von *Objekttypen*, so ermittelt man zuerst die Objekttypen des Objektbereichs, bevor anschließend die Objektbeziehungen ergänzt werden.

Eine dritte Möglichkeit, mit der sich Objekttypen im Objektbereich identifizieren lassen, ist die *Formulierung von Zwischenereignissen*. Hierzu fügt man in den Kausalzusammenhang ein Zwischenereignis ein, das zusammen mit dem Ursachen- und Wirkungsereignis eine aus zwei Einzelhypothesen zusammengesetzte Kausalkette bildet. Die Distanz zwischen Ursache und Wirkung wird somit nicht mehr von einer, sondern von mehreren, miteinander verketteten Kausalhypothesen überbrückt. Dieselbe Distanz ist im Anschluss auch auf der Objektebene zu überbrücken. Um die Objekttypen der kausalen Infrastruktur zu identifizieren, kann nun jedem Zwischenereignis der Kausalkette ein eigener Objekttyp als Ereignisträger zugeordnet werden. Auch hier empfiehlt es sich, Interaktions- oder Aggregationsereignisse durch Typwechsel- oder Eigenschaftsereignisse zu ersetzen. Im Anschluss sind die Ereignisträger der Zwischenereignisse über Objektbeziehungen mit den Ereignisträgern des Ursachen- und des Wirkungsereignisses zu verbinden.

Im Gegensatz zur Formulierung von Zwischenereignissen zeichnet sich die Modellkonstruktion auf Basis von Objektbeziehungen und Objekttypen dadurch aus, dass man sich gedanklich von der Ereignisebene löst und sich ausschließlich auf die Objektebene konzentriert. Wird das Modellsystem über den Umweg von Zwischenereignissen erschlossen, besteht jedoch die Gefahr, dass man nur solche Objekttypen und Beziehungen modelliert, von denen man bereits im Vorfeld der Untersuchung annimmt, dass sie Teil der kausalen Infrastruktur sind. Welche Objekte und Objektbeziehungen an einem Kausalzusammenhang beteiligt sind, soll jedoch erst in der darauf folgenden Phase der Verfahrensanwendung entschieden werden. Würde man sich bei der Modellkonstruktion zu sehr auf einen Ausschnitt des Objektbereichs konzentrieren, würden dem Modellsystem möglicherweise wichtige Objekttypen und Beziehungen fehlen. Aus diesem Grund sollte die Formulierung von Zwischenereignissen nur als Ergänzung der anderen beiden Verfahren genutzt werden; etwa dann, wenn es nicht gelungen ist, den Ursachen- und den Wirkungsobjekttyp über eine oder mehrere Objektbeziehungen zu verknüpfen.

6.3.3 Verfahrensanwendung

Ziel der Verfahrensanwendung ist es, im Objektmodell die kausale Infrastruktur des Kausalzusammenhangs zu bestimmen und diese gegebenenfalls so zu präzisieren, dass sich der kausale Wirkmechanismus erklären und nachvollziehen lässt. Dies erfolgt in zwei Prozessschritten:

1. *Bestimmung der kausalen Infrastruktur:* Aus dem Objektmodell werden die Objekttypen und Beziehungen ausgewählt, die die beiden Ereignisträger des Ursachen- und Wirkungseignisses verknüpfen und dem Kausalzusammenhang als kausale Infrastruktur dienen könnten.
2. *Plausibilisierung der Kausalhypothese:* Um den Wirkungsmechanismus des Kausalzusammenhangs zu plausibilisieren, können auf der Objektebene Infrastrukturbeziehungen hinzugefügt oder präzisiert sowie der kausale Geltungsbereich angepasst werden (siehe Abschnitt 6.1.3).

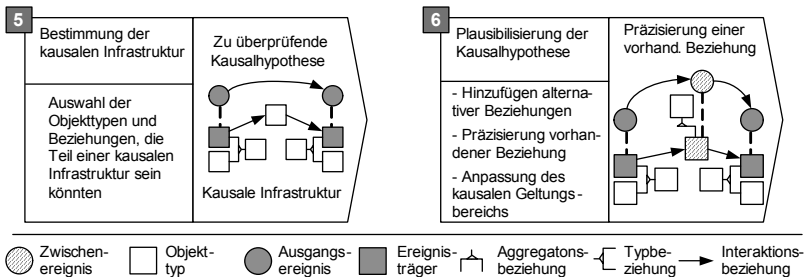


Abbildung 70: Prozessschritte der Verfahrensanwendung

Beim *ersten Prozessschritt* bestimmt man die kausale Infrastruktur, indem man prüft, ob und über welche Objektbeziehungen der Ursachen- mit dem Wirkungsobjekttyp verbunden ist. Sind die Ereignisträger weder direkt noch transitiv verbunden, kann die Bedingtheit des Kausalzusammenhangs nicht nachgewiesen werden. Dies muss nicht zwangsläufig bedeuten, dass die Kausalhypothese ungültig ist. Der Kausalzusammenhang kann trotzdem gültig sein, weil er möglicherweise auf Objektbeziehungen beruht, die außerhalb des abgegrenzten Objektbereichs verlaufen, oder weil das verwendete Objektvokabular lückenhaft war. Hat man diese Vermutung, kann man in die Phase der Modellkonstruktion zurückkehren, um die Lücken im Objektvokabular zu schließen und das Objektmodell zu erweitern.

Sind der Ursachen- und der Wirkungsobjekttyp über eine oder mehrere Objektbeziehungen verbunden, folgt im *zweiten Prozessschritt* die Plausibilisierung des Kausalzusammenhangs. Für jede der identifizierten Verbindungen ist zu prüfen, ob sie als kausale Infrastruktur den Kausalzusammenhang hinreichend erklären und stützen kann. Gegebenenfalls sind einzelne Infrastrukturbeziehungen hinzuzufügen oder zu präzisieren, damit sich der Wirkmechanismus auf der Objektebene plausibel nachvollziehen lässt. Hierfür bieten sich dieselben Möglichkeiten wie bei der modellzentrierten Hypothesenentwicklung (siehe Abschnitt 6.1.3):

- Hinzufügen einer alternativen Infrastrukturbeziehung
- Präzisierung einer bereits vorhandenen Infrastrukturbeziehung
- Einschränkung oder Erweiterung des kausalen Geltungsbereichs

Eine Präzisierung der kausalen Infrastruktur ist vor allem dann nötig, wenn die Verbindungen zwischen dem Ursachen- und dem Wirkungsobjekttyp auf einem sehr hohen Abstraktionsniveau beschrieben sind. Um das Abstraktionsniveau zu senken, kann man die an dem Kausalzusammenhang beteiligten Objekttypen disaggregieren oder durch spezialisierte Objekttypen ersetzen. Auf diese Weise erweitert sich die kausale Infrastruktur um neue Teil- und Subobjekttypen, die dann auf ihrer jeweiligen Typ- und Aggregationsebene über neue Objektbeziehungen verknüpft werden können.

6.3.4 Lösungstransformation

Ebenso wie die modellzentrierte Hypothesenentwicklung schließt auch die Hypothesenprüfung mit einer Ergebnisbewertung. Da das Ziel nicht die Entwicklung, sondern die Überprüfung einer Kausalhypothese ist, müssen lediglich die kausalen Infrastrukturbeziehungen auf Verständlichkeit, Neuheit, Gültigkeit und Nützlichkeit geprüft werden (siehe Abbildung 71).




Abbildung 71: Prozessschritt der Lösungstransformation

Hinsichtlich der vier Bewertungskriterien sind daher folgende Fragen zu beantworten:

- *Verständlichkeit*: Kann der Informationsempfänger den kausalen Wirkmechanismus auf der Objektebene nachvollziehen?
- *Neuheit*: Welche der Infrastrukturbeziehungen sind dem Informationsempfänger unbekannt? Wo erweitert sich sein Objektvokabular und - falls neue Zwischenereignisse eingefügt wurden - sein Ereignisvokabular?
- *Gültigkeit*: Deckt sich die kausale Infrastruktur mit den realen Gegebenheiten der originären Untersuchungssituation? Stehen die realen Objekte tatsächlich in den modellierten Infrastrukturbeziehungen?
- *Nützlichkeit*: Welche kausale Infrastruktur besitzt die größte Erklärungskraft? Welche Möglichkeiten bieten sich dem Informationsempfänger entlang der kausalen Infrastruktur, den Kausalzusammenhang zu verhindern oder zu etablieren bzw. zu verstärken?

Analog zur modellzentrierten Hypothesenentwicklung bemisst sich die Verständlichkeit und Neuheit der kausalen Infrastruktur am Informationsstand des Informationsempfängers. Ob die Kausalinformation nützlich ist, hängt vom Verwendungszweck und dem Anwendungskontext ab (siehe Abschnitt 5.1.2). Ein Kausalzusammenhang kann etabliert werden, indem man die benötigten Infrastrukturbeziehungen aufbaut. Umgekehrt lässt sich ein Kausalzusammenhang verhindern, falls es gelingt, die bestehenden Infrastrukturbeziehungen zu kappen. Kann eine kausale Infrastruktur nicht alle vier Kriterien erfüllen, distanziert man sich entweder von der überprüften Kausalhypothese oder man kehrt in die Phase der Modellkonstruktion zurück, um den Kausalzusammenhang zu plausibilisieren, etwa indem man die kausale Infrastruktur modifiziert bzw. den kausalen Geltungsbereich einschränkt.

6.4 Datenzentrierte Überprüfung von Kausalhypothesen

Die vierte und letzte Gestaltungsoption ist die datenzentrierte Überprüfung von Kausalhypothesen. Gesucht wird ein aussagekräftiges Datenmuster, das auf die Gültigkeit einer bereits bekannten Kausalhypothese hinweist. Anders als bei der modellzentrierten Überprüfung soll nicht die Bedingtheit, sondern die Gesetzmäßigkeit und die Chronologie eines Kausalzusammenhangs nachgewiesen werden. Da sich die gesuchten Datenmuster bereits im Vorfeld der Analyse genau spezifi-

zieren lassen, ist eine ungerichtete und ergebnisoffene Suche nach Datenmustern nicht mehr zweckmäßig: Anstatt eines datengetriebenen Analyseverfahrens benötigt man für die Überprüfung einer Kausalhypothese ein hypothesengetriebenes Analyseverfahren (siehe Abschnitt 5.3).

Hat man schließlich ein aussagekräftiges Datenmuster als Beleg für die Chronologie und die Gesetzmäßigkeit des Kausalzusammenhangs gefunden, kann dieser erst dann als gültig betrachtet werden, wenn auch Evidenzen für das dritte Wesensmerkmal, die Bedingtheit, vorliegen. Aus diesem Grund empfiehlt sich die datenzentrierte Überprüfung speziell für solche Kausalhypothesen, die modellzentriert entwickelt wurden.

Im Gegensatz zum Prozess der datenzentrierten Hypothesenentwicklung fehlt der datenzentrierten Hypothesenprüfung eine vergleichbare, allgemein anerkannte Prozessvorlage, wie sie für das Data-Mining in Form des KDD-Prozessmodells vorliegt (siehe Abschnitt 6.2). Knobloch weist jedoch darauf hin, dass auch die hypothesengetriebene Datenanalyse von den Schritten des KDD-Prozessmodells profitieren kann:

„Nach dem Aufstellen zu überprüfender Hypothesen müssen Datenbestände ermittelt und beschafft werden, anhand derer die Verifikation der getroffenen Annahmen erfolgen kann. Diese Daten sind anschließend für die Analyse vorzubereiten, bevor die eigentliche Untersuchung durchgeführt werden kann. Ergebnisse sind zu bewerten und im Kontext der Fragestellung zu interpretieren.“ [Knob00, S. 26]

Dennoch ist an dieser Stelle auf einen wichtigen Unterschied zwischen der daten- und hypothesengetriebenen Analyse hinzuweisen: Während die Komplexität der datengetriebenen Analyse der Komplexität der Data-Mining-Verfahren geschuldet ist, stellt die Anwendung der OLAP-Operatoren keine Herausforderung mehr dar. Im Gegenteil: Moderne OLAP-Systeme zeichnen sich gerade dadurch aus, dass sie dem Nutzer eine bequeme ad hoc Analyse ermöglichen (siehe Abschnitt 5.3.2.1). Die Komplexität der OLAP-Analyse erwächst nicht aus der Verfahrensanwendung, sondern vielmehr aus der Komplexität des zugrunde liegenden Modellsystems und seiner Konstruktion. Der multidimensionale Datenraum eines Data-Warehouse ist wesentlich aufwändiger zu konstruieren als eine zweidimensionale Datentabelle für Data-Mining-Verfahren. Auf diesen Umstand dürfte es zurückzuführen sein, dass sich für die OLAP-Analyse vor allem für die Phase der Modellkonstruktion ein standardisiertes Vorgehen herausgebildet hat, und zwar der ETL-Prozess, der die Extraktion, Transformation und das Laden der Daten in das Data-Warehouse beschreibt (siehe Abschnitt 5.3.2.2).

In den folgenden vier Abschnitten werden deshalb die Phasen der Zieltransformation, Verfahrensanwendung und Lösungstransformation in Anlehnung an das KDD-Prozessmodell gegliedert, während die Phase der Modellkonstruktion weitgehend den Prozessschritten des ETL-Prozesses folgt.

6.4.1 Zieltransformation

Gemeinsamer Ausgangspunkt der modell- und datenzentrierten Hypothesenprüfung ist die zu überprüfende Kausalhypothese. Im Gegensatz zum modellzentrierten Vorgehen, bei dem man den Kausalzusammenhang aus Typsicht analysiert, nutzt man im Folgenden eine instanzbezogene Kausalarchitektur: Anstatt mit der kausalen Infrastruktur zu zeigen, unter welchen Bedingungen ein kausaler Ereigniszusammenhang möglich ist, analysiert man bei der datenzentrierten Überprüfung die Gesetzmäßigkeit und Chronologie von bereits eingetretenen Ereignissen. Ebenso wie bei der datenzentrierten Hypothesenentwicklung sind für die Zieltransformation zwei Prozessschritte nötig: die Spezifikation des originären Untersuchungsproblems sowie die Transformation des Untersuchungsziels in ein Modellziel (siehe Abbildung 72).

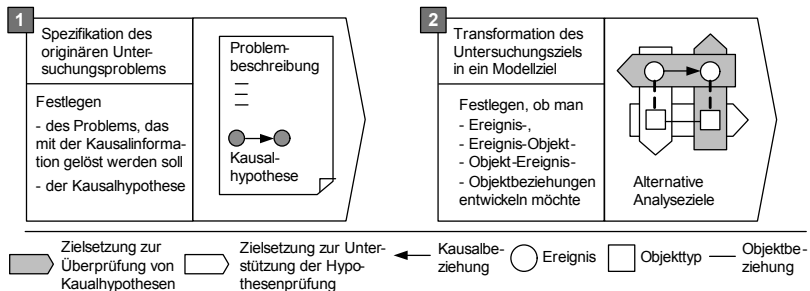


Abbildung 72: Prozessschritte der Zieltransformation

Analog zu den anderen Gestaltungsoptionen ist im *ersten Prozessschritt* zunächst das originäre Untersuchungsproblem zu spezifizieren, das mithilfe der Kausalhypothese gelöst werden soll (siehe Abschnitt 6.1.1). Da sich die Gesetzmäßigkeit des Kausalzusammenhangs nur dann überprüfen lässt, wenn der kausale Geltungsbereich der Hypothese spezifiziert ist, müssen auf der Objektebene die als Ereignisträger infrage kommenden Objektinstanzen abgegrenzt werden. Da jede Kausalhypothese nicht nur ein Ursachen- mit einem Wirkungseignis verknüpft,

sondern auch stets eine Aussage über die Ereignisträger trifft, lassen sich diese zu einem Ursachen- bzw. Wirkungsobjekttyp zusammenfassen. Bei der Überprüfung einer Kausalhypothese kann dann gezielt untersucht werden, inwieweit die Objektinstanzen dieser Objekttypen tatsächlich von Ursachen- oder Wirkungsereignissen betroffen waren. Denn würde sich herausstellen, dass nur eine bestimmte Teilmenge der infrage kommenden Objektinstanzen von einem Ursachen- oder Wirkungsereignis betroffen ist, kann dies auf einen zu weit gefassten kausalen Geltungsbereich hindeuten. Dieser müsste dann im Zuge der datenzentrierten Hypothesenprüfung eingeschränkt werden.

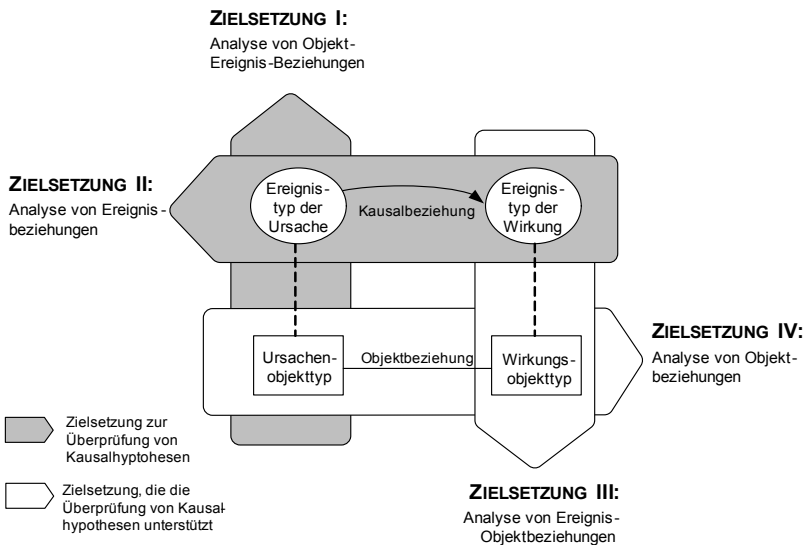


Abbildung 73: Generische Zielsetzungen der datenzentrierten Überprüfung einer Kausalhypothese

Das Modellsystem der Hypothesenprüfung setzt sich aus Ereignis- und Objektdaten zusammen. Das bedeutet, dass sich mit einer OLAP-Analyse nicht nur die Beziehungen zwischen Ereignis- *oder* Objekttypen, sondern auch zwischen Ereignis- *und* Objekttypen überprüfen lassen. Es können daher dieselben vier generischen Zielsetzungen wie bei der datenzentrierten Hypothesenentwicklung unterschieden werden (siehe Abbildung 73).

Der zweite Prozessschritt besteht darin, dass man das originäre Untersuchungsziel in ein Modellziel transformiert. Obwohl jede der vier Zielsetzungen als Modellziel einer OLAP-Analyse infrage kommt, sind nur die beiden ersten

Zielsetzungen unmittelbar für die Überprüfung einer Kausalhypothese relevant. Die beiden anderen Zielsetzungen unterstützen die datenzentrierte Überprüfung nur oder sind erst im Zusammenhang mit anderen Gestaltungsoptionen von Bedeutung. Doch im Gegensatz zur datenzentrierten Hypothesenentwicklung, bei der man sich zwischen zwei alternativen Zielsetzungen entscheiden konnte, besteht bei der Überprüfung einer Kausalhypothese keine Wahlmöglichkeit mehr: Um die Gültigkeit einer Kausalhypothese zu überprüfen, müssen sowohl Objekt-Ereignis-Beziehungen (Zielsetzung I) als auch Ereignisbeziehungen (Zielsetzung II) überprüft werden. Die vier Zielsetzungen werden im Folgenden kurz erläutert.

Zunächst ist mit einer Analyse der *Objekt-Ereignis-Beziehungen* (Zielsetzung I) zu prüfen, wie oft sich einzelne Ursachen- und Wirkungsergebnisse für diejenigen Objektinstanzen ereignet haben, die laut Kausalhypothese Ereignisträger sein sollen. Zweck dieser Analyse ist es zu untersuchen, ob überhaupt die Voraussetzung für eine datenzentrierte Hypothesenprüfung gegeben ist. Denn würde man feststellen, dass in den Daten weder der Eintritt eines Ursachen- noch eines Wirkungsergebnisses verzeichnet ist, kann auch die Gültigkeit der Kausalhypothese nicht überprüft werden (vgl. [BaGr04, S. 170]). Gesetzmäßigkeit und Chronologie eines Kausalzusammenhangs können nur bei einer nicht leeren Ereignismenge untersucht werden. Stellt man fest, dass Ursachen- und Wirkungsergebnisse eingetreten sind, vermittelt die Häufigkeit der Ereignisseintritte einen ersten Eindruck über die Relevanz des Kausalzusammenhangs. Doch erst in der Phase der Lösungstransformation ist darüber zu entscheiden, was es bedeutet, wenn sich die Ursachen- oder Wirkungsergebnisse nur selten und unregelmäßig ereignen. Um die Gesetzmäßigkeit und Chronologie des Kausalzusammenhangs zu überprüfen, sind als Nächstes die Beziehungen zwischen den identifizierten Ereignissen zu analysieren.

Mit der Analyse der *Ereignisbeziehungen* (Zielsetzung II) prüft man, ob nach einem Ursachenereignis das erwartete Wirkungsergebnis eingetreten ist, also ob sich jeder Instanz vom Ereignistyp Wirkung eine Instanz vom Ereignistyp Ursache zuordnen lässt. In diesem Zusammenhang ist für jedes identifizierte Ereignispaar auch die Chronologie der Ereignisse zu untersuchen. Dabei ist zu prüfen, ob sich jedes Ursachenereignis vor seinem komplementären Wirkungsergebnis ereignet hat und ob auch die Zeitdauer zwischen beiden Ereignissen nicht gegen die Gültigkeit des Kausalzusammenhangs spricht. Letzteres wäre der Fall, wenn sich das Wirkungsergebnis entweder zu spät oder zu früh ereignet hat, um vom Ursachenereignis hervorgerufen worden zu sein.

Nach der Analyse der Ereignisbeziehungen ist die datenzentrierte Überprüfung der Kausalhypothese abgeschlossen. Die Zielsetzungen III und IV gehen über den eigentlichen Zweck der Hypothesenprüfung hinaus, da sie entweder nur in Kombination mit anderen Gestaltungsoptionen oder erst nach einer fehlgeschlagenen Hypothesenprüfung verfolgt werden. Dies wäre der Fall, wenn man beispielsweise Ursachenereignisse ohne ein komplementäres Wirkungereignis identifiziert hätte. Da „wirkungslose“ Ursachenereignisse der Kausalhypothese widersprechen, deutet ein solches Ergebnis darauf hin, dass der kausale Geltungsbereich zu weit gefasst ist. Dieser lässt sich mit einer *Analyse der Ereignis-Objekt-Beziehungen* einschränken (Zielsetzung III). Hierbei müssen diejenigen Objektinstanzen, die Träger eines „wirkungslosen“ Ursachenereignisses sind, von den Objektinstanzen abgegrenzt werden, deren Ursachenereignissen komplementäre Wirkungereignisse zugeordnet werden konnten. Verfügt man bereits über eine Hypothese über die Merkmale, anhand derer sich beide Arten von Objektinstanzen unterscheiden, kann dies mit einer OLAP-Analyse überprüft und im Anschluss gegebenenfalls der kausale Geltungsbereich eingeschränkt werden. Hierzu ergänzt man die Typmerkmale des Ursachen- oder Wirkungsobjekttyps um genau die Merkmale und Merkmalswerte, anhand derer sich die ereignistragenden Objektinstanzen unterscheiden. Verfügt man allerdings über keine Hypothese, lässt sich eine solche auch im Rahmen der datenzentrierten Hypothesenentwicklung generieren (siehe Abschnitt 6.2).

Im Fokus der letzten Zielsetzung steht die *Analyse von Objektbeziehungen* (Zielsetzung IV). Hier überprüft man keine Kausal-, sondern Strukturhypothesen, die die strukturellen Beziehungen zwischen den Objektinstanzen der Objekttypen beschreiben (siehe Abschnitt 6.2.1). Da die Bedingtheit eines Kausalzusammenhangs auf den kausalen Infrastrukturbeziehungen der Objektebene beruht, lässt sich die Bedingtheit auch dadurch überprüfen, indem man diese Objektbeziehungen nachweist. Eine solche Analyse setzt jedoch voraus, dass die Bedingungskonstellation eines Kausalzusammenhangs bereits auf modellzentriertem Wege nachgewiesen wurde. Welche Synergien sich aus der Kombination von modell- und datenzentrierten Gestaltungsoptionen ergeben, wird in Abschnitt 6.5 erläutert.

Vor der eigentlichen OLAP-Analyse ist zunächst der multidimensionale Datenraum zu konstruieren. Dies geschieht in der zweiten Prozessphase, der Modellkonstruktion.

6.4.2 Modellkonstruktion

Obwohl die beiden datenzentrierten Gestaltungsoptionen eine instanzbezogene Kausalarchitektur als Modellsystem nutzen, unterscheiden sie sich in ihrer Modellkonstruktion in folgendem Punkt: Im Gegensatz zum Modellsystem für die Data-Mining-Analyse, deren Daten speziell für die zu beantwortende analytische Fragestellung ausgewählt und aufbereitet werden, greift man bei der OLAP-Analyse auf den gesamten Datenbestand eines Data-Warehouse zu, der erst im weiteren Verlauf der Analyse sukzessive eingeschränkt wird. Das Besondere eines Data-Warehouse ist, dass sich die darin enthaltenen Daten nicht nur zur Beantwortung einer, sondern unterschiedlicher Fragestellungen eines Themenbereichs eignen sollen (siehe Abschnitt 5.3.2.2). Das bedeutet für den Entwurf und Aufbau eines Data-Warehouse, dass man nicht nur ein, sondern mehrere Analyseziele im Blick behalten muss.

Ein weiterer Unterschied zwischen der Modellkonstruktion der Data-Mining- und OLAP-Analyse besteht darin, dass für Letztere keine denormalisierte Datentabelle, sondern ein multidimensionaler Datenraum aufzubauen ist. Da dies mit ungleich mehr Aufwand verbunden ist, beginnt die Modellkonstruktion für die OLAP-Analyse nicht mit der Auswahl und Aufbereitung der Daten, wie es beim Data-Mining der Fall ist (siehe Abschnitt 6.2.2), sondern mit einer Entwurfsphase, in der zunächst das Datenmodell des multidimensionalen Datenraums konzipiert wird (vgl. [Böhn01, S. 304]). Mit dem eigentlichen Aufbau der Datenbasis kann erst dann begonnen werden, wenn klar ist, welche multidimensionale Datenstruktur mit welchen Daten zu befüllen ist.

Die Phase der Modellkonstruktion gliedert sich deshalb in zwei Prozessschritte: den Entwurf und den Aufbau des Data-Warehouses (siehe Abbildung 74). Während sich der Entwurf aus einem konzeptionellen, einem logischen und einem physischen Entwurf zusammensetzt, folgt der Aufbau des Data-Warehouses den Schritten des ETL-Prozesses.




Abbildung 74: Prozessschritte der Modellkonstruktion

Ziel des konzeptionellen Entwurfs ist es, die fachlichen Anforderungen an das Data-Warehouse in einem semantischen Data-Warehouse-Schema festzuhalten. Dieses Schema informiert zum einen über die vom Data-Warehouse bereitzustellenden Kennzahlen, zum anderen über die Dimensionen, aus denen man die Kennzahlen betrachten möchte. Für diesen Fachentwurf können die Kennzahlen und Dimensionen entweder aus den operativen Quellsystemen oder aus dem subjektiven Informationsbedarf der zukünftigen Data-Warehouse-Nutzer abgeleitet werden. Darüber hinaus lassen sich auch Geschäftsprozessmodelle als Ausgangspunkt für den Fachentwurf nutzen. Böhnlein hält diese dritte Möglichkeit für den geeignetsten Weg, da Geschäftsprozessmodelle bereits „implizit eine formale Beschreibung des Informationsbedarfs eines Unternehmens enthalten“ [Böhn01, S. 307].

Sind die Kennzahlen und Dimensionen des Data-Warehouses definiert, folgt der *logische Entwurf* des Data-Warehouse-Schemas. Während man beim konzeptionellen Entwurf noch keine Rücksicht auf das spätere Datenbankmodell des Data-Warehouses nehmen musste, hängt der logische Entwurf davon ab, ob das Data-Warehouse mit einem relationalen oder einem multidimensionalen Datenbanksystem realisiert werden soll. Während multidimensionale Datenbanksysteme meist auf den proprietären Datenbankmodellen der verschiedenen Anbieter basieren ([Böhn01, S. 83]), lässt sich mit dem Datenschema eines relationalen Datenbanksystems auf zwei Arten ein multidimensionaler Datenraum auf Basis des Relationenmodells¹ realisieren: mit einem Star- oder Snowflake-Schema (vgl. [Lehn03, S. 85-90]).

Der erste Prozessschritt schließt mit dem *physischen Entwurf*. Ausgehend vom logischen Data-Warehouse-Schema ist ein physisches Schema zu erarbeiten, das schließlich mit dem ausgewählten Datenbanksystem umgesetzt werden muss. Liegt beispielsweise ein relationales Datenschema in Form eines Star- oder

¹ Zum Relationenmodell siehe [Codd70].

Snowflake-Schemas vor, müssen nun die Tabellen, Attribute und Primärschlüsselvererbungen mithilfe der Structured Query Language (SQL) angelegt werden (vgl. [Böhn01, S. 374]). Darüber hinaus ist die Soft- und Hardware des Data-Warehouse-Systems zu konfigurieren, um den Datenzugriff zu beschleunigen. Hierzu können beispielsweise Indexstrukturen angelegt oder Aggregations- und Fragmentierungsstrategien implementiert werden. Während eine Aggregationsstrategie darauf beruht, aggregierte Kennzahlenwerte in eigenen Tabellen auf Vorrat zu halten, um so den Rechenaufwand zur Kennzahlenaggregation zu minimieren, basieren Fragmentierungsstrategien auf der spalten- oder zeilenweisen Aufteilung einer umfangreichen Datentabelle auf unterschiedliche Datenbank- oder Hardwaresysteme (vgl. [Böhn01, S. 252]).

Sind die Data-Warehouse-Strukturen entworfen und im Datenbanksystem angelegt, kann im zweiten Prozessschritt mit dem Aufbau der Datenbasis begonnen werden. Anders als beim *Knowledge Discovery in Databases* werden die Schritte der Aufbauphase nicht mehr als Selektion, Exploration und Manipulation bezeichnet (siehe Abschnitt 6.2.2), sondern im so genannten ETL-Prozess zusammengefasst. Dieser unterteilt sich in drei Einzelschritte: die Extraktion, die Transformation und das Laden der Daten in das Data-Warehouse.

Bei der Durchführung des ETL-Prozesses unterscheidet man zwischen dem initialen Aufbau der Datenbasis und deren wiederholter Aktualisierung. Beim initialen Aufbau der Datenbasis sind bei der *Extraktion* zunächst die operativen Quellsysteme zu bestimmen, deren Datenbestände die vom Data-Warehouse-Schema vorgegebenen Daten enthalten. Die benötigten Daten werden dann in einen temporären Zwischenspeicher, die so genannte Staging Area, geladen, wo sie im Anschluss transformiert werden können.

Ziel der *Transformation* ist es, Datenmängel zu beseitigen und eine fehlerfreie, integrierte Datenbasis zu bilden. Die Transformation der Daten beginnt mit einer Schemaintegration, bei der die Datenobjekttypen und Attribute der Quellschemata mit denen des Data-Warehouse-Schemas abzugleichen sind. Aufgrund der Heterogenität der verschiedenen Quellsysteme werden zwischen den Schemata in der Regel sowohl syntaktische als auch semantische Inkonsistenzen auftreten. Hierzu zählen neben Synonymen und Homonymen auch Unterschiede bei der Attributbezeichnung oder den verwendeten Datentypen (vgl. [Böhn01, S. 50]). Neben den Konflikten auf der Schemaebene muss auch auf der Ebene der Merkmalsausprägungen die Datenqualität sichergestellt werden. Beim Aufbau eines Data-Warehouse ist man mit denselben Datenqualitätsproblemen konfrontiert, die auch im Vorfeld einer Data-Mining-Analyse zu beheben sind (siehe

Abbildung 65, Seite 186). Dies schließt die Behandlung fehlender oder fehlerhafter Datensätze ebenso ein wie die Vermeidung von Redundanzen, die bei einer Zusammenführung der Daten aus verschiedenen Quellsystemen entstehen können (vgl. [Böhn01, S. 50]).

Sind die Daten der operativen Quellsysteme bereinigt und zusammengeführt, folgt als letzter ETL-Schritt das *Laden* der Daten in das Data-Warehouse. Bei der Übertragung der Daten von der Staging Area in das Data-Warehouse müssen die im physischen Entwurf erarbeiteten Strategien zur Indizierung, Aggregation und Fragmentierung berücksichtigt und umgesetzt werden (vgl. [Böhn01, S. 57]). Zum Zweck der Historisierung sind die Daten beim Ladevorgang mit einem Zeitstempel zu versehen.

Damit das Data-Warehouse auch in Zukunft aktuelle Daten enthält, muss der ETL-Prozess wiederholt durchgeführt werden. Dies geschieht parallel zur Nutzung des Data-Warehouses (vgl. [Böhn01, S. 304]). Für die Nutzungsphase muss eine Aktualisierungsstrategie erarbeitet werden, die festlegt, zu welchen Zeitpunkten die Daten erneut zu extrahieren und in das Data-Warehouse zu laden sind. Über die routinemäßige Aktualisierung des Datenbestands hinaus müssen die Data-Warehouse-Strukturen aber auch außerplanmäßig angepasst werden, etwa, wenn sich der Informationsbedarf der Nutzer wandelt oder sich die Datenschemata der operativen Quellsysteme geändert haben (vgl. [Böhn01, S. 304]). In einem solchen Fall müssen beide Prozessschritte zum Entwurf und Aufbau des Data-Warehouses erneut durchlaufen werden.

6.4.3 Verfahrensanwendung

Im Rahmen der Verfahrensanwendung ist ein Untersuchungsverfahren auszuwählen und anzuwenden, mit dem sich das Untersuchungsproblem lösen lässt. Da ein Untersuchungsproblem aus einem Untersuchungsobjekt und einem Untersuchungsziel besteht, muss das Verfahren sowohl im Hinblick auf die gewählte Zielsetzung als auch auf das konstruierte Modellsystem festgelegt werden. Jedes Tripel aus Zielsetzung, Analyseverfahren und Analysedaten bildet somit eine eigene, modellgestützte Untersuchungssituation (siehe Abschnitt 6.2.3). Obwohl der datenzentrierten Hypothesenprüfung und -entwicklung dieselben generischen Zielsetzungen zugrunde liegen, unterscheiden sich ihre Untersuchungssituationen hinsichtlich des Modellsystems und der Analyseverfahren.

Hinsichtlich des *Analyseverfahrens* besteht der Unterschied zur Data-Mining-Analyse darin, dass die OLAP-Analyse keine algorithmischen Analyseverfahren nutzt. Bei der OLAP-Analyse handelt sich um ein manuelles Datenzugriffsverfahren, das als Besonderheit die flexible Navigation in einem multidimensionalen Datenraum ermöglicht. An die Stelle der Data-Mining-Algorithmen treten deshalb die OLAP-Operatoren, mit denen sich die Dimensionen, Hierarchiestufen und Dimensionselemente festlegen lassen (siehe Abschnitt 5.3.2.1). Doch anders als beim Data-Mining, wo bereits die Anwendung eines einzelnen Analyseverfahrens ein interessantes Datenmuster erzeugen kann, sind bei einer OLAP-Analyse meist mehrere Operatoren miteinander zu kombinieren. Anstatt ein ausgewähltes Data-Mining-Verfahren zu parametrisieren, muss für jedes Untersuchungsproblem eine geeignete Folge von OLAP-Operatoren gefunden werden, die das gesuchte Datenmuster generiert.

Für das *Modellsystem* bedeutet das, dass man zu Beginn einer OLAP-Analyse stets auf den gesamten Datenraum eines Data-Warehouse zugreift. Der multidimensionale Datenraum wird erst mithilfe der OLAP-Operatoren auf den interessierenden Teilbereich eingeschränkt. Voraussetzung dafür ist, dass der Datenraum die für die Analyse benötigten Kennzahlen, Dimensionen, Hierarchiestufen und Dimensionselemente enthält. Unabhängig davon, welche der vier generischen Zielsetzungen man verfolgt, gliedert sich die OLAP-Analyse deshalb in zwei Prozessschritte: die Sicherstellung der Datenverfügbarkeit und die eigentliche Durchführung der Analyse (siehe Abbildung 75):




Abbildung 75: Prozessschritte der Verfahrensanwendung

Im *ersten Prozessschritt* muss geprüft werden, ob sämtliche für die Analyse benötigten Objekt- und Ereignisdaten im Data-Warehouse vorhanden sind. Während sich die Dimensionen, Hierarchiestufen und Dimensionselemente aus den Typmerkmalen des Ursachen- und Wirkungsobjekttyps ergeben, werden die Kennzahlen durch die Zielsetzung bestimmt: Soll eine Ereignisbeziehung, Objekt-Ereignis-Beziehung oder Ereignis-Objekt-Beziehung analysiert werden, dann

ergeben sich die Kennzahlen aus den Ereignissen, die als Merkmalswertänderungen in der Datenbasis verzeichnet sind. Aus dem Meta-Modell der typbezogenen Kausalarchitektur ergeben sich folgenden Zuordnungsbeziehungen zwischen Ereignissen und den Objektmerkmalen, die als Kennzahlen im Data-Warehouse infrage kommen (siehe Abbildung 45 Seite 131):

- Ein *Eigenschaftsereignis* verweist auf ein Eigenschaftsmerkmal;
- ein *Interaktions-* oder *Aggregationsereignis* bezieht sich auf ein Interaktions- oder Aggregationsmerkmal;
- ein *Typwechselergebnis* verweist auf ein klassifikatorisches Objektmerkmal, das die Typzugehörigkeit einer Objektinstanz anzeigt.

Bei der Analyse der Objektbeziehungen (Zielsetzung IV) fehlt zwar der Ereignisbezug, es ist aber dennoch zu prüfen, ob die benötigten Interaktions-, Aggregations- oder Typmerkmale im Data-Warehouse vorhanden sind. Sollte eine Kennzahl fehlen, kann diese möglicherweise mit einem OLAP-Join aus bereits vorhandenen Kennzahlen erzeugt werden. Ist dies nicht der Fall oder fehlen zusätzlich wichtige Dimensionen oder Dimensionselemente, muss man die Analyse entweder abbrechen oder in die Phase der Modellkonstruktion zurückkehren, wo man das Modellsystem entsprechend anpassen und erweitern kann. Die Sicherstellung der Datenverfügbarkeit soll anhand eines Beispiels verdeutlicht werden:

Hat man beispielsweise die Vermutung, dass ein „*Rückgang der Kundenzufriedenheit eines Premiumkunden im Landkreis Bamberg*“ die Ursache für das Ereignis „*Bestellvolumen eines Premiumkunden im Landkreis Bamberg sinkt*“ ist, muss das Data-Warehouse neben den beiden Kennzahlen Bestellvolumen und Kundenzufriedenheit auch die beiden Dimensionen Kundengruppe und Vertriebsgebiet enthalten. Zum einen, um Premiumkunden zu identifizieren, zum anderen, um Kunden nach ihrem Landkreis zu differenzieren. Stellt man fest, dass noch kein eigenes Objektmerkmal für die Klassifizierung von Premiumkunden angelegt wurde, kann man dieses typbildende Merkmal möglicherweise aus einem anderen Kundenmerkmal gewinnen. Hierzu ist jedoch ein Rücksprung in die Phase der Modellkonstruktion nötig. Dort könnte aufgrund der Typvereinbarung, dass sich Premiumkunden durch besonders häufige und regelmäßige Bestellungen auszeichnen, der Kundenstatus über eine Auswertung der Bestellhistorie der letzten sechs Monate ermittelt werden. Dasselbe gilt für die Dimension Vertriebsgebiet: Fehlt die Zuordnung der Kunden zu einem Landkreis, können die

fehlenden Merkmalswerte zum Beispiel aus dem Wohnort oder der Postleitzahl des Kunden abgeleitet werden.

Ist die Datenverfügbarkeit sichergestellt, muss im *zweiten Prozessschritt* der Datenraum auf den für die Fragestellung interessierenden Teilbereich eingeschränkt und ausgewertet werden. Die Einschränkung des Datenraums erfolgt anhand der Dimensionsmerkmale, die sich aus den Typmerkmalen der betrachteten Objekttypen ergeben. Mithilfe von Slice- und Dice-Operatoren schränkt man den Datenraum so weit ein, dass nur noch die für die Analyse relevanten Objektinstanzen enthalten sind. Das sind bei einer Analyse von Objektbeziehungen all die Objektinstanzen, die mit Instanzen des jeweils anderen Objekttyps in der jeweiligen Beziehung stehen können. Bei den anderen drei Zielsetzungen sind das die Objektinstanzen, die als potenzielle Ereignisträger infrage kommen.

Um den zweiten Prozessschritt zu veranschaulichen, wird das bereits begonnene Beispiel fortgeführt: Da dem Ursachen- und dem Wirkungsereignis derselbe Ereignisträger zugrunde liegt, der Subobjekttyp PREMIUMKUNDE IM LANDKREIS BAMBERG, muss die Datenselektion nur für eine Gruppe von Objektinstanzen durchgeführt werden. Hierzu wählt man als Erstes die Dimensionen Kundengruppe und Vertriebsgebiet aus. Die Dimension Kundengruppe schränkt man mit dem Slice-Operator auf das Dimensionselement Premiumkunde ein. Die Dimension Vertriebsgebiet wird anschließend mit einem Drill-Down-Operator auf die Hierarchieebene der Landkreise disaggregiert, wo man schließlich mit einem weiteren Slice das Dimensionselement Bamberg auswählt. Als Ergebnis erhält man Zugriff auf sämtliche Instanzen vom Typ PREMIUMKUNDE IM LANDKREIS BAMBERG.

Welches Datenmuster gesucht wird und welche Folge von OLAP-Operatoren anzuwenden ist, hängt davon ab, welche der vier Zielsetzungen man verfolgt. Bei einer Analyse der *Objekt-Ereignis-Beziehungen* (Zielsetzung I) sucht man nach einem Datenmuster, das Auskunft darüber gibt, ob bzw. in welchem Maß die als Ereignisträger infrage kommenden Objektinstanzen von einem Ursachen- bzw. Wirkungsereignis betroffen waren. Hierbei richtet sich der Blick auf das Objektmerkmal, dessen Merkmalsänderung das gesuchte Ereignis beschreibt. Auf diese Weise kann auf der Objektebene die Zahl der Ereignisträger und Nicht-Ereignisträger bestimmt werden. Gleichzeitig erhält man auf der Ereignisebene die Menge der eingetretenen Ursachen- und Wirkungsereignisse. Die Analyse der Objekt-Ereignis-Beziehungen schafft somit die Voraussetzung für die nun folgende Analyse der Ereignisbeziehungen.

Bei einer Analyse von *Ereignisbeziehungen* (Zielsetzung II) sucht man nach einem Datenmuster, mit dem sich die Gesetzmäßigkeit und Chronologie des zu überprüfenden Kausalzusammenhangs beurteilen lässt. Zu diesem Zweck muss für jede identifizierte Instanz eines Ursachen- oder Wirkungseignisses untersucht werden, ob sich ihr aus der jeweils anderen Ereignismenge eine komplementäre Ereignisinstanz zuordnen lässt. Ein Ursachen- und ein Wirkungseignis sind dann komplementär, wenn zwei Voraussetzungen erfüllt sind:

- a) *Auf der Objektebene*: Zwischen den ereignistragenden Objektinstanzen besteht eine logische Zuordnungsbeziehung, wie sie zum Beispiel im relationalen Datenbankmodell die Primärschlüsselvererbung realisiert. Ein Spezialfall ist ein typologischer Kausalzusammenhang, der die Identität der ereignistragenden Objektinstanzen impliziert.
- b) *Auf der Ereignisebene*: Das Wirkungseignis hat sich nach dem Ursacheneignis ereignet und auch die Zeitspanne zwischen beiden Ereigniseintritten spricht nicht gegen die kausale Verknüpfung der Ereignisinstanzen.

Die Zeitpunkte der Ereigniseintritte lassen sich umso genauer bestimmen, desto regelmäßiger die Kennzahlen im Data-Warehouse aktualisiert werden. Liegen zwischen den Aktualisierungen sehr große Zeitintervalle, können unter Umständen auch solche Ereignisse als komplementär gelten, die sich scheinbar parallel ereignet haben, da sie in der Datenbasis mit demselben Zeitstempel versehen sind. Bei der paarweisen Zuordnung von Ursachen- und Wirkungseignissen lassen sich drei Fälle unterscheiden:

- a) *Komplementäres Ereignispaar*: Einem Ursachen- bzw. Wirkungseignis kann ein komplementäres Wirkungs- bzw. Ursacheneignis zugeordnet werden;
- b) *„Wirkungsloses“ Ursacheneignis*: Einem Ursacheneignis kann kein komplementäres Wirkungseignis zugeordnet werden;
- c) *„Ursachenloses“ Wirkungseignis*: Einem Wirkungseignis kann kein komplementäres Ursacheneignis zugeordnet werden.

Während eine Ereignissequenz im Fall a) im Einklang mit dem vermuteten Kausalzusammenhang steht und somit auf die Gültigkeit der Kausalhypothese hinweist, liegen im Fall b) und c) unvollständige Ereignissequenzen vor. Auf die Ungültigkeit der Kausalhypothese weisen allerdings nur „wirkungslöse“ Ursacheneignisse hin. Ein „ursachenloses“ Wirkungseignis widerspricht der

Kausalhypothese nicht, da die Wirkung auch durch ein alternatives Ursachenereignis hervorgerufen worden sein könnte. Um die Bildung komplementärer Ereignispaare zu veranschaulichen, wird das Beispiel fortgeführt:

Um die Gesetzmäßigkeit zwischen dem Rückgang der Kundenzufriedenheit und dem Rückgang des Bestellvolumens zu untersuchen, ist zunächst die Zeitspanne festzulegen, die zwei Ereignisinstanzen maximal auseinander liegen dürfen, um noch als komplementär zu gelten. Für jeden einzelnen Rückgang der Kundenzufriedenheit eines Premiumkunden ist dann zu prüfen, ob sich innerhalb dieser Zeitspanne auch dessen Bestellvolumen verringert hat. Umgekehrt muss für jeden Rückgang des Bestellvolumens kontrolliert werden, ob bei demselben Kunden zuvor die Kundenzufriedenheit gesunken ist.

Mit der Analyse von *Ereignis-Objekt-Beziehungen* (Zielsetzung III) sucht man Datenmuster, die über den kausalen Geltungsbereich einer Kausalhypothese informieren. Dies bietet sich vor allem dann an, wenn bei einer Analyse von Ereignisbeziehungen „wirkungslose“ Ursachenereignisse identifiziert wurden. Man kann dann versuchen, die Objektinstanzen, die Träger eines „wirkungslosen“ Ursachenereignisses sind, von den Objektinstanzen abzugrenzen, deren Ursachenereignis Teil einer vollständigen Ereignissequenz ist. Hier ist es ratsam, auch andere als die bislang betrachteten Kennzahlen und Dimensionen in die Analyse einzubeziehen. Ziel ist es, eine aussagekräftige Kombination aus Kennzahlen und Dimensionen zu finden, anhand derer sich beide Arten von Objektinstanzen unterscheiden. Nachdem man sich auf eine oder mehrere Dimensionen festgelegt hat, kann auf jeder Hierarchiestufe geprüft werden, welche Dimensionselemente sich als Distinktionsmerkmal eignen. Diese Art der OLAP-Analyse entspricht der in Abschnitt 5.3.1.2 beschriebenen Top-Down-Navigation (siehe Abbildung 47), nur mit dem Unterschied, dass sie nicht automatisiert, sondern manuell durchgeführt wird.

Einen Anlass zur Analyse der Ereignis-Objekt-Beziehungen würden etwa Premiumkunden geben, deren Verkaufsumsätze sich trotz gesunkener Kundenzufriedenheit nicht verringert haben. Man kann nun versuchen, das Bestellverhalten dieser Kunden aus dem Blickwinkel einer anderen Dimension zu betrachten, etwa der Produktdimension. Würde man feststellen, dass sich die Bestellungen der unzufriedenen, aber unvermindert bestellfreudigen Premiumkunden ausschließlich auf niedrigpreisige Produkte beziehen, lässt sich der kausale Geltungsbereich der Hypothese auf solche Premiumkunden einschränken, die hochpreisige Produkte bestellen.

Ebenso wie die Analyse der Ereignis-Objekt-Beziehung unterstützt auch die Analyse von *Objektbeziehungen* (Zielsetzung IV) die Überprüfung einer Kausalhypothese nur mittelbar. Statt einer Kausalhypothese überprüft man eine Strukturhypothese, die auf der Objektebene eine Typ-, Aggregations- oder Interaktionsbeziehung beschreibt. Hierzu sind zunächst die Objektinstanzen derjenigen Objekttypen zu selektieren, denen eine Objektbeziehung unterstellt wird. Auch hier geben die Typmerkmale der Objekttypen die Dimensionen vor, aus deren Blickwinkel man die Kennzahlen der Interaktions-, Aggregations- oder klassifikatorischen Typmerkmale betrachtet. Ist der Datenraum auf den interessierenden Teilbereich eingeschränkt, lassen sich die Objektinstanzen bestimmen, die mit einer oder mehreren Objektinstanzen des jeweils anderen Objekttyps in Beziehung stehen. Ob man die Strukturhypothese als gültig akzeptiert, wird jedoch erst in der nächsten Phase, der Lösungstransformation, entschieden.

Ein Beispiel für eine *Typhypothese* wäre die Vermutung, dass der größte Anteil an Premiumkunden älter als 50 Jahre ist. Dies kann mit einer einfachen Analyse überprüft werden, indem man den Anteil der Premiumkunden in den Altersklassen „jünger als 50 Jahre“ und „50 Jahre und älter“ berechnet. In analoger Weise ließe sich auch eine *Interaktionshypothese* überprüfen, die besagt, dass Premiumkunden seltener Artikel reklamieren und umtauschen als Nicht-Premiumkunden. Eine *Aggregationshypothese* läge vor, wenn man davon ausgeht, dass der Anteil an Premiumkunden in städtischen Vertriebsgebieten höher ist als in ländlichen Gebieten. Die Aggregationshypothese bezieht sich auf die Aggregationsbeziehung zwischen dem aggregierten Objekttyp VERTRIEBSGEBIET und dem Teilobjekttyp KUNDE. Um diese Aggregationshypothese prüfen zu können, müssen sich die Vertriebsgebiete in städtisch und ländlich geprägte Gebiete differenzieren lassen, bevor der jeweilige Anteil an Premiumkunden bestimmt werden kann.

6.4.4 Lösungstransformation

In der Phase der Lösungstransformation muss das gefundene Datenmuster in Bezug auf Verständlichkeit, Neuheit, Gültigkeit und Nützlichkeit bewertet werden (siehe Abbildung 76).

Ob das gefundene Datenmuster jedoch den Erwartungen entspricht, ist eine Frage der *Neuheit*. Anders als die datenzentrierte Hypothesenentwicklung setzt eine erfolgreiche Hypothesenprüfung voraus, dass das gefundene Datenmuster den Erwartungen entspricht. Einen Neuigkeitswert besitzt das Analyseergebnis




Abbildung 76: Prozessschritt der Lösungstransformation

deshalb nur insofern, dass es detailliert über den Zusammenhang informiert und anstelle einer Erwartung nun die Gewissheit tritt. Einen sehr viel höheren Neuigkeitswert besitzt zweifellos das Datenmuster einer fehlgeschlagenen Hypothesenprüfung. Ein solch unerwartetes Analyseergebnis mag die Kausalhypothese in ihrer vorliegenden Form

zwar widerlegen, bietet aber meist interessante Anknüpfungspunkte für weitere Analysen, um entweder den kausalen Geltungsbereich der Hypothese anzupassen oder um neue Kausalhypothesen zu entwickeln.

Um die *Gültigkeit* der Analyseergebnisse zu beurteilen, muss die Frage nach der Zuverlässigkeit der Daten und der Möglichkeit von Datenmängeln beantwortet werden. Im Gegensatz zu einer Data-Mining-Analyse, bei der in der Phase der Modellkonstruktion manuell und Einzelfall bezogen nach Datenmängeln gesucht wird, verläuft dieser Prozess bei der OLAP-Analyse dank der Routinen des ETL-Prozesses automatisiert ab. Damit sind Datenmängel zwar nicht ausgeschlossen, ihnen wird aber innerhalb des ETL-Prozesses standardmäßig entsprechend hohe Aufmerksamkeit geschenkt - nicht zuletzt deshalb, weil die Daten eines Data-Warehouse oft die Grundlage für die externe Berichterstattung sind und rechtsverbindlichen Vorschriften unterliegen.

Zuletzt ist die *Nützlichkeit* des Analyseergebnisses zu bewerten. Nützlich ist ein Analyseergebnis dann, wenn das Datenmuster die Gültigkeit der Hypothese entweder eindeutig bestätigt oder falsifiziert. Da jedoch in den seltensten Fällen ein derart eindeutiges Analyseergebnis vorliegen wird, muss der Aussagegehalt des Datenmusters je nach Zielsetzung unterschiedlich interpretiert werden.

Obwohl sich nach der *Analyse der Objekt-Ereignis-Beziehungen* (Zielsetzung I) noch nichts über die Gültigkeit eines Kausalzusammenhangs sagen lässt, erfährt man dennoch, wann und wie häufig oder regelmäßig sich das Ursachen- bzw. Wirkungseignis ereignet hat. Auf Grundlage dieser Information gewinnt man einen ersten Eindruck über die Bedeutung der untersuchten Ereignisse und somit über den Kausalzusammenhang, der sie möglicherweise verknüpft.

Ein konkreter Hinweis auf die Ungültigkeit der Kausalhypothese läge vor, wenn man bei der *Analyse der Ereignisbeziehungen* (Zielsetzung II) „wirkungslose“

Ursachenereignisse identifiziert hätte. Dann muss abhängig von der Zahl der vollständigen Ereignissequenzen entschieden werden, ob man die implizierte Gesetzmäßigkeit als Zufallstreffer betrachtet und die Kausalhypothese verwirft. „Wirkungslose“ Ursachenereignisse lassen sich aber auch anders interpretieren: Man könnte weiterhin von einem kausalen Ereigniszusammenhang ausgehen und das Analyseergebnis lediglich als Hinweis auf einen zu weit gefassten kausalen Geltungsbereich auffassen. Im Gegensatz zu „wirkungslosen“ Ursachenereignissen stellen „ursachenlose“ Wirkungsereignisse die Gültigkeit der Kausalhypothese nicht infrage. Stattdessen sagen sie etwas über die Bedeutung des Kausalzusammenhangs aus. Hätte man zum Beispiel neben einigen vollständigen Ereignissequenzen auch eine Vielzahl „ursachenloser“ Wirkungsereignisse identifiziert, ist anzunehmen, dass Alternativursachen dieselbe Wirkung hervorrufen können. Je nachdem wie das Verhältnis zwischen vollständigen Ereignissequenzen und „ursachenlosen“ Wirkungsereignissen ausfällt, ist dem überprüften Kausalzusammenhang mehr oder weniger Bedeutung beizumessen.

Bei einer Analyse der *Ereignis-Objekt-Beziehungen* (Zielsetzung III) muss die Aussagekraft der gefundenen Merkmalsunterschiede bewertet werden. Hat man diese Analyse im Anschluss an eine fehlgeschlagene Hypothesenprüfung durchgeführt, ist zu prüfen, ob die Merkmalsunterschiede die „Wirkungslosigkeit“ der Ursachenereignisse erklären können. Ist dies der Fall, kann der kausale Geltungsbereich auf zweierlei Art eingeschränkt werden: Beschreiben die Distinktionsmerkmale Eigenschaften der potenziellen *Ursachenobjekte*, ist der kausale Geltungsbereich durch eine Modifikation des Ursachenobjekttyps einzuschränken. Liegen den Merkmalsunterschieden abgeleitete Merkmale zugrunde, die die Eigenschaften der potenziellen *Wirkungsobjekte* beschreiben, ist der kausale Geltungsbereich durch eine Modifikation des Wirkungsobjekttyps einzuschränken. In beiden Fällen scheiden jeweils die Ereignisträger der „wirkungslosen“ Ursachenereignisse aus der Menge der potenziellen Ereignisträger aus.

Mit einer *Analyse von Objektbeziehungen* (Zielsetzung IV) erhält man ein Datenmuster, das die strukturellen Zusammenhänge zwischen den Objektinstanzen beschreibt. Selbst dann, wenn man damit die kausale Infrastruktur einer Kausalhypothese überprüft, ist zunächst allein die Aussage der Strukturhypothese zu bewerten. Erst in einem zweiten Schritt ist diese Aussage auf die Kausalhypothese zu beziehen, deren kausale Infrastruktur das Analyseergebnis beschreibt.

Ist man zum Beispiel in einem Supermarkt der Ansicht, dass sich ein Rückgang der Produktqualität von Biogemüse nicht nur negativ auf die Ver-

kaufumsätze der Gemüseabteilung auswirkt, sondern auch auf die Umsätze mit fair gehandeltem Kaffee, muss geprüft werden, ob die Kunden von Biogemüse tatsächlich fair gehandelten Kaffee kaufen (Interaktionshypothese). Denn nur wenn diese Strukturhypothese zutreffend ist, würde ein Qualitätsrückgang beim Biogemüse zu einer Abwanderung von Kunden von fair gehandeltem Kaffee führen. Ist man der Meinung, dass der Verlust von Biokunden insgesamt keine nennenswerte Auswirkung auf den Gesamtumsatz haben wird, liegt dieser Einschätzung eine Typhypothese zugrunde, die besagt, dass der Anteil der Biokunden am gesamten Kundenstamm gering ist. Nur wenn sich diese Typhypothese durch einen geringen Anteil von Biokunden bestätigt, kann diese Strukturhypothese als gültig betrachtet werden.

6.5 Kombination der Gestaltungsoptionen zu einem integrierten Analyseprozess

Nachdem die vier Gestaltungsoptionen zur Entwicklung und Überprüfung von Kausalhypthesen vorgestellt wurden, soll zum Abschluss dieses Kapitels gezeigt werden, wie sich diese Gestaltungsoptionen kombinieren und zu einem integrierten Analyseprozess zusammenfügen lassen. Um zwei Gestaltungsoptionen zu kombinieren, gibt es zwei Möglichkeiten: die sequenzielle und die verschachtelte Anwendung von Gestaltungsoptionen (siehe Abbildung 77).




Abbildung 77: Grundlegende Kombinationsmöglichkeiten von Gestaltungsoptionen

Bei der *sequenziellen Anwendung* knüpft die nachfolgende Gestaltungsoption an das Ergebnis der zuerst angewandten Gestaltungsoption an. Die zweite Gestaltungsoption beginnt also erst dann, wenn die erste Gestaltungsoption beendet ist und deren Ergebnis vorliegt. Anders bei der *verschachtelten Anwendung*: Zwar initiiert auch hier die zuerst angewandte Gestaltungsoption die Anwendung der

zweiten Gestaltungsoption, dies geschieht aber nur, um *deren* Ergebnis für die eigene Analyse nutzen zu können. Die Anwendung der ersten Gestaltungsoption wird nur so lange unterbrochen, bis das Ergebnis der zweiten Gestaltungsoption vorliegt.

Um die vier Gestaltungsoptionen zu einem integrierten Analyseprozess zusammenzufügen, muss geklärt werden, welche Gestaltungsoptionen sich wie kombinieren lassen. Im folgenden Abschnitt 6.5.1 wird zunächst die sequenzielle Anwendung der Gestaltungsoptionen erläutert, bevor im Abschnitt 6.5.2 die Kombinationsmöglichkeit der verschachtelten Anwendung vorgestellt wird.

6.5.1 Sequenzielle Anwendung der Gestaltungsoptionen

Welche Kombinationsmöglichkeiten sich bei einer sequenziellen Anwendung ergeben, lässt sich aus den konzeptionellen und methodischen Vorüberlegungen ableiten, auf deren Basis die vier Gestaltungsoptionen in Abschnitt 5.1 entwickelt wurden. Der Analyseprozess besteht demnach aus zwei Phasen: der Phase der Hypothesenentwicklung und der Phase der Hypothesenprüfung. Obwohl die analytische Fragestellung in der ersten Phase sehr viel offener ist als die der zweiten Phase, beruhen beide Phasen auf demselben Grundprinzip: dem Nachweis kausaler Wesensmerkmale (siehe Abschnitt 5.1.4.1). Im Gegensatz zu einer unbegründeten Kausalannahme kann sich eine Kausalhypothese auf wenigstens ein nachgewiesenes Wesensmerkmal stützen (siehe Abschnitt 5.1.2). Um eine Kausalhypothese in eine gültige Kausalinformation zu transformieren, müssen in der Phase der Überprüfung die noch ausstehenden Wesensmerkmale nachgewiesen werden.

Daraus folgt, dass es für die Gültigkeit einer Kausalinformation keine Rolle spielt, in welcher Reihenfolge die drei Wesensmerkmale nachgewiesen werden. Für die sequenzielle Anwendung der Gestaltungsoptionen lässt sich daraus Folgendes ableiten: Weil sich die Chronologie und Gesetzmäßigkeit eines Kausalzusammenhangs nur datenzentriert nachweisen lässt, die Bedingtheit wiederum nur modellzentriert zu belegen ist, können die Gestaltungsoptionen zu zwei spiegelbildlichen Prozessverläufen aneinandergefügt werden: Wurde eine Kausalhypothese modellzentriert entwickelt, muss diese im Anschluss datenzentriert überprüft werden. Ist die Kausalhypothese auf datenzentriertem Wege entwickelt worden, muss eine modellzentrierte Überprüfung folgen. Beide Prozessabläufe sind in Abbildung 78 skizziert.

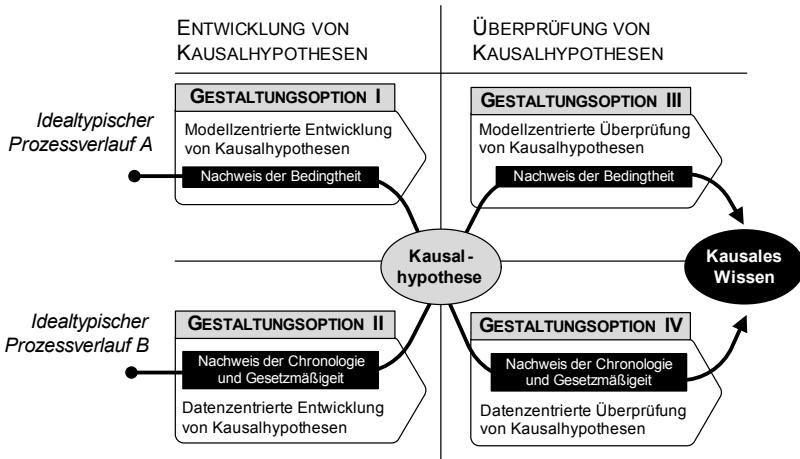


Abbildung 78: Idealtypischer Verlauf des Analyseprozesses

Beide Prozessverläufe sind jedoch als idealtypisch zu betrachten, da sie den kürzesten Verlauf des Analyseprozesses darstellen. In der Regel wird der Analyseprozess nicht linear, sondern zyklisch verlaufen. Sollte sich zum Beispiel eine Kausalhypothese bei der Überprüfung als ungültig erweisen, ist ein Rücksprung in die Phase der Hypothesenentwicklung nötig, wo dann eine alternative Kausalhypothese entwickelt werden muss. Folglich kann der Analyseprozess neben dem Phasenübergang von der Hypothesenentwicklung zur -überprüfung noch einen zweiten Phasenübergang enthalten: den von der Hypothesenprüfung wieder zurück in die Phase der Hypothesenentwicklung.

Während man beim Übergang von der Hypothesenentwicklung zur -überprüfung gezwungen ist, die Analyse mit einem Modellsystem der jeweils anderen Kausalarchitektur fortzusetzen, hat man beim Rücksprung in die Entwicklungsphase die Wahl, ob man die Analyse modell- oder datenzentriert weiterführen möchte. So kann man sich zum Beispiel nach einer erfolglosen OLAP-Analyse für einen Wechsel der Kausalarchitektur entscheiden und die nächste Kausalhypothese modellzentriert entwickeln. Alternativ kann man die instanzbezogene Kausalarchitektur auch beibehalten und sich für eine Hypothesenentwicklung mit Data-Mining-Verfahren entscheiden. Die gleiche Wahlmöglichkeit bietet sich auch im umgekehrten Fall, beim Scheitern der modellzentrierten Hypothesenprüfung. Auf diese Weise können die linearen Prozessverläufe in Abbildung 78 zu zwei spiralförmigen Analysezyklen verknüpft werden (siehe Abbildung 79).

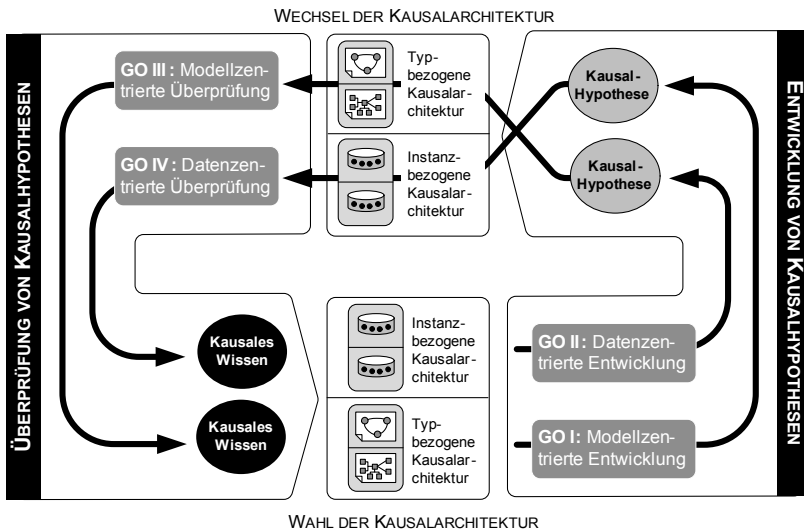


Abbildung 79: Spiralförmiger Analyseverlauf mit Wechsel des Modellsystems

Doch auch dieser spiralförmige Analyseverlauf entpuppt sich bei näherer Betrachtung als idealtypisch – und zwar aus zwei Gründen: Der erste Grund betrifft den Übergang von der modellzentrierten Entwicklung zur datenzentrierten Überprüfung, weil man aufgrund fehlender Daten nicht jede Kausalhypothese, die modellzentriert entwickelte wurde, auch datenzentriert überprüfen kann - sei es, weil die Daten erst noch erhoben werden müssen, oder weil sich die Daten nicht in der erforderlichen Genauigkeit oder und Regelmäßigkeit erheben lassen.

Der zweite Grund betrifft den Übergang von der datenzentrierten Entwicklung zur modellzentrierten Überprüfung: Es wird weder notwendig noch möglich sein, für jede aus den Daten gewonnene Kausalhypothese eine kausale Infrastruktur zu modellieren:

- nicht notwendig, falls sich die Kausalhypothese mit einer anderen Kausalhypothese dieselbe Infrastruktur teilt und die Infrastrukturbeziehung bereits modelliert wurde;
- nicht möglich, weil das Ursachen- mit dem Wirkungsobjekt identisch ist und ein typologischer Kausalzusammenhang vorliegt, der sich aufgrund mangelnden Objektvokabulars nicht auflösen lässt (siehe Abschnitt 5.2.1.2).

Es ist daher zuweilen möglich bzw. nötig, die Analyse nach der Hypothesenentwicklung ohne Wechsel der Kausalarchitektur fortzusetzen. Bei einem solchen Phasenübergang muss allerdings bedacht werden, dass es nicht möglich ist, eine Kausalhypothese mit derselben Kausalarchitektur zu überprüfen, mit der sie zuvor entwickelt wurde. Hat man ein kausales Wesensmerkmal bereits im Zuge der Hypothesenentwicklung nachgewiesen, kann dieses Merkmal kein zweites Mal belegt, allenfalls bekräftigt werden. Soll dieselbe Kausalarchitektur sowohl für die Entwicklung als auch für die Überprüfung verwendet werden, muss die Hypothese bei diesem Phasenübergang nicht vollständig verworfen werden, es reicht, wenn sie modifiziert wird (vgl. [Drei94, S. 33]).

Eine Kausalhypothese lässt sich modifizieren, indem man ihren kausalen Geltungsbereich entweder einschränkt oder erweitert. Sowohl bei der modell- als auch bei der datenzentrierten Überprüfung muss dann untersucht werden, ob sich das kausale Wesensmerkmal für die generalisierten bzw. spezialisierten Ereignisträger nachweisen lässt. Hat zum Beispiel eine Data-Mining-Analyse der Kundendaten ergeben, dass im Landkreis Bamberg ein eindeutiger Zusammenhang zwischen der Kundenzufriedenheit und den Bestellvolumina besteht, kann mit einer OLAP-Analyse geprüft werden, ob sich die Kausalhypothese generalisieren lässt und dieser Zusammenhang auch für die Kunden aller anderen Landkreise gilt. Folglich erweitert sich das Modellsystem um die Kundendaten der anderen Landkreise. Die OLAP-Analyse kann dann mit der erweiterten Datenbasis durchgeführt werden. Die Suche nach evidenten Kausalhypothesen entwickelt sich so zu einem iterativen Prozess „der Suchraumeinschränkung, der intensiven Suche im eingeschränkten Suchraum, der Suchraumerweiterung bei Erfolglosigkeit der Suche, der Einschränkung des neuen Suchraumes, der Fortsetzung der Suche in dem neuen Suchraum...“ [Dörn03, S. 245].

Behält man die Kausalarchitektur nicht nur beim Phasenübergang von der Entwicklung zur Überprüfung, sondern auch beim Wechsel in die Entwicklungsphase bei, entsteht ein homogener und in sich geschlossener Analysezyklus. Abhängig von der verwendeten Kausalarchitektur handelt es sich um einen modell- oder einen datenzentrierten Analysezyklus. Während sich bei einem datenzentrierten Analysezyklus hypothesen- und datengetriebene Verfahren abwechseln (vgl. [Knob00, S. 11], [PiMe03, S. 117]), folgen bei einem modellzentrierten Analysezyklus die modellzentrierte Hypothesenprüfung auf die modellzentrierte Entwicklung. Abbildung 55 zeigt die beiden Varianten eines geschlossenen Analysezyklus.

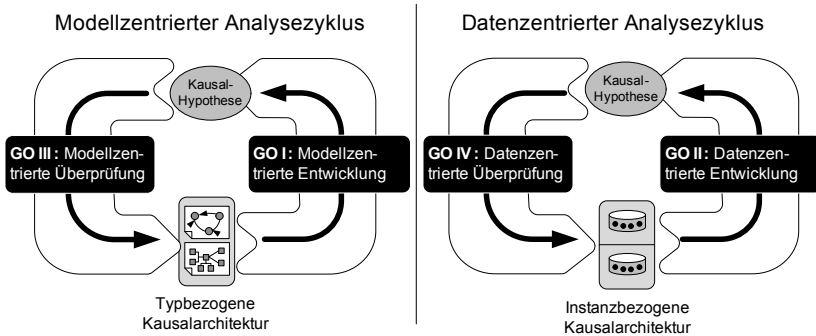


Abbildung 80: Modell- und datenzentrierter Analysezyklus

Außer dass es zuweilen möglich, aber auch nötig ist, die Kausalanalyse mit derselben Kausalarchitektur fortzusetzen, spricht noch ein weiterer Grund für einen geschlossenen Analysezyklus: Oft drängen sich gerade im Anschluss an die Hypothesenentwicklung Vermutungen über alternative Ursachen und Wirkungen auf. Obwohl diese Vermutungen auf Basis der Analyseergebnisse angestellt werden, beruhen sie dennoch nicht selten auf Intuition und Assoziation. Dann bietet es sich an, zunächst auf einen Wechsel der Kausalarchitektur zu verzichten und diese unbegründete Kausalannahme lediglich mit einem modifizierten bzw. erweiterten Modellsystem zu überprüfen. Wie ein solcher Analysezyklus in der Praxis aussehen kann, beschreiben Ittner und Larcker:

„In einem IT-Unternehmen aus unserer Studie führt ein bereichsübergreifendes Team vierteljährlich Analysen integrierter Daten durch - operativer, buchhalterischer und kundenrelevanter - und entwickelt Hypothesen über den Zusammenhang zwischen bestimmten Anstrengungen des Unternehmens und den erzielten Ergebnissen. Beispiel: Welche Art von Kunden wird das Unternehmen höchstwahrscheinlich verlieren, wenn operative Kennzahlen unter eine bestimmte Schwelle sinken? (...)

Die Hypothesen und die zugehörigen Untersuchungsergebnisse werden dann dem Topmanagement vorgelegt. In fast jedem Meeting werfen diese Präsentationen neue Fragen über die zugrunde liegenden Wertreiber auf, die dann wiederum in der nächsten vierteljährlichen Analyse untersucht werden. Kurz gesagt: Der Prozess der Verfeinerung sollte niemals zu Ende sein.“ [ItLa04, S. 80-81]

6.5.2 Verschachtelte Anwendung der Gestaltungsoptionen

In diesem Abschnitt werden die Synergieeffekte vorgestellt, die sich bei einer verschachtelten Anwendung daten- und modellzentrierter Gestaltungsoptionen

ergeben. Zunächst wird gezeigt, auf welche Weise die modellzentrierte Kausalanalyse von den Ergebnissen der datenzentrierten Kausalanalyse profitieren kann, bevor anschließend erläutert wird, welche Vorteile sich umgekehrt für die datenzentrierte Kausalanalyse ergeben.

Bei der Anwendung der modellzentrierten Gestaltungsoptionen müssen sowohl Annahmen über Objektbeziehungen als auch über die Beziehungen zwischen Ereignis- und Objekttypen getroffen werden. Um keine falschen Annahmen zu treffen, können diese Strukturhypothesen auch datenzentriert entwickelt und überprüft werden. Mit welcher der vier generischen Zielsetzungen man die Datenanalyse dann durchführt (siehe Abschnitte 6.2.1 und 6.4.1), hängt davon ab, welche Phase der modellzentrierten Kausalanalyse unterstützt werden soll.

In der Phase der *Zieltransformation* sind die ereignistragenden Objekttypen zu bestimmen. Mit einer gezielten Datenanalyse der Objekt-Ereignis-Beziehungen kann geprüft werden, in welchem Maße sich Instanzen vom Typ des Ausgangsereignisses überhaupt ereignet haben. Im Gegenzug lässt sich mit einer Analyse der Ereignis-Objekt-Beziehungen die Typisierung des als Ereignisträger genannten Objekttyps überprüfen. Alternativ können dessen typbildenden Merkmale auch datengetrieben entwickelt werden.

In der Phase der *Modellkonstruktion* lässt sich speziell die Ereignispräzisierung durch eine OLAP-Analyse unterstützen, indem man untersucht, welches der präziseren Ereignisse tatsächlich stattgefunden hat. Darüber hinaus kann es sinnvoll sein, die modellierten Objektbeziehungen mit einer OLAP-Analyse zu überprüfen oder mittels Data-Mining neue oder differenziertere Strukturhypothesen zu entwickeln.

Im Zuge der *Verfahrensanwendung* eignet sich eine Analyse der Objekt-Ereignis-Beziehungen, um den Eintritt der aus dem Objektmodell abgeleiteten Ereignisse zu verifizieren. Mit Data-Mining-Verfahren können aber auch neue Ereignisse für bestimmte Objekttypen entdeckt werden, sofern man über Daten der Objektinstanzen verfügt. Muss eine Kausalhypothese plausibilisiert werden, lässt sich der kausale Geltungsbereich entweder gezielt überprüfen oder sogar datengetrieben entwickeln.

In der Phase der *Lösungstransformation* bietet sich die OLAP-Analyse an, um bei der Bewertung der Nützlichkeit die Erklärungskraft der Kausalhypothesen abzuschätzen. Hierzu muss untersucht werden, welche Ursachen- oder Wirkungsergebnisse sich in welchem Ausmaß ereignet haben. Zuletzt kann mit einer Analyse von Objektbeziehungen geprüft werden, welche Objektinstanzen des

Ursachen- und Wirkungsobjekttyps tatsächlich in der modellierten Infrastrukturbeziehung stehen.

Doch auch die datenzentrierte Kausalanalyse kann von den Ergebnissen der modellzentrierten Gestaltungsoptionen profitieren - und zwar mit folgender Intention:

„Ziel ist, den die technische Analyse zunächst vorgelagerten, dann begleitenden Denkprozess so zu unterstützen, dass die Formulierung der Fragestellung, die Thesenbildung, Verifikation und Falsifikation rationalen Prinzipien folgt und transparent mit den Analyseergebnissen dokumentiert wird. Zudem soll ein, notwendigerweise kreativer, Prozess angestoßen werden, in dem der Anwender aus ausgetrampelten Denkpfaden ausbricht und zu neuen Fragestellungen und letztlich Gestaltungsmöglichkeiten findet.“
[Biss02, S. 244]

In der Phase der *Zieltransformation* hilft eine fundierte Modellanalyse, das Untersuchungsproblem und die analytische Fragestellung so präzise wie möglich zu formulieren. Bei der *Modellkonstruktion* strukturiert das Objektmodell den Objektbereich bereits so vor, dass sich aus den Objekt- und Subobjekttypen die für die Analyse benötigten Datenobjekttypen ableiten lassen. Hiervon profitiert speziell die Data-Mining-Analyse, da ihr Modellsystem für jede Fragestellung neu zu konstruieren ist. Das Objektmodell erleichtert dann insbesondere den Prozessschritt der Datenselektion. Dies gilt ebenso für Kausalmodelle, deren Ereignisse auf potenzielle Analysemerkmale hinweisen und somit den zukünftigen Datenbedarf aufzeigen (vgl. [Pyle03, S. 224]). Von geringerer Bedeutung ist das Kausal- und Objektmodell bei der Modellkonstruktion der OLAP-Analyse. Zwar ließe sich die typbezogene Kausalarchitektur als Grundlage für den konzeptionellen und logischen Data-Warehouse-Entwurf nutzen, allerdings dient ein Data-Warehouse vor allem dem Zweck der internen und externen Berichterstattung und wird deshalb selten speziell für die Kausalanalyse konstruiert werden.

In der Phase der *Verfahrensanwendung* profitiert lediglich die OLAP-Analyse von einem Objektmodell. Aus ihm erschließt sich, welche Dimensionen, Dimensionselemente und Kennzahlen sich kombinieren lassen. Das Objektmodell kann hierbei die Funktion einer Landkarte übernehmen, da man sich bei der Navigation im multidimensionalen Datenraum an den Aggregations- und Typbeziehungen orientieren kann.

Bei der *Lösungstransformation* erleichtert die Modellanalyse die Interpretation der Datenmuster. Ist das Ergebnis unverständlich, kann der Untersuchungsbereich in einem Objektmodell abgebildet werden. So lässt sich das Objektvokabular, das einem für die Interpretation der Datenmuster fehlt, mit einer Modellkonstruktion auf Basis von Objektbeziehungen systematisch erarbeiten.

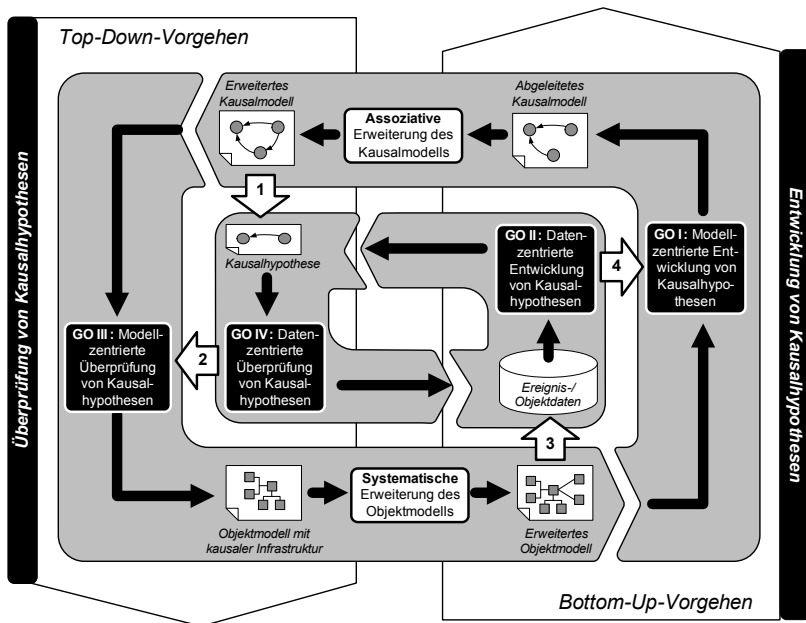


Abbildung 81: Kombination des modell- und datenzentrierten Analysezyklus

Abbildung 81 zeigt, wie der datenzentrierte Analysezyklus so in den modellzentrierten Analysezyklus eingebettet werden kann, dass einerseits die datenzentrierten Gestaltungsoptionen von den Ergebnissen der Modellanalyse profitieren, andererseits die Modellanalyse die Datenanalyse initiiert, um ihre Kausal- und Strukturhypothesen datenzentriert zu entwickeln und zu überprüfen. Grundsätzlich empfiehlt es sich, den Analyseprozess mit einer modellzentrierten Gestaltungsoption zu beginnen: zum einen, weil sich mit dieser Art der Analyse ohne größere Vorbereitung beginnen lässt, während die Datenanalyse sowohl die Datenverfügbarkeit als auch eine entsprechende Datenqualität voraussetzt. Zum anderen benötigt man für die Datenanalyse ohnehin ein differenziertes Ereignis- und Objektvokabular, das sich im Rahmen einer kombinierten Modell- und Datenanalyse wie folgt erarbeiten lässt.

Verfügt man über ein Kausalmodell, lassen sich daraus einzelne Hypothesen sowohl modell- als auch datenzentriert überprüfen (siehe Abbildung 81: 1). Das Analyseergebnis der OLAP-Analyse kann in die modellzentrierte Überprüfung einfließen, wo es den Beziehungen des Kausal- und Objektmodells mehr Sicher-

heit verleiht (2). Anstatt in den modellzentrierten Analysezyklus zurückzukehren, kann der Analyseprozess auch dem datenzentrierten Analysezyklus folgen und nach der OLAP-Analyse eine datenzentrierte Hypothesenentwicklung durchführen. Die hierfür benötigten Ereignis- und Objektdaten lassen sich auf Basis des Objektmodells selektieren (3), das sich nach der modellzentrierten Überprüfung systematisch um weitere Objekttypen und -beziehungen erweitern lässt. Je nachdem, ob man mit der Data-Mining-Analyse Struktur- oder Kausalhypothesen entwickelt, wird dadurch entweder das Objekt- oder Kausalmodell ergänzt (4). Doch auch hier besteht die Möglichkeit, vor der Rückkehr in den modellzentrierten Analysezyklus eine hypothesengetriebene Datenanalyse durchzuführen und den datenzentrierten Analysezyklus fortzusetzen.

Wie sich die modell- und datenzentrierten Gestaltungsoptionen in der Praxis anwenden und kombinieren lassen, zeigt die folgende Fallstudie im letzten Kapitel dieser Arbeit.

7 Entwicklung und Überprüfung von Kausalhypothesen für das Performance-Management eines Sportartikelherstellers

In Kapitel 4 wurden die Einsatzmöglichkeiten für Kausalinformationen im Performance-Management vorgestellt und somit die Brücke zwischen dem Performance-Management-Prozess auf der einen Seite und dem Analyseprozess auf der anderen Seite geschlagen. In diesem Kapitel soll der theoretische Brückenschlag durch eine Fallstudie untermauert werden, die zeigt, wie die in Kapitel 6 beschriebenen Gestaltungsoptionen des Analyseprozesses für das Performance-Management eines Sportartikelherstellers umgesetzt wurden. Der Fokus der Fallstudie liegt jedoch auf der Durchführung des Analyseprozesses. Gleichwohl ist der Bezug zum Performance-Management unmittelbar gegeben, da das Performance-Management des Sportartikelherstellers der Empfänger der bereitgestellten Kausalinformationen ist. Auf die Prozessschritte des Performance-Managements wird deshalb nur insofern eingegangen, als dass sie den äußeren Rahmen für die modell- und datenzentrierte Kausalanalyse bilden.

Da es für die Darstellung der Fallstudie nicht von Belang ist, bei welchem Sportartikelhersteller diese durchgeführt wurde, wird das Unternehmen im weiteren Verlauf als Sport AG bezeichnet. Um keine sensiblen Unternehmensdaten zu veröffentlichen, wurden sämtliche in dieser Fallstudie verwendeten Zahlenwerte und Datensätze so abgeändert, dass eine Zuordnung zum realen Unternehmen nicht mehr möglich ist. Hierbei wurden zwar die Absolutwerte abgeändert, aber das Verhältnis der Zahlenwerte beibehalten.

Im folgenden Abschnitt 7.1 wird zunächst das originäre Untersuchungsproblem spezifiziert, das das Performance-Management des Sportartikelherstellers mithilfe der Kausalinformationen lösen wollte. Im Anschluss wird in Abschnitt 7.2 die Durchführung des Analyseprozesses beschrieben.

7.1 Problemstellung des Performance-Managements

Um die Problemstellung des Performance-Managements zu erläutern, wird auf das Konzept der Untersuchungssituation zurückgegriffen (siehe Abschnitt 5.1.4.1). Demnach setzt sich das Untersuchungsproblem aus einem Untersuchungsobjekt und einem Untersuchungsziel zusammen. Während in Abschnitt 7.1.1 das Untersuchungsobjekt vorgestellt wird, geht Abschnitt 7.1.2 auf das Untersuchungsziel des Performance-Managements ein.

7.1.1 Untersuchungsobjekt des Performance-Managements

Das Untersuchungsobjekt der Fallstudie war der Kundenauftragsprozess der zentraleuropäischen Landesgesellschaften. Im folgenden Abschnitt wird dieser Prozess näher beschrieben. Der darauf folgende Abschnitt erläutert speziell den Ablauf der Kreditprüfung, deren Ergebnis über den Verlauf des Kundenauftragsprozesses entscheidet.

7.1.1.1 Kundenauftragsprozess

Bei der Sport AG handelt es sich um einen international operierenden Sportartikelhersteller. Die Produktpalette umfasst neben Sportschuhen und Bekleidung auch Sportgeräte und reicht von den klassischen Team- und Leistungssportarten hinein in den Lifestyle- und Modebereich. Das Sortiment setzt sich pro Saison aus mehr als 30 000 unterschiedlichen Modelltypen zusammen. Die Sport AG unterhält keine eigenen Produktionsstätten. Hergestellt werden die Sportartikel überwiegend von Zulieferfirmen in Asien, von wo aus die mehr als 300 Millionen verkauften Artikel pro Jahr entweder direkt zum Kunden oder in eines der eigenen Lagerhäuser transportiert werden. Die Produkte sind zwar in nahezu allen Ländern der Welt erhältlich, werden aber überwiegend an Großkunden vertrieben. Die Sport AG unterhält zudem eigene Läden, mit denen sie sich auch direkte Vertriebskanäle in Richtung Endkunde sichert.

Die mehr als 70 Landesgesellschaften sind in mehrere Regionen aufgeteilt. Ihre Aufgabe besteht darin, die Geschäftsbeziehungen zu den regionalen und lokalen Einzelhandelskunden herzustellen, aufrechtzuerhalten sowie die Kundenaufträge entgegenzunehmen und deren Konditionen auszuhandeln.

Der Kundenauftragsprozess beginnt mit der Erfassung von Kundenaufträgen, die sich in Vor- und Nachbestellungen differenzieren. Vorbestellungen müssen Kunden bereits vor der eigentlichen Verkaufssaison einer Kollektion abgeben, damit sie während der Verkaufssaison weitere Artikel der Kollektion nachbestellen können. Die von den Landesgesellschaften entgegengenommenen Vorbestellungen werden zusammen mit den für die Verkaufssaison prognostizierten Nachbestellungen zu einem Produktionsplan zusammengefasst. Dieser besteht aus Produktionsaufträgen für die asiatischen Zulieferfirmen und enthält für jeden Artikel genaue Angaben bezüglich Menge und Lieferdatum.

Bevor dem Kunden ein Auftrag bestätigt wird, sind mehrere Prüfvorgänge durchzuführen, die allerdings je nach Status und Risikoklasse des Kunden variieren. Viele Artikel können beispielsweise erst ab einer Mindestbestellmenge, eventuell nur von bestimmten Kunden oder Kundengruppen und in der Regel erst ab dem festgelegten Markteinführungsdatum bezogen werden. Für Nachbestellungen saisonal begrenzter Artikel muss deren Verfügbarkeit im Lager überprüft werden, da während der laufenden Saison üblicherweise keine Saisonartikel mehr in Asien nachproduziert werden. Ein wichtiger Prüfschritt ist die Kreditprüfung, die im folgenden Abschnitt im Detail erläutert wird.

7.1.1.2 Kreditprüfung

Mit der Kreditprüfung soll verhindert werden, dass ein Kunde mit Artikeln beliefert wird, die er anschließend nicht bezahlt. Um das Risiko eines Forderungsausfalls zu begrenzen, kann Kunden bestimmter Risikoklassen ein *Kreditlimit* zugeordnet werden, das diese bei ihren Vor- und Nachbestellungen nicht überschreiten dürfen. Das Kreditlimit eines Kunden wird von den Mitarbeitern der Finanzabteilung festgelegt. Diese beurteilen die Kreditwürdigkeit eines Kunden abhängig von verschiedenen Kundenmerkmalen, die über dessen Zahlungsmoral informieren. Wichtigstes Kriterium ist die für jeden Kunden eine Kennzahl, die angibt, wie viele Tage ein Kunde im Schnitt verstreichen lässt, bis er ausstehende Forderungen begleicht. Hier gilt die Regel, dass einem Kunden ein umso höheres Kreditlimit eingeräumt wird, desto schneller er seine Rechnungen begleicht. Auf Basis dieser Kennzahl und anderer Kriterien entscheidet die Finanzabteilung auch über die Risikoklasse, der die Kunden zugeordnet werden. Je nach Risikoklasse wird die Kreditprüfung unterschiedlich oft durchgeführt:

- *Risikoklasse Z01*: Es wird keine Kreditprüfung durchgeführt. In diese Klasse fallen zum Beispiel Warenhausketten oder Versandhandelskunden mit großem Auftragsvolumen.
- *Risikoklasse ZD2*: Eine Kreditprüfung findet nur bei Vorbestellungen statt. Nachbestellungen werden ohne Kreditprüfung bearbeitet.
- *Risikoklasse ZD3*: Eine Kreditprüfung erfolgt für alle Kundenaufträge, also für Vor- und Nachbestellungen.
- *Risikoklasse ZD9*: Mit diesen Kunden wurde die Zusammenarbeit beendet. Es können keine neuen Aufträge mehr erfasst, bestehende Aufträge aber noch abgearbeitet werden.

Bei der Kreditprüfung wird geprüft, ob der vom Kunden in Anspruch genommene *Kreditrahmen* das Kreditlimit überschreitet. Der von einem Kunden in Anspruch genommene Kreditrahmen ist die Summe aus

- dem Wert der abgeschlossenen Bestellungen, deren Artikel an den Kunden bereits ausgeliefert, aber von diesem trotz Rechnungsstellung noch nicht beglichen wurden,
- dem Wert der noch offenen Bestellungen,
 - denen bereits Artikel zugewiesen wurden, oder
 - deren Artikelzuweisung in den nächsten 14 Tagen (gültig für Vorbestellungen) bzw. am nächsten Tag (gültig für Nachbestellungen) erfolgen soll.

Rückt der vom Kunden gewünschte Liefertermin näher, prüft das vorhandene SAP-System automatisch, ob die bestellten Artikel im Lager vorrätig sind. Ist dies der Fall, werden der Bestellung die vorrätigen Artikel fest zugewiesen. Das hat zur Folge, dass die zugewiesenen Artikel keinem anderen Kundenauftrag mehr zugewiesen werden können.

Dem Kunden werden die zugewiesenen Artikel erst dann ausgeliefert, wenn der Kundenauftrag bei der Kreditprüfung nicht gesperrt wurde. Der Vorgang der Kreditprüfung selbst läuft bei Vor- und Nachbestellungen gleich ab. Beide Auftragsarten unterscheiden sich nur darin, wie oft ein Auftrag geprüft wird. Bei der Bearbeitung einer Bestellung wird das Kreditlimit eines Kunden an drei Kontrollpunkten des Kundenauftragsprozesses geprüft:

1. Bei der Erfassung des Kundenauftrags im SAP-System
2. Vor dem Beginn der Artikelzuweisung
3. Vor der Auslieferung der Artikel und der Erstellung der Lieferanweisung

Im Gegensatz zu einer Vorbestellung, bei der zwischen dem ersten und dritten Kontrollpunkt bis zu neun Monate liegen können, sollen die Artikel einer *Nachbestellung* sehr viel schneller ausgeliefert werden. Wenn die Auslieferung innerhalb von 24 Stunden erfolgen soll, liegt eine *Rush Order* vor. Wünscht der Kunde einen späteren Liefertermin, handelt es sich um eine *Standard Order*.

Die Kreditprüfung führt das SAP-System automatisch durch. Geprüft wird, ob der Kunde seinen Kreditrahmen bereits über das ihm zugeteilte Kreditlimit hinaus in Anspruch genommen hat. Ist dies der Fall, wird der Kundenauftrag gesperrt. Doch selbst wenn das Kreditlimit noch nicht erreicht ist, wird der betreffende Kundenauftrag gesperrt, falls nach einer Auftragsfreigabe das Kreditlimit um mehr als 20% überschritten wäre. Wird ein Auftrag bereits bei der Auftrags erfassung gesperrt (Kontrollpunkt eins), kann er trotzdem im SAP-System angelegt werden. Sollte sich die Kreditsituation des Kunden bis zum Zeitpunkt der Artikelzuweisung nicht verbessert haben, verhindert die Sperrung eine Artikelzuweisung. Dasselbe gilt, falls ein Auftrag erst beim zweiten Kontrollpunkt gesperrt wird. Beim dritten Kontrollpunkt verhindert eine Auftragsperrung die Erstellung der Lieferanweisung und somit die Auslieferung der bestellten Artikel.

Entspannt sich die Kreditsituation des Kunden, gibt das SAP-System den gesperrten Auftrag wieder frei. Wurde ein Auftrag gleich beim Auftragsingang gesperrt, kann die automatische Freigabe erst beim zweiten Kontrollpunkt, vor der Artikelzuweisung, erfolgen. Die Kreditsituation eines Kunden entspannt sich, sobald er offene Rechnungsposten begleicht oder einer seiner Aufträge storniert wird, der unter die Berechnungsvorschrift des Kreditrahmens fällt. Ein Auftrag wird storniert, falls der Kundenwunschtermin mehr als 60 Tage überschritten ist.

Neben der automatischen Auftragsfreigabe durch das SAP-System kann ein Auftrag vom Kundenservice auch manuell freigegeben werden. Alle zwei Wochen gehen die Mitarbeiter des Kundenservice die aktuell gesperrten Kundenaufträge durch, um dann entweder autonom oder in Rücksprache mit dem Kunden über eine manuelle Auftragsfreigabe zu entscheiden. Da ein manuell freigegebener Auftrag jeden weiteren Kontrollpunkt ohne Kreditprüfung passiert, kommt diese Ausnahmeregelung nur für solche Kunden infrage, die aus Sicht des Kundenservice trotz negativer Kreditprüfung als zuverlässig und sol-

vent gelten. Hierbei steht es dem Kundenservice offen, welche Kunden er kontaktiert und über die Auftragsperrung informiert. Kann ein Kunde die Bezahlung von noch offenen Rechnungsposten glaubhaft zusichern, besteht die Möglichkeit, diesen Auftrag manuell freizugeben.

Zusammenfassend lässt sich festhalten, dass an der Kreditprüfung drei verschiedene Aufgabenträger beteiligt sind:

- als personeller Aufgabenträger die Mitarbeiter der *Finanzabteilung*, die über die Höhe des Kreditlimits und die Risikoeinstufung eines Kunden entscheiden;
- ebenfalls als personeller Aufgabenträger die Mitarbeiter der *Kundenserviceabteilung*, die die Kundenaufträge erfassen und im Falle einer Auftragsperrung intervenieren können;
- als automatisierter Aufgabenträger das *SAP-System*, das die automatische Kreditprüfung an den jeweiligen Kontrollpunkten durchgeführt.

7.1.2 Untersuchungsziel des Performance-Managements

Ziel des Performance-Managements der Sport AG ist es, ein Kennzahlensystem zu entwickeln, das zum einen über die Zielerreichung des Kundenauftragsprozesses informiert, zum anderen dazu beiträgt, die Zielkonflikte zwischen den an der Kreditprüfung beteiligten Abteilungen auszubalancieren. Diese Zielkonflikte werden im Folgenden kurz erläutert.

Die *Finanzabteilung* ist daran interessiert, die Forderungsausfälle so gering wie möglich zu halten. Entsprechend vorsichtig ordnet sie die Kunden in Risikoklassen ein und limitiert deren Kreditrahmen. Die Mitarbeiter der Finanzabteilung stellen jedoch fest, dass viele Kunden trotz eines überschrittenen Kreditlimits mit Artikeln beliefert werden, weshalb der Verdacht nahe liegt, dass der Kundenservice viele Aufträge manuell freigibt. Die Finanzabteilung wünscht sich mit dem Kennzahlensystem mehr Transparenz darüber, welche Aufträge vom Kundenservice manuell freigegeben werden und ob die Höhe des Kreditlimits adäquat gesetzt ist.

Dass der Verdacht der Finanzabteilung nicht ganz abwegig ist, liegt daran, dass sich der *Kundenservice* primär an der Zufriedenheit der Kunden und weniger an der Vermeidung von Forderungsausfällen ausrichtet. Die Mitarbeiter des Kundenservice sehen in einer zu starken Limitierung des Kreditrahmens die Gefahr unnötiger Umsatzeinbußen. Dies ist der Fall, wenn die Aufträge von an sich

zuverlässigen Kunden aufgrund eines zu niedrigen Kreditlimits gesperrt und schließlich storniert werden. Zudem kann jede Auftragsperrung dazu führen, dass die Nachbestellungen anderer Kunden nicht mehr bedient werden; und zwar dann, wenn die gewünschten Artikel nicht mehr in ausreichender Zahl im Lager vorrätig sind, da sie einem anderen, allerdings gesperrten Auftrag zugewiesen sind. Werden die gesperrten Aufträge schließlich storniert, kann dies gerade am Saisonende zur paradoxen Situation führen, dass die Sport AG trotz einer hohen Nachfrage auf unverkauften Artikeln sitzen bleibt. Diese nicht verkauften Artikel müssen dann am Saisonende mit teils erheblichen Erlösschmälerungen verkauft werden. Diesen Umsatzeinbußen versucht der Kundenservice mit einer manuellen Auftragsfreigabe entgegenzuwirken.

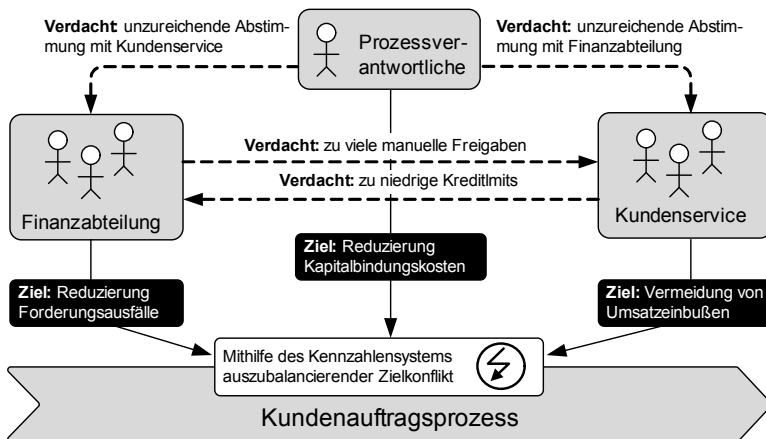


Abbildung 82: Zielkonflikte im Kundenauftragsprozess

Der für den gesamten Kundenauftragsprozess verantwortliche Mitarbeiter befürchtet, dass der Interessenkonflikt zwischen der Kundenservice- und der Finanzabteilung dazu führt, dass ein von der Unternehmensleitung und externen Investoren hoch priorisiertes Ziel bislang nur unzureichend berücksichtigt wird: die Reduzierung des gebundenen Kapitals und der dadurch verursachten Kapitalbindungskosten. Abbildung 82 visualisiert den Ziel- und Interessenkonflikt der an dem Prozess beteiligten Personen und Abteilungen.

Um die Erreichung der konfliktären Prozessziele zunächst messen und ausbalancieren zu können, soll zunächst nur für den Kundenauftragsprozess der zentraleuropäischen Landesgesellschaften ein neues Kennzahlensystem ent-

wickelt werden. Da sowohl der Unternehmensplan, der Kundenauftragsprozess als auch dessen Ressourcen bereits spezifiziert und implementiert waren, lag der Fokus des Projekts auf der Planung des Performance-Measure-Systems (siehe Abschnitt 3.2.2, Abbildung 21). Ziel war es, ein aussagekräftiges Kennzahlensystem mit Früh- und Spätindikatoren zu entwickeln, das es erlaubt, die Performance des Kundenauftragsprozesses effektiv zu steuern und zu kontrollieren. Der folgende Abschnitt zeigt, wie der Analyseprozess das Performance-Management durch eine evidenzbasierte Entwicklung und Überprüfung von Kausalhypothesen unterstützen konnte.

7.2 Durchführung des Analyseprozesses

Im Verlauf des Analyseprozesses wurden alle vier Gestaltungsoptionen angewandt, wobei jeweils zwei Gestaltungsoptionen einen geschlossenen Analysezyklus bildeten. Die Analyse beginnt in Abschnitt 7.2.1 mit der modellzentrierten Entwicklung von Kausalhypothesen. Dieses Kausalmodell wird dann in Abschnitt 7.2.2 mithilfe der datenzentrierten Hypothesenentwicklung um weitere Hypothesen erweitert, bevor im Anschluss die Überprüfung der Kausalhypothesen folgt. Hierbei werden die Hypothesen der modellzentrierten Entwicklung in Abschnitt 7.2.3 auf datenzentriertem Weg, die Hypothesen der datenzentrierten Entwicklung in Abschnitt 7.2.4 modellzentriert überprüft. Abbildung 83 skizziert den Verlauf des Analyseprozesses und seiner beiden Analysezyklen.

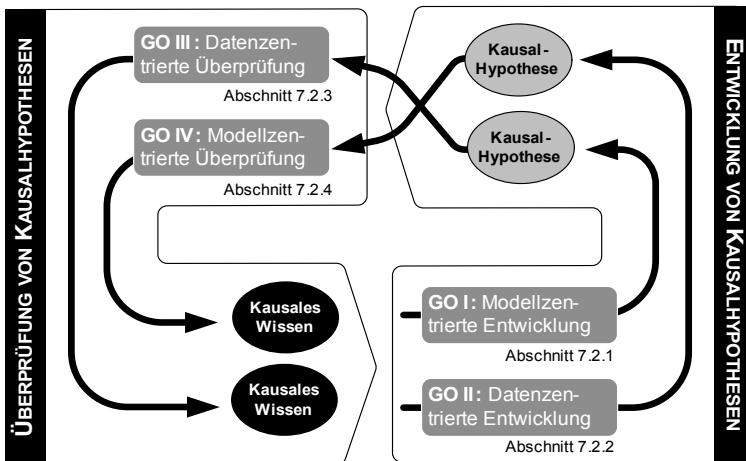


Abbildung 83: Verlauf des Analyseprozesses und seiner Analysezyklen

7.2.1 Modellzentrierte Entwicklung von Kausalhypothesen

Die modellzentrierte Entwicklung von Kausalhypothesen dauerte insgesamt sechs Wochen. Während die Phase der Zieltransformation nur etwa vier Tage in Anspruch nahm, erstreckten sich die Phasen der Modellkonstruktion und Verfahrensanwendung über etwa vier Wochen. Die Phase der Lösungstransformation war nach ca. einer Woche abgeschlossen. Die vier Phasen liefen allerdings nicht streng sequenziell ab. In der Phase der Verfahrensanwendung musste mehrmals in die Phase der Modellkonstruktion zurückgesprungen werden, um dem Objektmodell neue Objekttypen und -beziehungen hinzuzufügen, die dann die kausale Infrastruktur für weitere Kausalhypothesen waren. Die folgenden vier Abschnitte fassen den Verlauf und die Ergebnisse der vier Phasen zusammen.

7.2.1.1 Zieltransformation

Die Phase der Zieltransformation besteht aus zwei Prozessschritten (siehe Abschnitt 6.1.1): der Spezifikation des originären Untersuchungsproblems sowie der Transformation des Untersuchungsziels in ein Modellziel.

Um im *ersten Prozessschritt* das originäre Untersuchungsproblem zu spezifizieren, müssen sowohl das Untersuchungsobjekt als auch das Untersuchungsziel festgelegt werden. Das Untersuchungsobjekt ist der Kundenauftragsprozess, insbesondere die Kreditprüfung (siehe Abschnitt 7.1.1). Wie bereits geschildert, besteht das originäre Untersuchungsziel des Performance-Managements in der Ableitung aussagekräftiger Kennzahlen und der Begründung kausaler Kennzahlbeziehungen (siehe Abschnitt 7.1.2). Da die Kennzahlen den Grad der Zielerreichung messen sollen, bieten sich als Anknüpfungspunkt zur Spezifikation der Ausgangsereignisse die Ziele an, die der Kundenservice, die Finanzabteilung und der Prozessverantwortliche verfolgen (siehe Abbildung 82). Hierbei verständigte man sich darauf, Forderungsausfälle ebenfalls als eine Form von Umsatzeinbußen zu betrachten, weshalb schließlich zwei Ausgangsereignisse formuliert wurden: die Reduzierung von Umsatzeinbußen sowie die Reduzierung der Kapitalbindungskosten.

Ausgehend von diesen beiden Ausgangsereignissen sollen nun die Ursachenereignisse identifiziert werden, die den Grad der zukünftigen Zielerreichung

beeinflussen können und die sich mit einer oder mehreren Kennzahlen abbilden lassen. Somit handelt es sich bei dem Untersuchungsziel der Hypothesenentwicklung um eine Ursachenforschung für zukünftige Ereignisse (siehe Abschnitt 5.1.4.1 und Abbildung 35).

Im *zweiten Prozessschritt* müssen die identifizierten Ausgangsereignisse entsprechend den in Abschnitt 5.2.1.2 eingeführten Ereignisarten charakterisiert und den ereignistragenden Objekttypen zugeordnet werden. Sind die Ereignisträger spezifiziert, ist zuletzt der Objektbereich der Untersuchung festzulegen. Da sowohl die Summe der Umsatzeinbußen als auch die Summe der Kapitalbindungskosten in Euro angegeben werden, handelt es sich um zwei Eigenchaftsereignisse. Die jeweils zugrunde liegenden Objekteigenschaften - die Umsatzeinbußen und die Kapitalbindungskosten - sind Merkmale des Objekttyps KUNDENAUFTRAGSPROZESS, der somit für beide Ausgangsereignisse als Ereignisträger fungiert. Der Objektbereich der Untersuchung wurde mit dem Objekttyp des Kundenauftragsprozesses gleichgesetzt.

7.2.1.2 Modellkonstruktion

In der Phase der Modellkonstruktion ist das Objektmodell der typbezogenen Kausalarchitektur zu erstellen. Im *ersten Prozessschritt* wird versucht, die Ausgangsereignisse zu präzisieren, bevor im *zweiten Prozessschritt* die Modellierung des Objektbereichs folgt (siehe Abschnitt 6.1.2). Da der Berechnung der Kapitalbindungskosten eine Formel zugrunde liegt, lässt sich die Reduzierung der Kapitalbindungskosten durch präzisere Ausgangsereignisse ersetzen. Die Formel zur Berechnung der Kapitalbindungskosten veranschaulicht Tabelle 5 anhand eines fiktiven Rechenbeispiels:

<i>Berechnungsformel für Kapitalbindungskosten</i>		<i>Beispiel</i>
	Kumulierte Bestellsumme aller Kundenaufträge, die im betrachteten Zeitraum gesperrt wurden (€/Zeitraum)	3 000 000 (€/Jahr)
x	Durchschnittliche Dauer einer Auftragsperrung (Tage)	48 (Tage)
x	Kapitalkostensatz (%)	7 (%)
/	Anzahl der Tage im Zeitraum	365 (Tage)
=	durch die Kreditprüfung verursachten Kapitalbindungskosten (€ im Zeitraum)	27 616 (€/Jahr)

Tabelle 5: Beispiel zur Berechnung der Kapitalbindungskosten

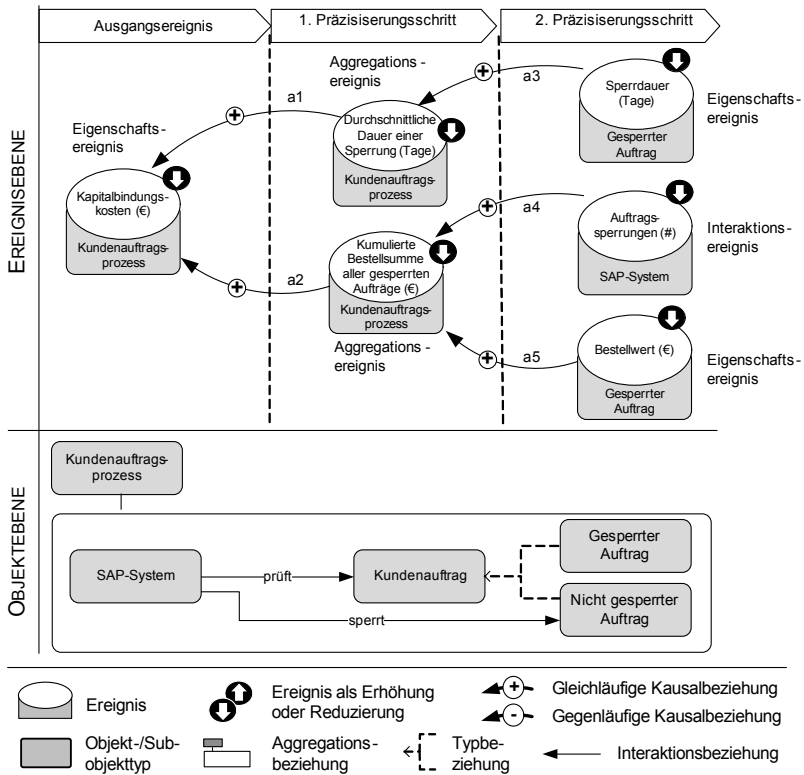


Abbildung 84: Präzisierung des Ausgangsereignisses „Reduzierung der Kapitalbindungskosten“¹

Da der Kapitalkostensatz als gegeben gilt, ergeben sich die von der Kreditprüfung verursachten Kapitalbindungskosten aus der durchschnittlichen Dauer einer Auftragssperrung sowie der kumulierten Bestellsomme aller gesperrten Kundenaufträge. Wenn man von einer Senkung des Kapitalkostensatzes absieht, ist eine Reduzierung der Kapitalbindungskosten nur möglich, wenn sich die durchschnittliche Sperrdauer pro Kundenauftrag verkürzt (siehe Abbildung 84; Hypothese a1) oder die kumulierte Bestellsomme der gesperrten Aufträge sinkt (a2).

¹ In den folgenden Kausalmodellen ist für jeden Ereignistyp in Klammern die Einheit des sich verändernden Objektmerkmals angegeben (z.B. € oder Tage). Das Rautensymbol (#) zeigt bei Beziehungsereignissen an, dass sich die Anzahl der Objektinstanzen oder -beziehungen ändert. Der geschwungene Bindestrich (~) kennzeichnet ein Typwechsellereignis.

Beide Ereignisse dieses ersten Präzisierungsschritts sind Eigenschaftereignisse. Ihr gemeinsamer Ereignisträger ist noch immer der Objekttyp KUNDENAUFTRAGSPROZESS, der sowohl durch die durchschnittliche Sperrdauer als auch durch die kumulierte Bestellsumme aller gesperrten Aufträge charakterisiert wird. Abbildung 84 zeigt jedoch, dass sich beide Ereignisse in einem zweiten Schritt weiter präzisieren lassen.

Im zweiten Präzisierungsschritt gilt für die durchschnittliche Sperrdauer, dass diese ansteigt bzw. sinkt, sobald sich die Sperrdauer eines einzelnen Kundenauftrags verlängert bzw. verkürzt (a3). Ereignisträger ist nun der Objekttyp Kundenauftrag, speziell jedoch der Subobjekttyp gesperrter Auftrag. Da sich die kumulierte Bestellsumme aus den einzelnen Bestellwerten der gesperrten Kundenaufträge ergibt, verringert sich diese Summe, wenn die Anzahl der vom SAP-System durchgeführten Auftragsperrungen zurückgeht (a4) oder der Bestellwert eines einzelnen gesperrten Auftrags sinkt (a5). Letzteres ist der Fall, wenn Bestellpositionen aufgelöst werden. Bei der Bestellwertverringerung handelt es sich um ein Eigenschaftereignis, dessen Ereignisträger ebenfalls der Objekttyp gesperrter Auftrag ist. Da es sich bei der Anzahl der Auftragsperrungen um ein Interaktionsmerkmal handelt, liegt ein Interaktionsereignis vor, dessen Ereignisträger das SAP-System als merkmalsstragender Objekttyp ist. Damit ist die Präzisierung des ersten Ausgangsereignisses abgeschlossen.

Im Gegensatz zum ersten Ausgangsereignis muss beim zweiten Ausgangsereignis, der Reduzierung der Umsatzeinbußen, auf eine Ereignispräzisierung verzichtet werden. Während die Reduzierung der Kapitalbindungskosten anhand der Berechnungsformel eindeutig und vollständig auf präzisere Ereignisse zurückgeführt werden kann, fehlt für die Umsatzeinbußen eine solche Formel.

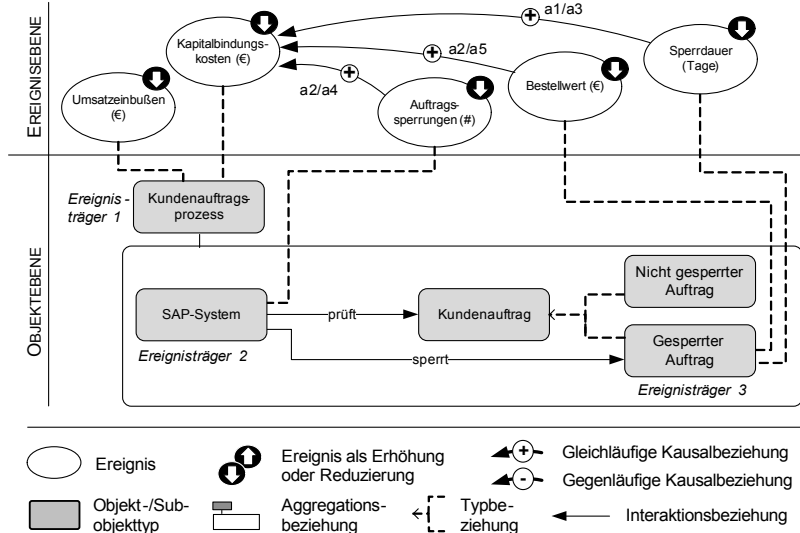


Abbildung 85: Initiales Ereignis- und Objektmodell nach der Ereignispräzisierung

Als Zwischenergebnis lässt sich festhalten, dass das erste Ausgangsereignis, die Reduzierung der Kapitalbindungskosten, vollständig auf drei präzisere Ausgangsereignisse zurückgeführt werden kann, während das zweite Ausgangsereignis unverändert zu übernehmen ist. Abbildung 85 zeigt das initiale Kausal- und Objektmodell, das die Ausgangsbasis für die im zweiten Prozessschritt folgende Modellierung des Objektbereichs bildet. In der Abbildung wurde allerdings auf die Darstellung der Zwischenereignisse aus Abbildung 84 verzichtet und die transitiven Kausalhypothesen zu je einer Hypothese zusammengefasst.

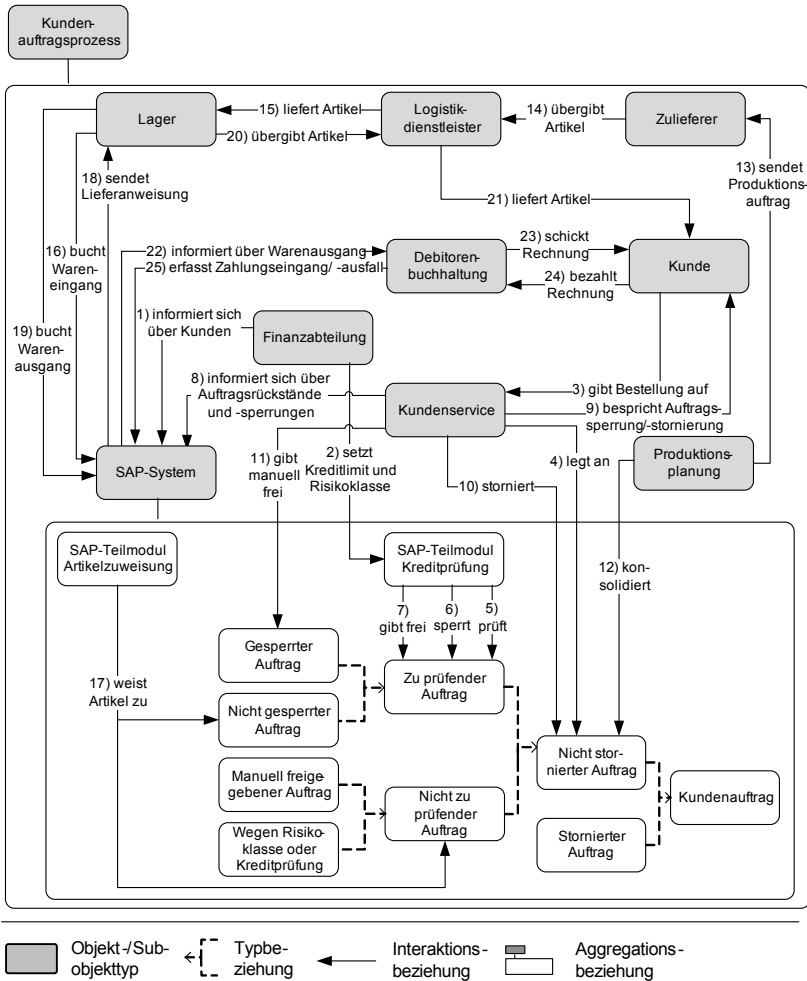


Abbildung 86: Objektmodell des Kundenauftragsprozesses

In Abbildung 85 wird deutlich, dass neben dem ursprünglichen Ereignisträger, dem KUNDENAUFTRAGSPROZESS, zwei weitere Ereignisträger hinzugekommen sind: das SAP-SYSTEM und der GESPERRTE AUFTRAG. Ausgehend von diesen drei Objekttypen wurden im zweiten Prozessschritt auf Basis von Objektbeziehungen diejenigen Objekttypen identifiziert, die mit einem der Ereignisträger direkt

oder indirekt in Beziehung stehen und deshalb als Träger eines Ursacheneignisses infrage kommen. Abbildung 86 zeigt, um welche Objektbeziehungen und Objekttypen das initiale Objektmodell aus Abbildung 85 erweitert wurde.

In einem ersten Schritt informiert sich die FINANZABTEILUNG im SAP-SYSTEM über die Kunden und deren Zahlungsverhalten (siehe Abbildung 86: 1), bevor sie ihnen im SAP-TEILMODUL DER KREDITPRÜFUNG ein Kreditlimit und eine Risikoklasse zuordnet (2). Sobald ein KUNDE beim KUNDENSERVICE eine Bestellung aufgibt (3), legt der KUNDENSERVICE einen NICHT STORNIERTEN AUFTRAG an - sofern es die Risikoklasse des Kunden zulässt (4). Passiert der Kundenauftrag im weiteren Prozessverlauf einen der drei Kontrollpunkte, prüft das SAP-TEILMODUL DER KREDITPRÜFUNG den ZU PRÜFENDEN AUFTRAG (5). Je nach Prüfergebnis sperrt das SAP-TEILMODUL DER KREDITPRÜFUNG den ZU PRÜFENDEN AUFTRAG (6) oder gibt diesen wieder frei (7). Alle zwei Wochen informiert sich der KUNDENSERVICE im SAP-SYSTEM über Auftragsrückstände und Auftragsperrungen (8). Ein Auftragsrückstand liegt vor, sobald der Kundenwunschtermin eines Auftrags überschritten ist, da dem Auftrag nicht alle Artikel zugewiesen werden konnten. Abhängig vom Auftragswert und dem Kundenstatus informiert der KUNDENSERVICE den KUNDEN über die Sperrung bzw. den Auftragsrückstand und bespricht mit ihm das weitere Vorgehen (9). Hier gilt die Regel, dass der KUNDENSERVICE den NICHT STORNIERTEN AUFTRAG storniert (10), falls dieser 60 oder mehr Tage nach dem Kundenwunschtermin noch immer auf eine Freigabe oder eine Artikelzuweisung wartet. Speziell für einen GESPERRTEN AUFTRAG besteht die Möglichkeit, dass der KUNDENSERVICE diesen manuell freigibt (11).

Nachdem der Zeitraum der Vorbestellungen verstrichen ist, beginnt die Abteilung der PRODUKTIONSPLANUNG mit der Konsolidierung der NICHT STORNIERTEN AUFTRAG (12). Das bedeutet, dass die Bestellpositionen der Kundenaufträge je nach Artikel zu verschiedenen Produktionsaufträgen zusammengefasst werden, die dann an die ZULIEFERER gesendet werden (13). Diese übergeben die produzierten Artikel einem LOGISTIKDIENSTLEISTER (14), der diese dann an das LAGER liefert (15). Treffen die Waren im Lager ein, bucht das LAGER den Wareneingang im SAP-SYSTEM (16).

Liegt der Kundenwunschtermin innerhalb der nächsten 14 Tage (gültig für Vorbestellungen) bzw. ist er am nächsten Tag (gültig für Nachbestellungen), versucht das SAP-TEILMODUL DER KREDITPRÜFUNG einem NICHT GESPERRTEN bzw. einem NICHT ZU PRÜFENDEN AUFTRAG Artikel zuzuweisen (17). Sobald einem Kundenauftrag alle bestellten Artikel zugewiesen sind, sendet das SAP-SYSTEM dem LAGER die Lieferanweisung (18), das daraufhin im SAP-SYSTEM den Ware-

nausgang bucht (19) und dem LOGISTIKDIENSTLEISTER die Artikel übergibt (20). Während der LOGISTIKDIENSTLEISTER die Artikel an den KUNDEN ausliefert (21), informiert das SAP-SYSTEM die DEBITORENBUCHHALTUNG über den Warenausgang (22), woraufhin dem KUNDEN die Rechnung zugestellt wird (23), die dieser schließlich bezahlt (24). Ob und wann ein Kunde eine Rechnung bezahlt, erfasst die DEBITORENBUCHHALTUNG im SAP-SYSTEM (25). Die FINANZABTEILUNG kann diese Informationen wieder zur Aktualisierung der Risikoklasse und des Kreditlimits verwenden (2).

Die Konstruktion des Modellsystems ist damit abgeschlossen. Das Objektmodell kann nun in der Phase der Verfahrensanwendung zur Entwicklung neuer Kausalhypothesen genutzt werden.

7.2.1.3 Verfahrensanwendung

Die Verfahrensanwendung gliedert sich in zwei Prozessschritte: die Ableitung von Kausalhypothesen sowie deren Plausibilisierung (siehe Abschnitt 6.1.3).

Um im *ersten Prozessschritt* die Suche nach geeigneten Ursachenobjekttypen zu erleichtern, ist zu prüfen, ob sich die Ereignisträger der Ausgangsereignisse durch einen anderen Objekttyp ersetzen lassen, der dem Objektmodell bei der Modellkonstruktion hinzugefügt wurde. Dies ist bei dem Ereignis „Reduzierung der Auftragssperrungen“ der Fall: Der ursprüngliche Ereignisträger, das SAP-SYSTEM, wurde disaggregiert und der Teilobjekttyp SAP-TEILMODUL DER KREDITPRÜFUNG hinzugefügt. Da jetzt nicht mehr das SAP-SYSTEM, sondern das SAP-TEILMODUL DER KREDITPRÜFUNG die Auftragssperrungen durchführt (siehe Abbildung 86: 6), lässt sich die Reduzierung der Auftragssperrungen diesem Teilobjekttyp zuordnen. Für die Suche nach Ursachenobjekttypen bedeutet das, dass man diese nicht mehr vom aggregierten Objekttyp SAP-SYSTEM, sondern von dessen Teilobjekttyp aus beginnt. Dasselbe gilt für das Ausgangsereignis Reduzierung der Umsatzeinbußen: Die eingebüßten Umsätze können dem Objekttyp DEBITORENBUCHHALTUNG zugerechnet werden, da dort die Zahlungseingänge und -ausfälle erfasst werden (25).

Im Folgenden wird gezeigt, welche Kausalhypothesen sich für welches der insgesamt vier Ausgangsereignisse (siehe Abbildung 85) aus dem Objektmodell ableiten lassen. Um die Komplexität der Darstellung zu reduzieren, wird das resultierende Kausalmodell in insgesamt vier Teilmodellsysteme aufgeteilt. Während in Teilmodellsystem a die unmittelbaren Ursachen für die Reduzierung der Kapitalbindungskosten abgebildet sind, fassen die Teilmodellsysteme b und c die

weiter entfernt liegenden Ursachenereignisse zusammen. Teilmodellsystem d verfolgt die unmittelbaren Ursachen für das zweite Ausgangsereignis, die Reduzierung der Umsatzeinbußen. Die in Teilmodellsystem d enthaltene Kausalstränge sind ebenfalls mit den Ursachenereignissen der drei anderen Teilmodellsysteme verbunden. Abbildung 87 skizziert den Zusammenhang zwischen den vier Teilmodellsystemen.

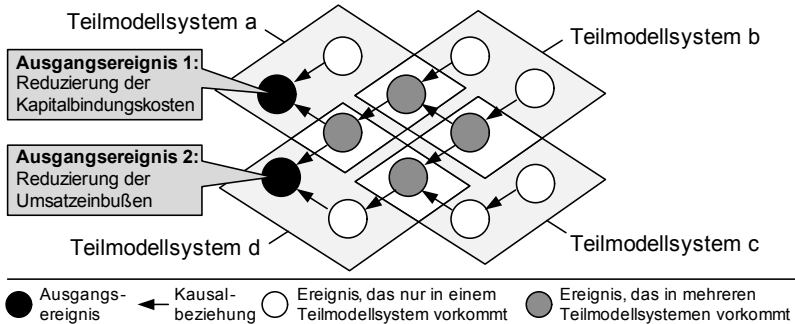


Abbildung 87: Zusammenhang der Teilmodellsysteme

Um Kausalhypothesen von Interaktionsbeziehungen unterscheiden zu können, werden Kausalhypothesen im Folgenden mit dem Kleinbuchstaben ihres Teilmodellsystems sowie einer fortlaufenden Ziffer bezeichnet. Die Interaktionsbeziehungen des Objektmodells werden hingegen weiterhin nur mit Ziffern gekennzeichnet, die sich auf Abbildung 86 beziehen.

Ausgangspunkt des Teilmodellsystems a (siehe Abbildung 88) sind die drei Ereignisse, die das Ausgangsereignis „Reduzierung der Kapitalbindungskosten“ präzisieren (siehe Abbildung 84). Da eine Auftragssperrung nur dann möglich ist, wenn das SAP-TEILMODUL DER KREDITPRÜFUNG eine solche Kreditprüfung durchführt (5), kann sich die Zahl der Auftragssperrungen bereits dann verringern, wenn auch die Zahl der Kreditprüfungen sinkt (siehe Abbildung 88: a6). Folgt man im Objektmodell der Interaktionsbeziehung der Kreditprüfung (5), stößt man auf den Objekttyp ZU PRÜFENDER AUFTRAG. Die Anzahl der Kreditprüfungen sinkt, wenn sich die Anzahl der zu prüfenden Aufträge verringert. Diesem Ereignis liegt ein Aggregationsmerkmal zugrunde, das dem SAP-SYSTEM als aggregierten Objekttyp zugeordnet ist (a7). Da ein Auftrag erst dann gesperrt wird, wenn das Kreditlimit eines Kunden überschritten ist, verringert sich die Zahl der Auftragssperrungen auch dann, wenn sich die überschrittene Kreditsumme im SAP-SYSTEM verringert (a8).

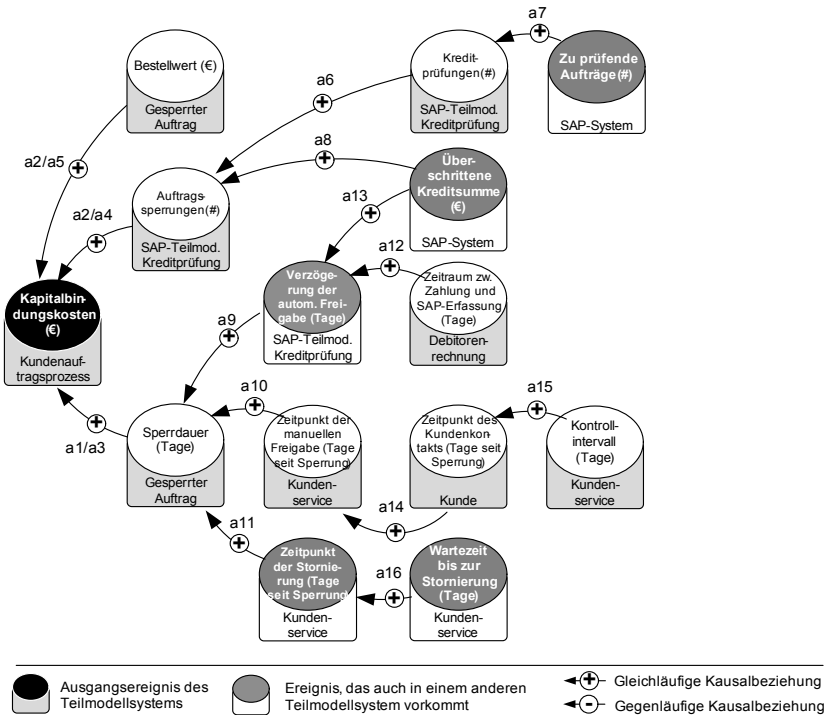


Abbildung 88: Kausalhypothesen zur Reduzierung der Kapitalbindungskosten (Teilmodellsystem a)

Da der Bestellwert eines angelegten Auftrags in der Regel unverändert bleibt, wurden für das zweite Ausgangsereignis, die Reduzierung des Bestellwerts, keine Kausalhypothesen aus dem Objektmodell abgeleitet. Für das dritte Ausgangsereignis, die Reduzierung der Sperrdauer, können hingegen mehrere Kausalstränge aus dem Objektmodell gewonnen werden. Den insgesamt drei Kausalsträngen liegen die Interaktionsbeziehungen zugrunde, die vom ereignistragenden Objekttyp GESPERRTER AUFTRAG oder einem Sub- bzw. Superobjekttyp ausgehen. Die Sperrdauer wird umso geringer sein, desto früher ein GESPERRTER AUFTRAG

- automatisch freigegeben (a9, 7),
- manuell freigegeben (a10, 11) oder

- storniert wird (a11, 10).

Die *automatische Auftragsfreigabe* erfolgt umso eher, je weniger Zeit die DEBITORENBUCHHALTUNG nach der Rechnungsbegleichung (24) bis zur Erfassung des Zahlungseingangs im SAP-SYSTEM (25) verstreichen lässt (a12). Der Zeitpunkt der Auftragsfreigabe hängt darüber hinaus von der überschrittenen Kreditsumme ab, die der aggregierte Objekttyp, das SAP-SYSTEM, für die Kunden der gesperrten Aufträge ausweist. Die Kausalhypothese lautet: Je mehr das Kreditlimit überschritten ist, desto später wird ein Auftrag automatisch freigegeben (a13). Der Kunde muss dann eine höhere Rechnungssumme begleichen, damit sich seine Kreditsituation wieder entspannt.

Die zweite Möglichkeit, die Sperrdauer zu verkürzen, ist die Beschleunigung der *manuellen Auftragsfreigabe* durch den KUNDENSERVICE (a10). Da der KUNDENSERVICE den GESPERRTEN AUFTRAG in der Regel erst dann manuell freigibt (11), wenn der KUNDE die Bezahlung seiner ausstehenden Rechnungsposten glaubhaft versichert (9), hängt der Zeitpunkt der Auftragsfreigabe vom Zeitpunkt dieses Kundenkontakts ab (a14). Der KUNDE kann umso früher kontaktiert werden, je kleiner das Intervall ist (a15), in dem der KUNDENSERVICE die gesperrten Aufträge kontrolliert (8).

Als Drittes verkürzt sich die Sperrdauer eines Auftrags, wenn *früher storniert* wird, sich also der Zeitpunkt der Stornierung nach vorne verschiebt (a11). Der Stornierungszeitpunkt hängt unmittelbar von der Zeitspanne ab, die der KUNDENSERVICE nach der Überschreitung des Kundenwuschtermins noch bis zur Auftragsstornierung wartet (a16). Im aktuellen Kundenauftragsprozess ist diese Zeitspanne einheitlich auf 60 Tage festgelegt (siehe Abschnitt 7.1.1.2).

Anknüpfungspunkt für das Teilmodellssystem b (siehe Abbildung 89) ist das Ausgangsereignis „Reduzierung der zu prüfenden Aufträge“. Ausgehend von den Teilobjekttypen des Ereignisträgers SAP-SYSTEM gelangt man über zwei Interaktionsbeziehungen zu den Objekttypen KUNDENSERVICE (4) und FINANZABTEILUNG (2). Beide Objekttypen kommen für die Reduzierung der zu prüfenden Aufträge als Ursachenobjekttypen infrage. Denn im SAP-System ist die Zahl der zu prüfenden Kundenaufträge umso geringer,

- desto mehr GESPERRTE AUFTRÄGE der KUNDENSERVICE manuell freigibt (11), da diese ohne weitere Kreditprüfung bearbeitet werden (b1)
- desto mehr NICHT STORNIERTE AUFTRÄGE der KUNDENSERVICE storniert (b2, 10)
- desto weniger ZU PRÜFENDE AUFTRÄGE der KUNDENSERVICE anlegt (b3, 4)

- desto weniger Kunden von der FINANZABTEILUNG in eine Risikoklasse mit Kreditprüfung eingestuft werden (b4, 2).

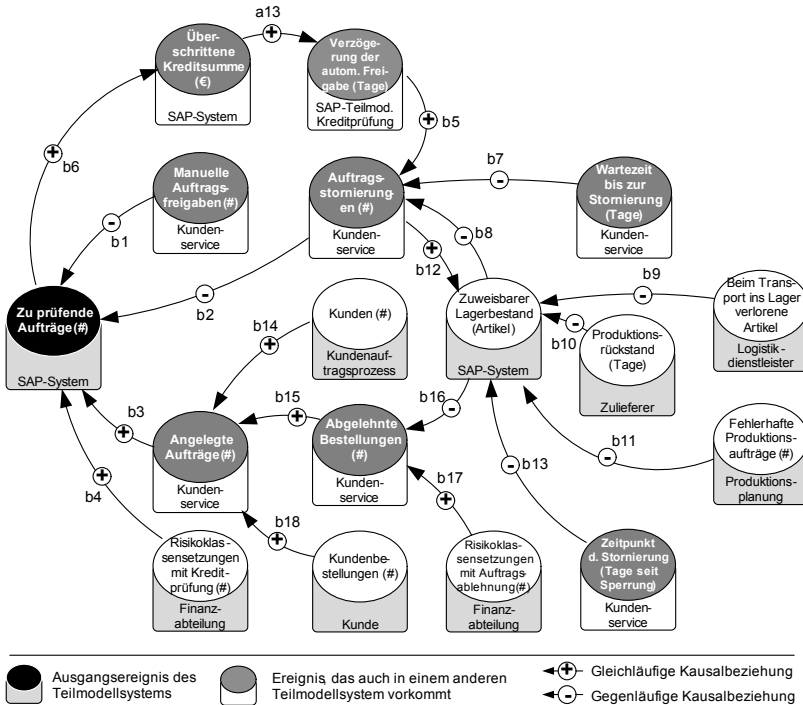


Abbildung 89: Kausalhypothesen zur Reduzierung der zu prüfenden Kundenaufträge (Teilmodellsystem b)

Damit ein GESPERRTER AUFTRAG vom SAP-TEILMODUL DER KREDITPRÜFUNG automatisch freigegeben wird, muss das gewährte Kreditlimit wieder unterschritten werden. Da ein KUNDE hierfür offene Rechnungen zu begleichen hat, wird der Zeitpunkt der automatischen Auftragsfreigabe umso später sein, desto höher die überschrittene Kreditsumme ist (siehe Abbildung 89: a13). Denn je mehr das Kreditlimit eines KUNDEN überschritten ist, desto mehr Rechnungen muss er begleichen, damit sein GESPERRTER AUFTRAG vom SAP-TEILMODUL DER KREDITPRÜFUNG wieder freigegeben wird (7). Schafft es ein Kunde nicht, eine ausreichende Zahl offener Rechnungen innerhalb der gesetzten 60-Tage-Frist zu begleichen, storniert der KUNDENSERVICE seinen Auftrag (10). Je mehr sich daher beim SAP-TEILMODUL DER KREDITPRÜFUNG die automatische Auftragsfreigabe verzögert,

desto näher rückt das Ende dieser 60-Tage-Frist und eine Auftragsstornierung wird wahrscheinlicher (b5). Die Höhe der überschrittenen Kreditsumme hängt wiederum davon ab, wie viele Kundenaufträge der KUNDENSERVICE anlegt (4) und wie viele Aufträge sich daraufhin als ZU PRÜFENDE AUFTRÄGE im SAP-SYSTEM befinden (b6).

Neben der überschrittenen Kreditsumme wird die Anzahl der Auftragsstornierungen auch von der Zeit beeinflusst, die einem Kunden zum Ausgleichen seines überschrittenen Kreditlimits gewährt wird, bevor man seinen Auftrag storniert. Daher ist anzunehmen, dass sich die Anzahl der Auftragsstornierungen reduziert, wenn sich die Wartezeit von 60 Tagen verkürzt (b7). Es wird dann weniger Kunden gelingen eine Auftragsperrung rechtzeitig zu verhindern, indem sie eine ausreichende Zahl an offenen Rechnungen begleichen (24).

Die Anzahl der Auftragsstornierungen nimmt jedoch auch dann zu, wenn der zuweisbare Lagerbestand im SAP-SYSTEM so gering ist, dass das SAP-TEILMODUL DER ARTIKELZUWEISUNG nicht allen Aufträgen Artikel zuweisen kann (17). Je höher der dadurch verursachte Auftragsrückstand ist, desto wahrscheinlicher ist es, dass ein Auftrag 60 Tage nach dem Kundenwunschtermin immer noch auf die Artikelzuweisung wartet und schließlich die Anzahl der Auftragsstornierungen steigt (b8). Der zuweisbare Lagerbestand sinkt wiederum, wenn der LOGISTIKDIENSTLEISTER nicht ausreichend Artikel anliefert (15) und das LAGER deshalb weniger Wareneingänge im SAP-SYSTEM bucht (16). Eine Ursache hierfür könnte sein, dass dem Dienstleister beim Transport ins Lager Artikel verloren gehen (b9). Alternativ kommt auch der ZULIEFERER als Ursachenobjekttyp infrage, falls dieser in Produktionsrückstand gerät (b10). Da der ZULIEFERER seinen Produktionsauftrag von der PRODUKTIONSPLANUNG erhält (13), lässt sich eine zu geringe Produktions-, Liefer- und Lagermenge womöglich auch mit fehlerhaften Produktionsaufträgen erklären (b11). Der zuweisbare Lagerbestand erhöht sich, wenn mehr Aufträge storniert werden (b12) oder diese Stornierungen früher erfolgen (b13). Denn sobald ein gesperrter Auftrag storniert wird, dem bereits Artikel zugewiesen wurden, lassen sich dessen Artikel wieder anderen Aufträgen zuweisen, wodurch der zuweisbare Lagerbestand steigt.

Dass der KUNDENSERVICE weniger Aufträge anlegt (4) und sich dadurch die Anzahl der zu prüfenden Aufträge reduziert (b3), kann auf drei Ursachen zurückgeführt werden. Zunächst erreicht man vom Objekttyp KUNDENSERVICE über die Aggregationsbeziehung den aggregierten Objekttyp KUNDENAUFTRAGS-PROZESS. Verringert sich dort die Anzahl der KUNDEN, stehen weniger Kunden als potenzielle Auftraggeber zur Verfügung, weshalb sich infolgedessen beim KUN-

DENSERVICE die Anzahl der angelegten Aufträge verringern kann (b14). Als weiterer Ursachenobjekttyp kommt jedoch auch der Objekttyp KUNDENSERVICE infrage, falls dieser vermehrt Aufträge ablehnt (b15). Handelt es sich um eine Nachbestellung, die der Kunde während der Verkaufssaison aufgibt, kann auch ein zu geringer zuweisbarer Lagerbestand zu einer Bestellablehnung führen (b16). Der KUNDENSERVICE muss eine Kundenbestellung dann ablehnen, wenn das SAP-SYSTEM das Anlegen eines neuen Auftrags aufgrund der Risikoeinstufung des Kunden verhindert. Je mehr Kunden deshalb die FINANZABTEILUNG in eine Risikoklasse einstuft (2), die eine Auftragsanlage verhindert, desto mehr Bestellungen muss der Kundenservice ablehnen (b17). Als dritter Ursachenobjekttyp kommt der Objekttyp KUNDE infrage, denn auch er kann schlicht die Zahl seiner Bestellungen reduzieren (b18).

Ausgangspunkt des Teilmodellsystems c (siehe Abbildung 90) ist die Höhe der überschrittenen Kreditsumme, die das SAP-SYSTEM ausweist. Diese Summe reduziert sich, wenn die FINANZABTEILUNG das Kreditlimit erhöht (c2, 2) oder wenn sich die Summe der offenen Rechnungen verringert, weil ein KUNDE seine offenen Rechnungen bezahlt (c2, 24). Die Summe der offenen Kundenrechnungen sinkt, sobald die KUNDEN weniger Zahlungsziel in Anspruch nehmen (c3). Wenn ihr Kreditlimit steigt, können sie mehr Aufträge platzieren, die später als fakturierte Aufträge die Summe der offenen Rechnungen erhöhen (c4).

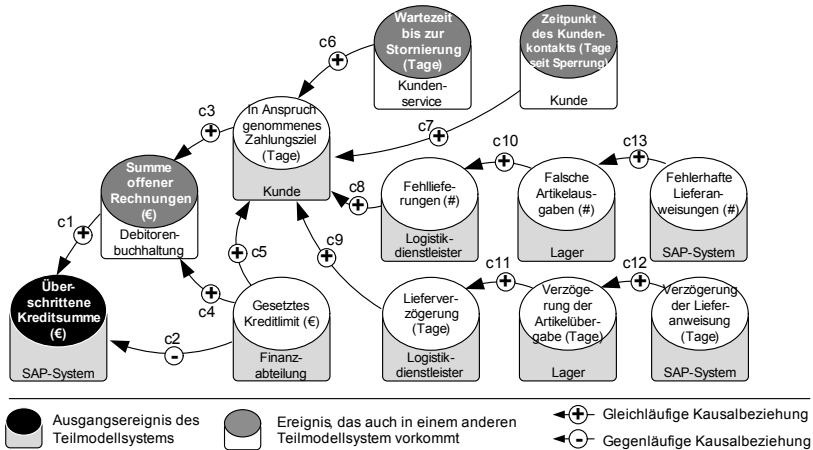


Abbildung 90: Kausalhypothesen zur Reduzierung der überschrittenen Kreditsumme (Teilmodellsystem c)

Wie lange ein KUNDE mit der Bezahlung einer Rechnung wartet, hängt zum einen von der Höhe des gesetzten Kreditlimits (c5, 2), zum anderen auch von der Wartezeit bis zur Stornierung ab (c6, 10). Denn ein wichtiger Grund, weshalb ein KUNDE seine Rechnungen vor Ablauf des Zahlungsziels begleichen sollte, besteht darin, dass er damit die drohende Sperrung und Stornierung eines noch nicht durchgeführten Auftrags verhindern kann. Würde die FINANZABTEILUNG ein höheres Kreditlimit setzen (2), würde sich dieser Anreiz zur frühzeitigen Rechnungsbegleichung reduzieren, da seltener Aufträge gesperrt und storniert würden. Die beiden Kausalbeziehungen c5 und c6 setzen jedoch voraus, dass der KUNDE sowohl über die Höhe des Kreditlimits als auch über die Wartezeit bis zur Stornierung informiert ist. Diese Information erhält er spätestens dann, wenn ihn der KUNDENSERVICE über kontaktiert und über durchgeführte Auftragssperrungen und drohende Stornierungen informiert (9). Je früher dann ein KUNDE von einer drohenden Auftragssperrung erfährt, desto eher kann er auf die Inanspruchnahme seines vollen Zahlungsziels verzichten und seine offenen Rechnungen noch vor Ablauf der Zahlungsfrist begleichen (c7).

Neben dem KUNDENSERVICE steht auch der LOGISTIKDIENSTLEISTER mit dem Objekttyp KUNDE in einer direkten Interaktionsbeziehung. Inwieweit der KUNDE sein Zahlungsziel ausschöpft oder sogar überschreitet, hängt auch davon ab, ob und wann ihm der LOGISTIKDIENSTLEISTER die bestellten Artikel liefert (21). Kommt es zu einer Fehllieferung (c8) oder einer Lieferverzögerung (c9), wird ein betroffener KUNDE vermutlich mit der Begleichung der bereits gestellten Rechnungen warten - zumindest so lange, bis die Artikel wie bestellt eingetroffen sind.

Da der LOGISTIKDIENSTLEISTER die Artikel vom LAGER bekommt (20), lassen sich die Ereignisse Fehllieferung und Lieferverzögerung möglicherweise auf ein Lagerereignis zurückführen, zum Beispiel darauf, dass dem LOGISTIKDIENSTLEISTER die falschen Artikel übergeben wurden (c10) oder dass sich im LAGER die Artikelausgabe verzögert hat (c11). Da das LAGER die Artikel gemäß der Lieferanweisung versendet, die das SAP-SYSTEM ausstellt (19), lässt sich über diese Interaktionsbeziehung auch das SAP-SYSTEM als Ursachenobjekttyp identifizieren, falls eine verzögerte (c12) oder fehlerhafte Lieferanweisung (c13) abgesetzt wird.

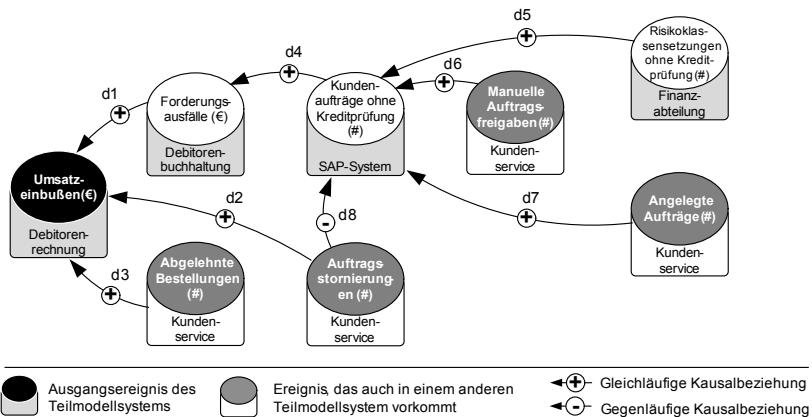


Abbildung 91: Kausalhypothese zur Reduzierung der Umsatzeinbußen (Teilmodell-system d)

Das Teilmodell-system d (siehe Abbildung 91) zeigt die Ursachen für das zweite Ausgangsereignis: die Reduzierung der Umsatzeinbußen (siehe Abbildung 85). Wie bereits weiter oben erwähnt, fungiert nicht mehr der Objekttyp KUNDENAUFTRAGSPROZESS, sondern die DEBITORENBUCHHALTUNG als Ereignisträger. Verfolgt man von dort den Prozess anhand der Interaktionsbeziehungen zurück, lassen sich drei Kausalstränge für entgangene Umsätze identifizieren:

- Eine Kunde bezahlt eine von der DEBITORENBUCHHALTUNG gestellte Rechnung nicht (23), obwohl sein Auftrag ausgeführt wurde (d1).
- Der Kundenauftrag wurde weder durchgeführt noch fakturiert, da der KUNDENSERVICE den Auftrag vorher storniert hat (d2, 10).
- Es wurde im SAP-SYSTEM kein Auftrag angelegt (4), da der Kundenservice die Bestellung eines Kunden (3) abgelehnt hat (d3).

Beim Ursachenereignis des ersten Kausalstrangs (d1) handelt es sich um ein Interaktionsereignis, das einen Forderungsausfall beschreibt und sich auf die Interaktion zwischen der DEBITORENBUCHHALTUNG und dem KUNDEN bezieht. Das Interaktionsmerkmal ist die Summe der fakturierten aber vom KUNDEN nicht beglichene Rechnungen. Im Gegensatz zu den beiden anderen Kausalsträngen kann dies zu 100% als Umsatzeinbuße verrechnet werden. Stornierte Aufträge (d2) und abgelehnte Bestellungen (d3) lassen sich nur dann als entgangener Umsatz werten, falls die betroffenen Kunden ihre Rechnungen bezahlt hätten,

wenn ihre Aufträge angenommen und durchgeführt worden wären. Wurde ein Auftrag aber abgelehnt oder storniert, lässt sich dies nicht mehr überprüfen. Obwohl man die aus solchen (Fehl-)Entscheidungen resultierenden Umsatzeinbußen nicht quantifizieren kann, wird mit beiden Kausalhypothesen unterstellt, dass sich die Umsatzeinbußen proportional mit der Anzahl der stornierten Aufträge (d2) und abgelehnten Bestellungen (d3) verringert.

Die Forderungsausfälle ließen sich reduzieren, wenn sich die Anzahl derjenigen Aufträge verringert, die ohne Kreditprüfung bearbeitet werden (d4). Da für diese Aufträge keine automatisierte Kreditprüfung durchgeführt wird, können sich Zahlungsrückstände zunächst unbegrenzt anhäufen. Als Ursachenobjekttyp für eine Verringerung der Aufträge ohne Kreditprüfung kommt sowohl die FINANZABTEILUNG als auch der KUNDENSERVICE infrage: die FINANZABTEILUNG, indem sie die Kunden in eine Risikoklasse ohne Kreditprüfung einstuft (d5, 2), der KUNDENSERVICE, indem er Aufträge manuell freigibt (d6, 11), weniger Aufträge anlegt (d7, 4) bzw. mehr Aufträge storniert (d8, 10).

Obwohl sich die Kausalstränge mithilfe des Objektmodells vereinzelt noch weiter zurückverfolgen ließen, wurde die Phase der Verfahrensanwendung an dieser Stelle beendet. Die Unsicherheit der abgeleiteten Kausalhypothesen nimmt letztlich zu, je weiter man sich bei der Hypothesenformulierung vom Ausgangsereignis und dessen Ereignisträger entfernt. Statt weitere Hypothesen zu formulieren, sollen nun die bereits vorhanden Hypothesen in der Phase der Lösungstransformation bewertet werden.

7.2.1.4 Lösungstransformation

In dieser Phase wurden die abgeleiteten Kausalhypothesen zusammen mit ihren zugrunde liegenden Objektbeziehungen auf ihre Verständlichkeit, Neuheit, Gültigkeit und Nützlichkeit geprüft (siehe Abschnitt 6.1.4).

Hinsichtlich der *Neuheit* gab es erwartungsgemäß Unterschiede zwischen den drei Abteilungen, da die Mitarbeiter der Finanzabteilung mit dem operativen Ablauf des Kundenauftragsprozesses nicht in dem Maße vertraut waren, wie es bei den Mitarbeitern des Kundenservice der Fall war. Für die Mitarbeiter der Finanzabteilung und des Kundenservice war der Neuigkeitswert meist bei den Kausalhypothesen am größten, die als Bindeglied zwischen zwei Kausalsträngen fungieren, zwischen denen man bislang keinen Zusammenhang gesehen hatte. So war zum Beispiel bekannt, dass die Sperrdauer eines Auftrags vom Zeitpunkt abhängt, zu dem dieser automatisch bzw. manuell freigegeben wird (siehe

Abbildung 92: a9, a10). Auch wusste man, dass der Zeitpunkt der automatischen Freigabe von der Höhe der überschrittenen Kreditsumme (a13) beeinflusst wird, die wiederum von der Summe der unbezahlten Rechnungen abhängt (c1). Neu war hingegen, dass sowohl das vom Kunden in Anspruch genommene Zahlungsziel (c7) als auch der Zeitpunkt der manuellen Auftragsfreigabe (a14) ein *gemeinsames* Ursachenereignis besitzen: den Zeitpunkt des Kundenkontakts.

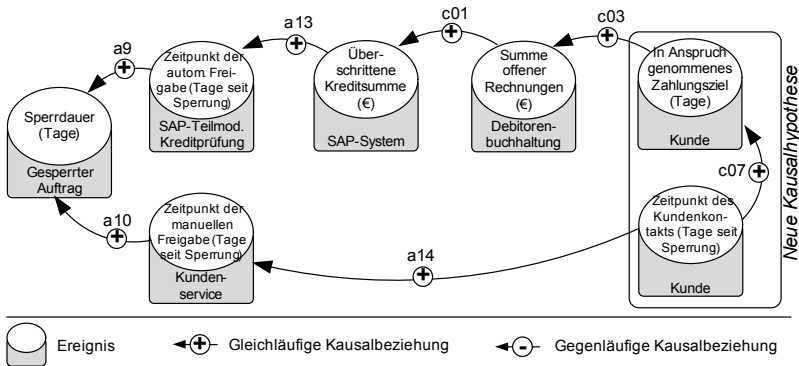


Abbildung 92: Neue Kausalhypothese als Bindeglied zwischen zwei Kausalsträngen

Ebenfalls neu war die Aussage, dass eine Erhöhung des Kreditlimits drei unterschiedliche, miteinander verwobene Wirkungen hervorrufen kann (siehe Abbildung 93):

- die *erste Wirkung*, wonach sich nach einer Erhöhung des Kreditlimits die überschrittene Kreditsumme reduziert (c2), da sich die überschrittene Kreditsumme aus der Differenz zum gewährten Kreditlimit errechnet (siehe Abschnitt 7.1.1.2);
- die *zweite Wirkung*, wonach eine Erhöhung des Kreditlimits auch die Summe der offenen Rechnungsposten (c4) und somit das überschrittene Kreditlimit (c1) erhöhen kann, da nun mehr Aufträge aufgegeben und ohne Sperrung bedient werden können;
- die *dritte Wirkung*, wonach bei einer Erhöhung des Kreditlimits die offene Rechnungssumme steigt (c3), da der Kunde nun einen geringeren Anreiz hat, seine Rechnungen vor Ablauf des Zahlungsziels zu begleichen (c5), weil ihm aufgrund seines erhöhten Kreditlimits erst später eine Auftrags-sperrung bzw. -stornierung droht (siehe Abschnitt 7.1.1.2).

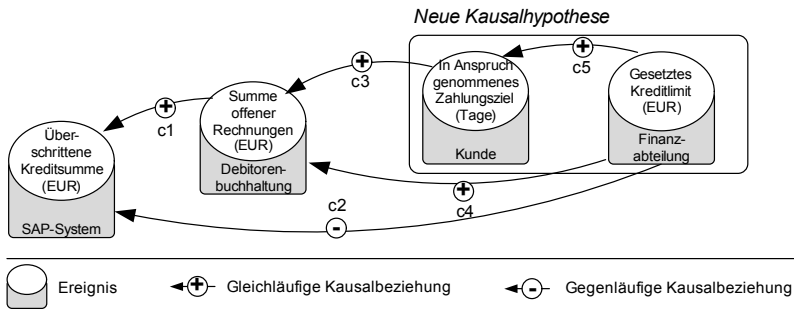


Abbildung 93: Neue Kausalhypothese bezüglich der Höhe des gesetzten Kreditlimits

Eine weitere neue Erkenntnis war, dass sich bei einer Reduzierung der Wartezeit bis zur Stornierung nur kurzfristig die Anzahl der Auftragsstornierungen erhöht (siehe Abbildung 94: b7). Denn indem der KUNDENSERVICE einem Kunden weniger Zeit gewährt, eine Auftragsstornierung mit der Bezahlung offener Rechnungen abzuwenden, ist der Kunde bei zukünftigen Aufträgen dazu angehalten, sein zur Verfügung stehendes Zahlungsziel nicht voll auszuschöpfen (c6). Dieser zweite Effekt wirkt eher mittelfristig, sorgt jedoch dafür, dass sich die Zahl der Auftragsstornierungen wieder reduziert (c3, c1, b5).

Obwohl es keine neue Erkenntnis war, dass sich mit einer Reduzierung der Wartezeit die Sperrdauer verkürzen lässt (a17, a11), war vor allem der Finanzabteilung nicht bewusst, dass sich diese Wirkung über zwei unterschiedliche Kausalstränge entfalten kann, die auf unterschiedlichen Infrastrukturbeziehungen beruhen: Zum einen kommt der Effekt zustande, weil sich der Zeitpunkt der Stornierung durch die verkürzte Wartezeit nach vorne verschiebt (a11), zum anderen, weil ein Kunde aufgrund der geringeren Wartezeit gezwungen ist, seine Rechnungen früher zu bezahlen, was schließlich dazu führt, dass das SAP-TEILMODUL DER KREDITPRÜFUNG seinen Auftrag schneller freigeben kann (a9).

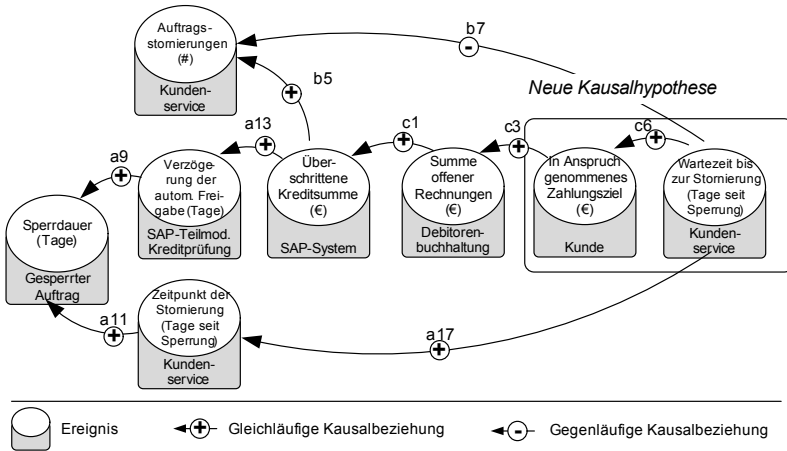


Abbildung 94: Neue Kausalhypothese bezüglich der Wartezeit bis zur Stornierung

Die beiden Kausalhypothesen c5 und c6 (siehe Abbildung 95) waren für die Mitarbeiter des Performance-Managements und der Finanzabteilung zunächst unverständlich: Warum sollte das vom KUNDEN in Anspruch genommene Zahlungsziel von der Höhe des Kreditlimits und der Wartezeit bis zur Stornierung abhängen? Was den Mitarbeitern an Information fehlte, war das Detailwissen über die kausale Infrastruktur, insbesondere darüber, dass der KUNDENSERVICE den KUNDEN kontaktiert und mit ihm die Auftragsperrungen bzw. -stornierungen bespricht (9). Die Mitarbeiter konnten den Ursache-Wirkungs-Zusammenhang erst dann nachvollziehen, als sie erfuhren, dass der Kunde im Verlauf dieser Besprechung auch die Höhe seines gewährten Kreditlimits (9.1) sowie den voraussichtlichen Zeitpunkt der Stornierung (9.2) erfährt. Denn nur auf Basis dieser Information kann der Kunde zukünftig eine Auftragsperrung oder -stornierung vermeiden, indem er sein zur Verfügung stehendes Zahlungsziel nicht mehr voll ausschöpft. Abbildung 95 zeigt, wie den Mitarbeitern die Kausalhypothesen c5 und c6 plausibilisiert werden konnten, indem in die Phase der Modellkonstruktion zurückgesprungen und die neuen Infrastrukturbeziehungen 9.1 und 9.2 eingefügt wurden.

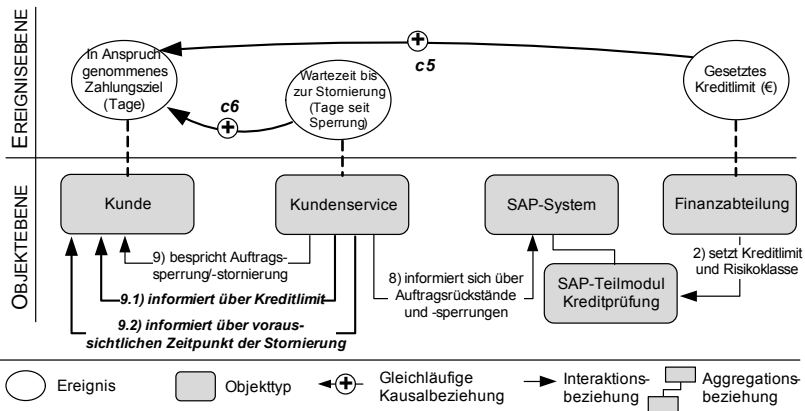


Abbildung 95: Präzisierung von Kausalhypothesen durch das Einfügen neuer Infrastrukturbeziehungen

Um über die *Nützlichkeit* der Kausalhypothesen zu entscheiden, muss die Erklärungskraft und der Handlungsspielraum der Kausalhypothesen beurteilt werden, den sie dem Performance-Management bei der Problemlösung und Zielerreichung verschaffen (siehe Abschnitt 6.1.4).

Hinsichtlich der *Erklärungskraft* ist zu beurteilen, wie wahrscheinlich es ist, dass das Ursacheneignis tatsächlich eintritt und wie stark dessen Einfluss auf das Wirkungsobjekt im Vergleich zu alternativen Ursacheneignissen ist. Eine geringe Erklärungskraft wurde der Kausalhypothese zugesprochen, die besagt, dass der zuweisbare Lagerbestand sinkt, wenn dem LOGISTIKDIENSTLEISTER beim Transport zum Lager Artikel verloren gehen könnten (b9, 15). Dasselbe gilt für die Kausalhypothese a12: Es wurde als unwahrscheinlich angesehen, dass sich der Zeitpunkt der automatischen Auftragsfreigabe verzögert, weil die DEBITORENBUCHHALTUNG den Zahlungseingang der Kunden im SAP-SYSTEM zu spät erfasst (a12, 25).

Auch dass ein KUNDE mehr Zahlungsziel in Anspruch nimmt, lässt sich nach Ansicht des Kundenservice nur in Ausnahmefällen mit einer Lieferverzögerung (c9) oder Fehllieferung (c8) seitens des LOGISTIKDIENSTLEISTERS erklären - beide Ereignisse treten nur sehr selten auf. Dasselbe gilt auch für die Ereignisse, mit denen eine Lieferverzögerung oder Fehllieferung begründet wurde (c10, c11, c12, c13).

Nachdem sämtliche Kausalhypothesen mit geringer Erklärungskraft aus dem Kausalmodell entfernt wurden, musste der *Handlungsspielraum* beurteilt werden. Die verbleibenden Kausalhypothesen können nur dann als nützlich erachtet werden, wenn sich ihre Ereignisse entweder zur Ableitung von Kennzahlen oder zur Begründung kausaler Kennzahlbeziehungen eignen. Für den ersten Punkt, die Ableitung von Kennzahlen, ist es notwendig, dass für das jeweilige Ursachenereignis entsprechende Ereignisdaten vorliegen. Falls die Ereignisdaten nicht vorliegen, müssen sie sich mit einem vertretbaren Aufwand erheben lassen. Die folgenden Ursachenereignisse schieden aufgrund mangelnder Datenverfügbarkeit als Basis für neue Kennzahlen aus: Veränderungen

- der Anzahl der vom Kundenservice abgelehnten Bestellungen (d3)
- der Höhe der Produktionsrückstände bei den Zulieferern (b10)
- der Anzahl der fehlerhaften Produktionsaufträge (b11)
- des Zeitpunkts des Kundenkontakts (a14, c7).

Obwohl sich für diese Ereignisse mangels Datenverfügbarkeit keine Kennzahlen erheben lassen, können ihre Kausalbeziehungen dennoch kausale Kennzahlbeziehungen begründen. Dies ist der Fall, wenn es sich bei den Ursachenereignissen um Zwischenereignisse einer transitiven Kausalbeziehung handelt, für deren Ursachen- und Wirkungereignis sich wiederum eine oder mehrere Kennzahlen erfassen lassen.

Abbildung 96 zeigt exemplarisch, weshalb die Kausalhypothese b18 als unnützlich, die Hypothesen b15, b17 hingegen als nützlich einzustufen sind. Obwohl sich die Anzahl der abgelehnten Bestellungen nicht quantifizieren lässt, ist man davon ausgegangen, dass die Anzahl der vom Kundenservice angelegten Aufträge sinkt (b15), wenn die Anzahl der Risikoklassensetzungen mit Auftragsablehnung steigt (b17). Im Gegensatz dazu lassen sich mit den Kausalhypothesen b10, b11, b18 und d3 keine kausalen Kennzahlbeziehungen begründen, da sie im Kausalmodell weder als Zwischenereignis vorliegen noch als Basisereignis einer Kennzahl infrage kommen.

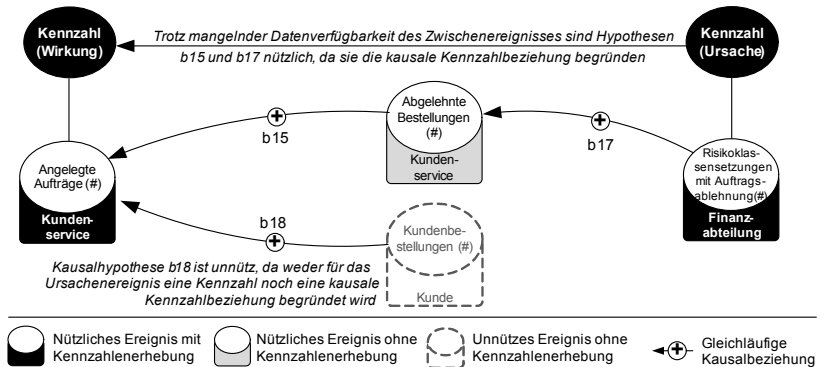


Abbildung 96: Handlungsspielraum zur Kennzahlenbildung und Begründung kausaler Kennzahlenbeziehungen als Kriterium für die Nützlichkeit

Mit der Lösungstransformation ist nun die modellzentrierte Entwicklung von Kausalhypothesen abgeschlossen. Bevor diese Hypothesen datenzentriert überprüft wurden, sind weitere Kausalhypothesen entwickelt worden - und zwar auf datenzentriertem Wege.

7.2.2 Datenzentrierte Entwicklung von Kausalhypothesen

Mit insgesamt fast drei Monaten erstreckte sich die datenzentrierte Entwicklung von Kausalhypothesen über einen sehr viel längeren Zeitraum als die modellzentrierte Hypothesenentwicklung. Dies war vor allem der Phase der Modellkonstruktion geschuldet, in der die benötigten Daten beschafft und aufbereitet wurden. Während an der modellzentrierten Hypothesenentwicklung allein die Mitarbeiter des Kundenservice und der Finanzabteilung mitwirkten, wurden nun zusätzlich Mitarbeiter der IT-Abteilung sowie zwei externe Berater hinzugezogen. Deren Aufgabe war es, die für die Datenanalyse benötigten Daten aus dem SAP-System zu extrahieren und für die Datenanalyse aufzubereiten.

7.2.2.1 Zieltransformation

Der *erste Prozessschritt* besteht in der Spezifikation des originären Untersuchungsproblems, das mithilfe der Kausalhypothesen gelöst werden soll. Im *zweiten Prozessschritt* ist das Untersuchungsziel in ein Modellziel zu transformieren, das angibt, welches Analyseergebnis man sich von der Datenanalyse verspricht.

Analog zur modellzentrierten Hypothesenentwicklung besteht das Untersuchungsobjekt nach wie vor aus dem Kundenauftragsprozess. Auch das Ziel bleibt dasselbe: die Entwicklung eines Kennzahlensystems für das Performance-Management, dessen Kennzahlen und Kennzahlbeziehungen sich auf Basis von Kausalbeziehungen begründen lassen (siehe Abschnitt 7.2.1.1).

Da die Datenanalyse nach der modellzentrierten Hypothesenentwicklung durchgeführt wurde, konnte das Ausgangsereignis aus dem bereits vorhandenen Kausalmodell ausgewählt werden. Im Fokus der Datenanalyse stand das Interaktionsereignis der Auftragsstornierung. Dieses Ereignis nimmt im Kausalmodell eine zentrale Stellung ein, da es sich auf beide Prozessziele gleichermaßen auswirkt: auf die Reduzierung der Kapitalbindungskosten sowie auf die Reduzierung der Umsatzeinbußen. Allerdings beschreibt das Kausalmodell bislang nur unzureichend, wie sich Auftragsstornierungen auf die Höhe der Umsatzeinbußen auswirken. Abbildung 97 fasst die Ursachen und Auswirkungen von Auftragsstornierungen zusammen.

Aus dem Kausalmodell der modellzentrierten Hypothesenentwicklung geht hervor, dass eine Auftragsstornierung die Umsatzeinbußen einerseits *erhöhen*, andererseits aber auch *verringern* kann (siehe Abbildung 97: A). Eine Erhöhung der Umsatzeinbußen liegt vor, wenn der Kunde den stornierten Auftrag eigentlich bezahlt hätte (d2). Verringert werden die Umsatzeinbußen, falls sich durch Stornierungen die Aufträge ohne Kreditprüfung verringern (d8) und es dadurch zu weniger Forderungsausfällen kommt (d4, d1). Der Beitrag einer Auftragsstornierung zur Reduzierung der Umsatzeinbußen ist somit uneindeutig. Das bedeutet, dass eine Kennzahl, die pauschal die Anzahl *aller* Auftragsstornierungen erfasst, nicht sinnvoll im Hinblick auf die Zielerreichung interpretiert werden kann. Eine solche Kennzahl ließe keine eindeutige Aussage über die Entwicklung der Umsatzeinbußen und die Performance des Kundenauftragsprozesses zu. Ein Untersuchungsziel der datenzentrierten Hypothesenentwicklung ist es daher, die bestehenden Kausalhypothesen zu differenzieren und zu zeigen, unter welchen Umständen eine Auftragsstornierung die Umsatzeinbußen erhöht und wann sie diese reduziert.

A) Auswirkungen auf Umsatzeinbußen:

Die Stornierung eines Auftrags kann zu einer Erhöhung oder Verringerung der Umsatzeinbußen führen

B) Kausaler Zusammenhang zwischen Auftragsstornierungen:

Die Stornierung von Aufträgen kann die Stornierung anderer Aufträge verhindern

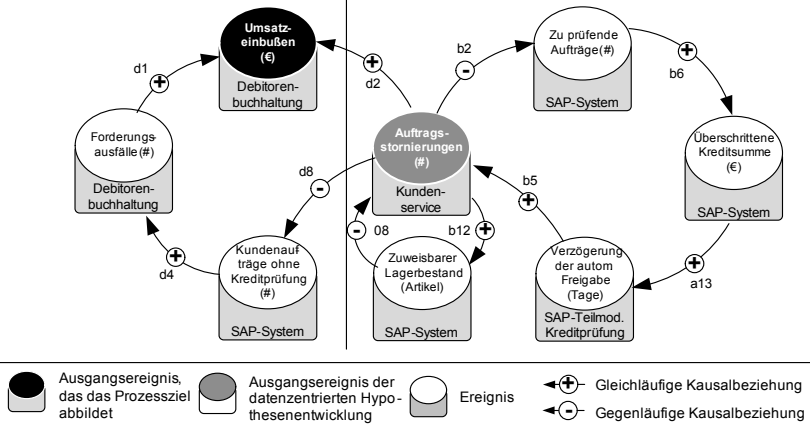


Abbildung 97: Ursachen und Wirkungen von Auftragsstornierungen

Das zweite Untersuchungsziel bezieht sich auf den kausalen Zusammenhang *zwischen* den Auftragsstornierungen (siehe Abbildung 97: B). Laut Kausalmodell kann eine Auftragsstornierung die Stornierung eines anderen Auftrags verhindern. Diese Rückkopplung lässt sich entlang zweier Kausalstränge verfolgen: Erstens wenn bestimmte Artikel aufgrund einer Stornierung ihre Auftragszuweisung verlieren und sich deshalb der zuweisbare Lagerbestand erhöht (b12). Dadurch wird möglicherweise verhindert, dass ein anderer Auftrag aufgrund zu geringer Lagerbestände storniert oder abgelehnt werden muss (b8). Zweitens kann eine Auftragsstornierung die überschrittene Kreditsumme eines Kunden so weit verringern, dass ein gesperrter Auftrag *desselben Kunden* automatisch freigegeben wird und dadurch einer drohenden Stornierung entgeht (b5). Das zweite Ziel der Datenanalyse besteht deshalb darin, differenzierte Kausalhypothesen über die kausalen Wechselwirkungen zwischen den Auftragsstornierungen zu entwickeln. Man möchte wissen, welche Art von Auftragsstornierung die Stornierung anderer Aufträge verhindert.

Beide Zielsetzungen sind im *zweiten Prozessschritt* in konkrete Modellziele für die Datenanalyse zu transformieren. In beiden Fällen geht es darum, ein differenziertes Kausalverständnis zu entwickeln. Hierzu sollen zunächst verschiedene Stornierungsarten anhand ihrer typischen Merkmalsausprägungen abge-

grenzt werden, um anschließend das differenzierte Ereignisvokabular zur Formulierung neuer Kausalhypothesen zu nutzen. Zu diesem Zweck wird im Folgenden die Beziehung zwischen dem Ausgangsereignis der Auftragsstornierung und dem ereignistragenden Objekttyp, dem KUNDENSERVICE, analysiert. Abbildung 98 illustriert exemplarisch die angestrebte Analyse der Ereignis-Objekt-Beziehung.

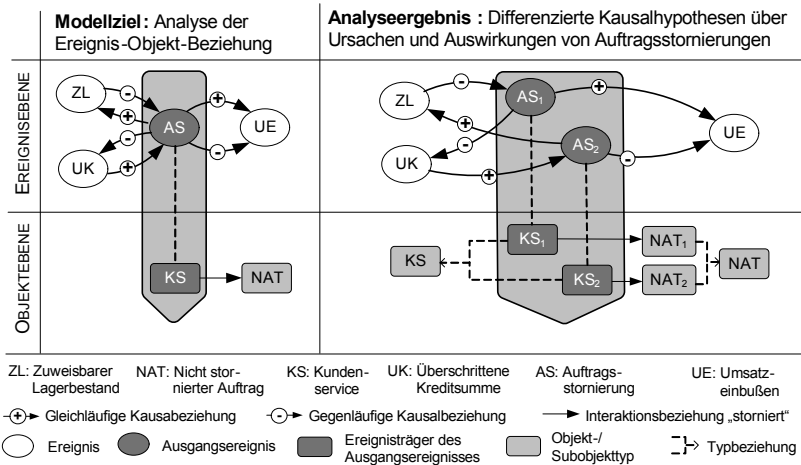


Abbildung 98: Modellziel und beispielhaftes Analyseergebnis der datenzentrierten Entwicklung von Kausalhypothesen

Wie in Abbildung 98 skizziert, soll der Ereignistyp der Auftragsstornierung (AS) so in der Objektebene verortet werden, dass er nicht mehr dem generalisierten Objekttyp KUNDENSERVICE (KS) allein zugeordnet ist. Stattdessen sollen für den Objekttyp KUNDENSERVICE Subjekttypen gebildet werden (KS_1 , KS_2), die dann auf der Ereignisebene verschiedene Arten von Auftragsstornierungen begründen (AS_1 , AS_2). Um den Objekttyp KUNDENSERVICE anhand von Subjekttypen zu differenzieren, lassen sich sowohl die originären Merkmale des Objekttyps Kundenservice als auch die abgeleiteten Merkmale anderer Objekttypen verwenden (siehe Abschnitt 5.2.1.1, Abbildung 42). In Abbildung 98 beruht die Bildung der Subjekttypen KS_1 und KS_2 zum Beispiel auf einem abgeleiteten Merkmal, das vom interagierenden Objekttyp NICHT STORNIERTER AUFTRAG stammt. Dort wurde es als originäres Merkmal zur Bildung der beiden Subjekttypen NAT_1 und NAT_2 verwendet.

Die analytische Fragestellung lautet daher: Mit welchen Ausprägungen der eigenen oder abgeleiteten Objektmerkmale storniert der Kundenservice typischerweise einen Auftrag? Auf Basis dieses differenzierten Ereignis- und Objektvokabulars sollen dann auf der Ereignisebene neue Kausalhypothesen gebildet werden. Welche originären und abgeleiteten Merkmale des Kundenservice analysiert wurden, ist in der nächsten Phase festzulegen: der Modellkonstruktion.

7.2.2.2 Modellkonstruktion

Die Phase der Modellkonstruktion unterteilt sich in zwei Prozessschritte: in die Selektion der Analysedaten sowie deren Exploration und Manipulation (siehe Abschnitt 6.2.2).

Aufgabe der *Datenselektion* ist es, zunächst die Merkmale - das sind die Spalten der Datentabelle - festzulegen, damit sich anschließend die Menge der Datensätze - das sind die Zeilen der Datentabelle - anhand von Filterkriterien eingrenzen lässt. Da eine Analyse von Ereignis-Objekt-Beziehungen durchzuführen ist, werden auf einen Zeitpunkt bezogene Ereignis- und Objektdaten benötigt (siehe Abschnitt 6.2.3, Tabelle 2). Bei der Auswahl der Objekt- und Ereignismerkmale konnte auf das Objektmodell der modellzentrierten Hypothesenentwicklung zurückgegriffen werden (siehe Abbildung 86). Obwohl der Rückgriff auf das Objektmodell ein Beispiel für eine verschachtelte Anwendung der Gestaltungsoptionen ist (siehe Abschnitt 6.5.2), kommt dieser Synergieeffekt auch bei einer sequenziellen Anwendung der Gestaltungsoptionen zum Tragen. Tabelle 6 fasst die aus dem Objektmodell abgeleiteten Merkmale zusammen. Wie diese aus dem Objektmodell abgeleitet wurden, wird im Folgenden skizziert.

Analysemerkmal	Beispiel für Merkmalsausprägung	Objekt- (OT)/Ereignistyp (ET)	Skala	Beschreibt...
1) Landgesellschaft	D, PL, AT, SL, HU, CZ, CH, SK	Kundenservice (OT)	nominal	Objekteigenschaft
2) Auftragsnummer	13498232	Kundenauftrag (OT)	nominal	Objekteigenschaft
3) Auftragswert	2300 EUR	Kundenauftrag (OT)	metrisch	Objekteigenschaft
4) Kundenwunschtermin	28.04.05	Kundenauftrag (OT)	metrisch	Objekteigenschaft
5) Auftragsyp	Standard-, Rush- oder Future-Order	Kundenauftrag (OT)	nominal	Objekteigenschaft
6-8) Auftragsstatus nach 1./2./3. Kreditprüfung	A (autom. freigegeben), B (gesperrt), C (storniert), D (manuell freigegeben)	Kundenauftrag (OT)	nominal	Objekteigenschaft
9) Auftragsendstatus	A, B, C, D (siehe oben)	Kundenauftrag (OT)	nominal	Objekteigenschaft
10) Statussequenz der Auftragsbearbeitung	A, ABA, ABC, ABCA	Autom. Freigabe (ET), Manuelle Freigabe (ET), Auftragsperrung (ET), Auftragsstornierung (ET)	nominal	Ereigniseintritt
11) Stornierungsart	L (Lager), K (Kreditlimit)	Auftragsstornierung (ET)	nominal	Ereigniseintritt
12) Auftragsanlagendatum	05.02.05	Auftragsanlage (ET)	metrisch	Ereigniszeitpunkt
13-15) Beginn der 1./2./3. Kreditprüfung	08.04.08	Kreditprüfung (ET)	metrisch	Ereigniszeitpunkt
16-18) Sperrdauer bei 1./2./3. Kreditprüfung	6 Tage	Kreditprüfung (ET)	metrisch	Ereignisdauer
19) Gesamtsperrdauer	32 Tage	Kreditprüfung (ET)	metrisch	Ereignisdauer
20-21) Zeitpunkt und Dauer der Art. Zuweisung	21.03.05, 3,5 Tage	Artikelzuweisung (ET)	metrisch	Ereigniszeitpunkt, Ereignisdauer
22) Stornierungsdatum	12.04.05	Auftragsstornierung (ET)	metrisch	Ereigniszeitpunkt
23) Kundenrisikoklasse	Z01, ZD2, ZD3, ZD9	Kunde (OT)	nominal	Objekteigenschaft
24) Kundennummer	23122345	Kunde (OT)	nominal	Objekteigenschaft
25-33) Kreditrahmen, Kreditlimit und Kreditlimitüberschreitung bei 1./2./3. Prüfung	1400 EUR, 1200 EUR, 15%	Kunde (OT)	metrisch	Objekteigenschaft

Tabelle 6: Analysemerkmale der datenzentrierten Entwicklung von Kausalhypothesen

Beim Ausgangsereignis der Auftragsstornierung handelt es sich um ein Interaktionsereignis, an dem neben dem ereignistragenden Objekttyp KUNDENSERVICE

auch der Objekttyp NICHT STORNIERTER AUFTRAG beteiligt ist (siehe Abbildung 86: 10). Die Instanzen des Objekttyps KUNDENSERVICE lassen sich zum Beispiel durch ein originäres Merkmal beschreiben, das angibt, welcher Landesgesellschaft der jeweilige Kundenservice angehört (siehe Tabelle 6: Analysemerkmal 1). Da das Fallstudienprojekt im Geschäftsbereich der zentraleuropäischen Landesgesellschaften angesiedelt war, gehört eine Kundenservice-Abteilung entweder zur Landesgesellschaft Deutschland (D), Österreich (AT), Schweiz (CH), Polen (PL), Tschechien (CZ), Slowakei (SK), Ungarn (HU) oder Slowenien (SL).

Um einen NICHT STORNIERTEN AUFTRAG zu beschreiben, können sämtliche Objektmerkmale des Superobjekttyps KUNDENAUFTRAG verwendet werden. Hierzu zählen etwa die originären Eigenschaftsmerkmale Auftragsnummer (2)¹, Auftragswert (3), Kundenwunschtermin (4) sowie der Auftragstyp (5). Letzterer gibt an, ob eine Vor- oder Nachbestellung vorliegt. Steigt man vom Objekttyp KUNDENAUFTRAG über die Typbeziehung eine oder mehrere Typebenen tiefer, geben die Subobjekttypen Hinweise auf weitere Merkmale zur Typunterscheidung. So wurde zum Beispiel das Eigenschaftsmerkmal Auftragsstatus gebildet, das anzeigt, ob eine Objektinstanz vom Typ KUNDENAUFTRAG zu einem bestimmten Zeitpunkt gesperrt (Status B), storniert (Status C) oder automatisch (Status A) bzw. manuell freigegeben ist (Status D). Um den Auftragsstatus zu verschiedenen Zeitpunkten wiedergeben zu können, wurden vier Merkmale gebildet: Der Auftragsstatus nach Ende der ersten (6), zweiten (7) und dritten (8) Kreditprüfung sowie der Status nach Ende des Kundenauftragsprozesses (9).

Auf Basis von Interaktionsbeziehungen wurden Ereignismerkmale gebildet: Abhängig davon, welchem Subobjekttyp eine Auftragsinstanz angehört, kann dieser gesperrt oder automatisch bzw. manuell freigegeben werden. Den Eintritt dieser verschiedenen Interaktionsereignisse zeigt das Merkmal Statussequenz (10) an. Eine Statussequenz gibt wieder, von welchen dieser Status verändernden Ereignissen ein Auftrag im Prozessverlauf betroffen war. Die Statussequenz ABAC sagt beispielsweise aus, dass vier Ereignisse eingetreten sind: eine Auftragsperrung (Übergang von A nach B), eine automatische Auftragsfreigabe (Übergang von B nach C) sowie als letztes Ereignis die Stornierung des Auftrags (Übergang von A nach C).

Hinsichtlich des Ausgangsereignisses - der Auftragsstornierung - benötigt man zusätzlich ein Ereignismerkmal, das angibt, welches Stornierungsereignis eingetreten ist: eine Stornierung aufgrund zu geringer Lagerbestände oder eine

¹ Die Ziffern verweisen im Folgenden die Analysemerkmale in Tabelle 6.

Stornierung wegen eines überschrittenen Kreditlimits. Dies zeigt das Merkmal Stornierungsart (11) an.

Weiterhin lassen sich anhand von Merkmalen der Zeitpunkt und die Dauer eines Interaktionsereignisses abbilden, so zum Beispiel das Datum der Auftragsanlage durch den Kundenservice (12). In Bezug auf die Kreditprüfung war man sich einig, dass sowohl der Beginn und das Ende als auch die Dauer der Prüfung von Interesse sein könnten. Wird ein Auftrag gesperrt, entspricht die Dauer der Kreditprüfung der Zeitspanne bis zum nächsten Statuswechsel - wenn der Auftrag entweder storniert oder automatisch bzw. manuell freigegeben wird. Erfolgt keine Sperrung, ist die Dauer der Kreditprüfung gleich null. Daher wurde sowohl der Beginn der drei Kreditprüfungen (13-15) als auch die daraus resultierende Sperrdauer (16-18) als je eigenes Merkmal aufgenommen. Des Weiteren wurde auch die Gesamtsperrdauer (19) berücksichtigt, die sich aus der Summe der einzelnen Prüfungsdauern errechnet. Da sich nicht nur die Kreditprüfung, sondern auch die Zuweisung von Artikeln über einen Zeitraum von mehreren Tagen oder Wochen erstrecken kann, lassen sich auch für die Artikelzuweisung die Merkmale Zeitpunkt und Dauer definieren (20-21). Im Gegensatz dazu ist die Auftragsstornierung ein punktuell Ereignis ohne Dauer, weshalb sich nur das Ereignismerkmal Stornierungsdatum (22) angeben lässt.

Verlässt man die beiden an einer Auftragsstornierung beteiligten Objekttypen KUNDENSERVICE und KUNDENAUFTRAG, gelangt man über die Aggregations- und Interaktionsbeziehungen des Objektmodells zu anderen Objekttypen. Über den Objekttyp SAP-SYSTEM gelangt man zur FINANZABTEILUNG, die die Risikoklasse (23) des Kunden festlegt. Instanzen des Objekttyps KUNDE werden durch ihre Kundennummer (24) eindeutig identifiziert. Die Kundennummer lässt sich wiederum im Zuge der Fremdtypisierung zur Zuordnung eines Auftrags zu einem Kunden nutzen. Ob ein Auftrag bei der Kreditprüfung gesperrt oder automatisch freigegeben wird, hängt vom Kreditlimit des Kunden sowie seinem zum Zeitpunkt der Kreditprüfung ausgeschöpften Kreditrahmen ab. Entscheidend für eine Sperrung ist, ob bzw. wie weit das Kreditlimit überschritten ist. Daher wurden für die erste, zweite und dritte Kreditprüfung der ausgeschöpften Kreditrahmen, das Kreditlimit sowie die prozentuale Kreditlimitüberschreitung als weitere Merkmale spezifiziert (25-33).


Nach der Festlegung der Analysemerkmale können diese als Nächstes dazu genutzt werden, die Menge der Datensätze einzuschränken. Da die laufende Saison Herbst/Winter 2005 noch nicht abgeschlossen war, konzentrierte man sich auf die bereits zurückliegende Saison Frühjahr/Sommer 2005. Die Saison Früh-

jahr/Sommer beginnt jeweils am 1. September des Vorjahres, da die Kunden ab diesem Zeitpunkt mit der Vorbestellung von Artikeln beginnen können. Vorbestellungen können jedoch nur bis 20 Tage vor dem eigentlichen Saisonstart, dem 1. Januar, abgegeben werden. In der Zeit vom 1. Januar bis 30. Juni können dann die Kunden, die bereits eine Vorbestellung aufgegeben haben, weitere Nachbestellungen aufgeben. Der spätestmögliche Kundenwuschtermin für eine Nachbestellung ist jedoch der 30. Juni. Da ein gesperrter Auftrag spätestens 60 Tage nach dem Kundenwuschtermin storniert wird, sind am 30. August alle Aufträge der Saison Frühjahr/Sommer abgearbeitet. Der Analysezeitraum erstreckte sich somit vom 1. September 2004 bis 30. August 2005 und entspricht somit exakt dem Zeitraum der Kundenauftragsbearbeitung für die Frühjahr/Sommer-Kollektion 2005.


Neben dieser zeitlichen Einschränkung wurde auch das Merkmal „Auftragsendstatus“ (siehe Tabelle 6: Analysemerkmal 9) als weiteres Selektionskriterium verwendet. Da die Auftragsstornierungen im Fokus der Analyse stehen, wurden die Analysedaten auf die Menge der stornierten Aufträge eingeschränkt.

Ziel des zweiten Prozessschritts, der *Datenexploration*, war es, ein Gespür für die Struktur und die Zusammensetzung der Daten zu bekommen sowie deren Qualität und Plausibilität zu beurteilen. Hierzu wurden die Ereignis- und Objektdaten aus den operativen Quellsystemen extrahiert und in einer denormalisierten Datentabelle zusammengefasst. Primäre Datenquelle war das SAP-System mit dem Modul SD (Sales & Distribution). Im Zeitraum zwischen dem 01.09.04 und 30.08.05 wurden insgesamt 634 930 Kundenaufträge der Frühjahr/Sommer-Kollektion 2005 bearbeitet. Davon wurden in dem Zeitraum 3 059 Aufträge storniert. Für die Datenexploration wurden die Häufigkeitsverteilungen der Merkmale grafisch aufbereitet. Im Folgenden werden die bei der Datenexploration entdeckten Auffälligkeiten gemeinsam mit den daraus abgeleiteten Maßnahmen der *Datenmanipulation* beschrieben.


a) Anzahl Aufträge pro Landesgesellschaft




b) Anzahl Aufträge nach Auftragsstyp




c) Anzahl Aufträge pro Risikoklasse




d) Anzahl Aufträge nach Status zum Prozessende




e) Anzahl Aufträge nach Auftragswert




f) Anzahl Aufträge nach Stornierungsart



g) Anzahl der Aufträge mit häufigster Statussequenz



h) Anzahl Aufträge nach Monat der Auftragsanlage

**Abbildung 99:** Visuelle Datenexploration mittels Analyse der Häufigkeitsverteilungen

Zunächst wurden die Kundenaufträge nach der Landesgesellschaft des Kundenservice ausgewertet, der den Auftrag angelegt und bearbeitet hat (siehe Abbildung 99a). Obwohl den Mitarbeitern der Sport AG bekannt war, dass die

meisten Kundenaufträge in der der Landesgesellschaft Deutschland bearbeitet wurden, war man dennoch erstaunt darüber, wie groß der Unterschied zu den anderen Ländergesellschaften tatsächlich war. Die Analysedaten wurden daraufhin auf die Kundenaufträge des deutschen Kundenservice eingeschränkt, da die Merkmalsausprägungen der deutschen Kundenaufträge das Analyseergebnis ohnehin massiv prägen würden.

Die Auswertung nach dem Auftragsstyp (siehe Abbildung 99b) brachte hingegen keine Überraschung. Dass die Mehrzahl der bearbeiteten Aufträge Rush Orders sind, war ebenso erwartet worden, wie die Tatsache, dass die Standard Orders den weitaus geringsten Anteil der Aufträge stellen.

Interessanter wurde es, als die Anzahl der Aufträge nach Risikoklasse (siehe Abbildung 99c) mit der Anzahl der Aufträge nach Status zum Prozessende (siehe Abbildung 99d) verglichen wurden: In der Risikoklasse Z01 befanden sich zahlenmäßig weniger Aufträge als in der Klasse der Aufträge ohne Auftragsstatus. Erwartet wurde, dass beide Zahlen identisch sein müssten, da für einen Auftrag eines Kunden der Risikoklasse Z01 keine Kreditprüfung durchgeführt wird, was der Statuswert „Null“ anzeigt. Dass es aber Aufträge mit Auftragsstatus „Null“ gab, deren Kunden einer anderen als der Risikoklasse Z01 angehören, wurde als nicht plausibel erachtet. Diese Datensätze wurden als fehlerhafte Datensätze aus der Analyse ausgeschlossen. Dasselbe traf auf die 123 Aufträge zu, die zum Saisonende, am 30. August, noch immer gesperrt waren. Hier vermutete man, dass die Aufträge zwar bearbeitet wurden, dass aber die Statussequenz vom SAP-System nicht mehr vollständig aufgezeichnet wurde. Daher hat man auch diese Datensätze von der Analyse ausgenommen.

Die Auswertung der Aufträge nach ihrem Auftragswert (siehe Abbildung 99e) wurde wiederum als plausibel erachtet; ebenso die Verteilung der stornierten Aufträge nach der Stornierungsart (siehe Abbildung 99f). Sowohl überraschend als auch erfreulich war das Ergebnis in Abbildung 99g: Nahezu die Hälfte der kreditgeprüften Aufträge wies eine Statussequenz von A auf, was bedeutet, dass diese Aufträge ohne Sperrung oder Stornierung bearbeitet wurden. Allerdings waren selbst die Mitarbeiter des Kundenservice verwundert, dass mit 3 532 Aufträgen die zweithäufigste Statussequenz BD war, was bedeutet, dass der Kundenservice diese Aufträge bereits nach der ersten Sperrung manuell freigegeben hat.

Abbildung 99h zeigt die monatliche Verteilung der Auftragseingänge. Deutlich zu sehen ist, wie im Vor-Saison-Bereich, von September bis Dezember, die Vorbestellungen ansteigen, während die Nachbestellungen innerhalb der Ver-

kaufssaison von Januar bis Juli erst ansteigen, um schließlich ab April wieder abzunehmen. Dieser Verlauf entsprach den Erfahrungen des Kundenservice.

7.2.2.3 Verfahrensanwendung

Vor der eigentlichen Analyse der Daten musste zunächst das Analyseverfahren bestimmt sowie dessen Analysemethode ausgewählt und parametrisiert werden (siehe Abschnitt 6.2.3). Wie in Tabelle 2 dargestellt (siehe Seite 192), lassen sich Ereignis-Objekt-Beziehungen sowohl im Rahmen einer Assoziations- als auch einer Abweichungsanalyse untersuchen. Daneben können auch Verfahren zur Segmentierung sowie zur Prognose und Klassifikation eingesetzt werden. Die Abweichungsanalyse schied von vornherein aus, da es sich bei dem Ereignismerkmal um ein nominales Merkmal handelt; und mit der einzig infrage kommenden Methode der Top-Down-Navigation lassen sich nur Abweichungen metrisch skalierten Merkmale analysieren. Als Analysesoftware wurde die Data-Mining-Suite RapidMiner verwendet, wodurch in jeder der drei verbleibenden Verfahrensklassen jeweils unterschiedliche Analysemethoden zur Segmentierung, Klassifikation und Prognose zur Verfügung standen.

Im *ersten Prozessschritt*, der Verfahrens-, Methoden- und Parametersuche, wurde entschieden, ein segmentierendes Verfahren für die Analyse der Ereignis-Objekt-Beziehung zu nutzen. Da jedes der gefundenen Segmente als eigene Stornierungsart interpretiert werden kann, soll im Anschluss ein Entscheidungsbaumverfahren angewandt werden, um die Merkmalsunterschiede zwischen den identifizierten Stornierungsarten zu untersuchen. In der Phase der Lösungstransformation lassen sich diese Merkmalsunterschiede dazu verwenden, differenzierte Kausalhypothesen über Ursachen und Auswirkungen der Stornierungsarten zu entwickeln.

In der Verfahrensklasse der segmentierenden Verfahren engte sich die *Methodensuche* auf die Klasse der partitionierenden Verfahren ein, in der neben der K-Means- auch die K-Medoids-Methode zur Auswahl stand. Nachteil der K-Means-Methode ist, dass diese zur Berechnung des euklidischen Distanzmaßes nur metrische Merkmale akzeptiert und diese eine Transformation der nominalen Merkmale in metrisch skalierte Merkmale erfordert. Die Wahl fiel dennoch auf die K-Means-Methode, da diese die charakteristischen Merkmalsunterschiede zwischen den Segmenten grafisch darstellt und somit die Interpretation der Analyseergebnisse erleichtert. Dies hat den Vorteil, dass keine weiteren Analysen zum Zweck der Ergebnisinterpretation nötig sind.

Bei der *Parametersuche* musste zunächst mit dem Parameter k die Anzahl der zu bildenden Segmente angegeben werden. Anstatt k einen festen Wert zuzuweisen, wurde die Segmentierung mit unterschiedlichen k -Werten wiederholt, um die generierten Segmenteinteilungen vergleichen zu können. Darüber hinaus wurde die Anzahl der Iterationsschritte auf 100 und die Häufigkeit der Methodenanwendung auf fünf festgesetzt. Das bedeutet, dass jede der fünf Methodenanwendungen per Zufall andere k Datenobjekte als initiale Segmentzentren auswählt, die dann im Verlauf von maximal 100 Iterationsschritten sukzessive in Richtung Optimum verschoben werden. Durch die fünffache Methodenanwendung soll vermieden werden, dass die gefundene Segmenteinteilung nur ein lokales Optimum ist.

Bevor mit der eigentlichen Datenanalyse begonnen wurde, mussten noch alle nominalen Merkmale in metrisch skalierte Merkmale transformiert werden. Hierzu wurde für jede Ausprägung eines nominalen Merkmals ein eigenes binominales Merkmal mit der Ausprägung 0 oder 1 gebildet. Anschließend sind alle metrischen Merkmale ebenfalls auf den Wertebereich zwischen 0 und 1 normalisiert worden. Denn nur wenn alle Merkmale denselben Wertebereich besitzen, ist sichergestellt, dass sie gleichgewichtet in die Analyse einfließen und die Berechnung des euklidischen Distanzmaßes nicht verfälschen.

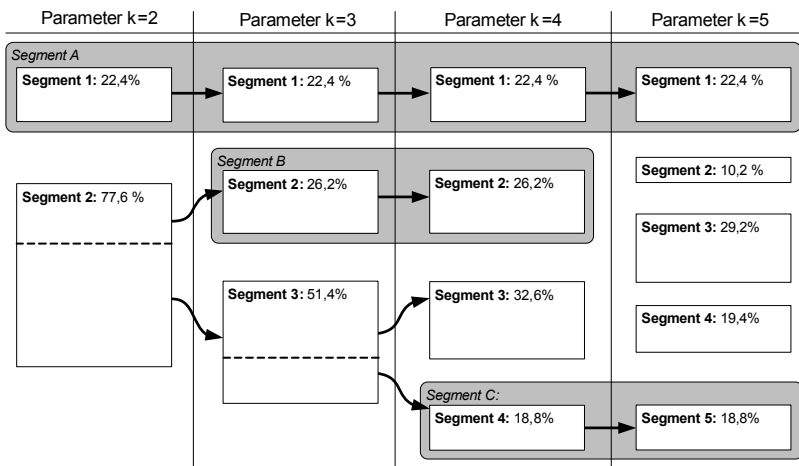


Abbildung 100: Segmenteinteilungen mit Parametrisierung $k = 2, 3, 4$ und 5

Im zweiten Prozessschritt, der Analysedurchführung, wurde die Segmentierung mit den Parametern $k=2$, $k=3$, $k=4$ und $k=5$ wiederholt. Abbildung 100 zeigt die Segmenteinteilungen und weist für jedes Segment den darin enthaltenen Anteil der Datensätze aus.

Um zu entscheiden, mit welcher der vier Parametrisierungen die Analyse fortgesetzt werden soll, wurden die ihre Segmenteinteilungen verglichen. Auffällig war, dass sich die Zusammensetzung einzelner Segmente auch bei wechsellagerung der Parametrisierung nicht änderte. So ist zum Beispiel das Segment A in allen vier Segmenteinteilungen enthalten. Zwei andere Segmente waren in jeweils zwei aufeinander folgenden Segmenteinteilungen zu finden: Während das Segment B in der Parametrisierung $k=3$ und 4 zu finden ist, wird das Segment C sowohl bei $k=4$ als auch bei $k=5$ erzeugt. Da nur die Parametrisierung $k=4$ diese drei stabilen Segmente gleichzeitig erzeugt, wurde diese Segmenteinteilung im Anschluss näher untersucht.

Abbildung 101 zeigt, hinsichtlich welcher Merkmale sich die vier Segmente der Parametrisierung $k=4$ am deutlichsten unterscheiden. Der unter a) ausgewiesene Merkmalsunterschied errechnet sich aus dem Mittelwert der paarweisen Differenzen zwischen den Merkmalswerten der vier Segmentzentren. Beim Merkmal der Stornierungsart ist der Merkmalsunterschied zwischen dem ersten und dem zweiten Segment mit $1-0=1$ maximal, während er zwischen dem ersten und dem dritten Segment mit $1-1=0$ minimal ist. Aufgrund der Kombinatorik mit vier Segmenten lassen sich pro Analysemerkmal sechs paarweise Merkmalsdifferenzen berechnen. Der Mittelwert dieser Merkmalsdifferenzen gibt an, wie stark sich die vier Segmente bezüglich des jeweiligen Merkmals unterscheiden. In Abbildung 101a sind die Differenzmittelwerte derjenigen Merkmale aufgeführt, die zusammen genommen 80% der Segmentunterschiede erklären. In Abbildung 101b bis e sind die normierten Merkmalswerte der vier Segmentzentren abgebildet.




Abbildung 101: Normierte Merkmalsausprägungen und -unterschiede der Segmentzentren für $k = 4$

Obwohl die Interpretation des Analyseergebnisses erst in der Phase der Lösungstransformation folgt, ist aus Abbildung 101a bereits ersichtlich, dass sich die vier Segmente am deutlichsten bezüglich der Stornierungsart und somit im Grund ihrer Stornierung unterscheiden. Dies warf die Frage auf, anhand welcher Merkmale sich Aufträge, die aufgrund zu geringer Lagerbestände storniert werden, von den Aufträgen unterscheiden, die aus Kreditgründen zu stornieren sind. Dies ist aber eine Frage, die sich im Anschluss mithilfe von Entscheidungsbaumverfahren beantworten lässt, wie die folgenden Abschnitte zeigen.

Bei der *Methodensuche* fiel die Entscheidung auf das Analysemodul Decision-Tree, das den C4.5-Algorithmus nutzt. Im Gegensatz zu anderen Methoden, wie etwa dem klassischen ID3-Algorithmus, können sowohl metrische als auch nominale skalierte Merkmale verarbeitet werden. Folglich kann auf die Transformation der Merkmale in binominale Merkmale verzichtet werden.

Anders als bei der K-Means-Segmentierung, deren Haupteinflussgröße die Anzahl der Segmente (k) ist, sind für die Anwendung des Entscheidungsbaumverfahrens drei Parameter festzulegen, die das Ergebnis der Analyse maßgeblich beeinflussen:

- *Criterion* legt fest, nach welchem Kriterium die Merkmale und Merkmalswerte bestimmt werden, anhand derer sich die Datensätze sukzessive aufspalten sollen.
- *Minimal leaf size* gibt die Anzahl der Datensätze an, die mindestens in den Blattknoten des Entscheidungsbaums enthalten sein müssen.
- *Maximal depth* legt die maximale Tiefe des Entscheidungsbaums und somit die maximale Anzahl der hierarchischen Baumebenen fest.

Die *Parametersuche* erfolgte iterativ und parallel zum Prozessschritt der *Analyse-durchführung*. Genau genommen wurde ein Teil der Lösungstransformation vorgezogen, indem die Parameter abhängig von der Interpretation des generierten Entscheidungsbaums geändert wurden. Zwei Kriterien lagen der Entscheidung zugrunde, ob die Analyse mit veränderten Parametern wiederholt wird:

- *Neuheit*: Waren die Wenn-Dann-Regeln des Entscheidungsbaums nicht neu, sondern trivialer Natur, wurde der Parameter *criterion* angepasst.
- *Verständlichkeit*: War der Entscheidungsbaum zu unübersichtlich, da er sich zu breit oder zu tief auffächerte, wurden die Parameter *minimal leaf size* und *maximal depth* sukzessive erhöht bzw. reduziert.

Neben Änderungen in der Parametrisierung wurden während der Analyse auch einzelne Merkmale aus der Datenbasis entfernt. Dieser Rücksprung in die Phase der Modellkonstruktion war nötig, weil einige Merkmale die beiden Stornierungsarten zwar deutlich, aber dennoch auf triviale und bereits bekannte Weise voneinander trennten. So wurden die drei Merkmale Statussequenz, Auftragsstatus (nach der zweiten bzw. dritten Prüfung) und Dauer der dritten Prüfung entfernt. Denn dass ein stornierter Auftrag, der bei der dritten Kreditprüfung eine Prüfdauer größer null aufweist, nur aus Kredit- und nicht mehr aus Lagergründen storniert wurde, war ebenso zu erwarten, wie die Aussage, dass Aufträge mit einer Statussequenz AAC, ABAC oder BAC aus Lagergründen storniert wurden (ersichtlich am Statuswechsel von A nach C). Erst als diese Merkmale entfernt waren, wurden die lager- und kreditstornierten Aufträge durch andere, interessantere Merkmale voneinander getrennt. Abbildung 102 zeigt den Entscheidungsbaum, dessen Regeln sowohl als neu als auch verständlich beurteilt wurden.

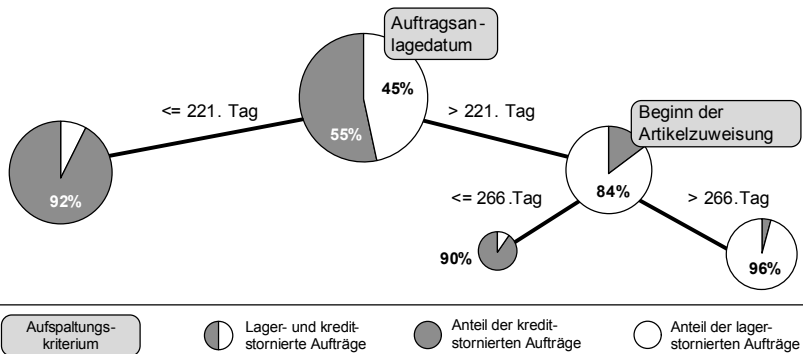


Abbildung 102: Entscheidungsbaum zur Charakterisierung von lager- und kredit-stornierten Aufträgen

Der abgebildete Entscheidungsbaum war das Ergebnis der Parametrisierung $\text{criterion} = \text{gain_ratio}$, $\text{minimal_leaf_size} = 20$ und $\text{maximal_depth} = 5$. Welche kausalen Schlussfolgerungen aus dem Entscheidungsbaum zusammen mit dem Ergebnis der Segmentierung gezogen wurden, zeigt der folgende Abschnitt der Lösungstransformation.

7.2.2.4 Lösungstransformation

Wie in Abschnitt 6.2.4 beschrieben, ist im Rahmen der Lösungstransformation zunächst die Interessantheit der Datenmuster zu beurteilen. Interessant ist ein Datenmuster dann, wenn es nicht nur verständlich, gültig und neu, sondern auch nützlich ist. Letzteres ist der Fall, wenn sich aus dem Datenmuster Kausalhypothesen ableiten lassen, die ebenfalls verständlich, neu, gültig und nützlich - und somit interessant - sein müssen. Beides, die Bewertung der Datenmuster sowie die Ableitung der Kausalhypothesen, wird im Folgenden erläutert.

Die *Verständlichkeit* der gefundenen Segmenteinteilung hängt davon ab, ob sich die charakteristischen Merkmalsausprägungen der Segmente nachvollziehen lassen. Diese sind in Tabelle 7 zwar visualisiert, allerdings nur in codierter Form. Vor der Analyse wurden die nominalen Merkmale erst in metrische Merkmale transformiert und anschließend mit den anderen metrischen Merkmalen auf den Wertebereich zwischen 0 und 1 normiert. Aus diesem Grund sind die Merkmale erst in ihren ursprünglichen Wertebereich zurückzutransformieren, damit die charakteristischen Merkmalsausprägungen der vier Segmente sichtbar

werden. Tabelle 7 gibt für die wichtigsten Merkmale das Ergebnis dieser Transformation wieder. Die Ähnlichkeiten und Unterschiede der vier Segmente lassen sich wie folgt zusammenfassen:

Merkmal <i>Gesamtanteil:</i>	Segment 1: <i>Anteil: 22,4%</i>	Segment 2: <i>Anteil: 26,2%</i>	Segment 3: <i>Anteil: 32,6%</i>	Segment 4: <i>Anteil: 18,8%</i>
1) Stornierungsart	Lager = 100%	Kredit = 100%	Lager = 100%	Kredit = 100%
2) Status 2. Prüfung	0 = 100%	C = 100%	A = 78% D = 22%	A = 100%
3) Status 1. Prüfung	0 = 100%	A = 26% B = 74%	A = 18% B = 82%	A = 46% B = 54%
4) Statussequenz	C = 100%	ABC = 26% BBC = 74%	BBAC = 56% BBDC = 20% sonstige = 24%	AAABC = 37% BBABC = 32% BABC = 22% ABABC = 10%
5) Status 3. Prüfung	0 = 100%	0 = 100%	0 = 100%	C = 100%
6) Dauer 2. Prüfung	0 Tage	65 Tage	26 Tage	3 Tage
7) Risikoklasse	Z01 = 84% ZD2 = 16%	ZD3 = 97% ZD2 = 3%	ZD3 = 97% ZD2 = 3%	ZD3 = 96% ZD2 = 4%
8) Sperrdauer	0 Tage	65 Tage	26 Tage	33 Tage
9) Beginn der Zuweisung	263. Tag	0. Tag	292. Tag	214. Tag

Tabelle 7: Charakteristische Merkmalsausprägungen der Segmentzentren für $k=4$ sortiert nach Signifikanz der Merkmalsunterschiede

- **Segment 1** setzt sich aus lagerstornierten Aufträgen zusammen (siehe Tabelle 7: Zeile 1), die aufgrund der Risikoklasse Z01 und ZD2 (Zeile 7) nicht kreditgeprüft wurden (Zeile 5).
- **Segment 2** enthält kreditstornierte Aufträge (Zeile 1), die bereits bei der zweiten Kreditprüfung storniert worden sind (Zeile 2) und von Kunden der Risikoklassen ZD2 und ZD3 stammen (Zeile 7).
- **Segment 3** besteht aus lagerstornierten Aufträgen (siehe Zeile 1), die im Gegensatz zu den Aufträgen des ersten Segments aufgrund der Risikoklasse ihrer Kunden (Zeile 7) einer Kreditprüfung unterzogen wurden (Zeilen 2 und 3).
- **Segment 4** umfasst kreditstornierte Aufträge (Zeile 1), die anders als die Aufträge des zweiten Segments erst bei der dritten Kreditprüfung storniert wurden (Zeile 5), aber ebenfalls von Kunden der Risikoklassen ZD3 und ZD2 stammen (Zeile 7).

Im Gegensatz zum Analyseergebnis der Segmentierung war der Entscheidungsbaum auf Anhieb verständlich, da sich die Entscheidungsregeln unmittelbar aus dem Baum ablesen ließen:

- **Entscheidungsregel 1** besagt, dass ein Auftrag, der vor bzw. am 221. Tag der Saison angelegt wurde, aus Kreditgründen storniert wurde.
- **Entscheidungsregel 2** drückt aus, dass bei Aufträgen, die nach dem 221. Saisontag angelegt wurden, der Beginn der Artikelzuweisung entscheidend ist: Lag der Zeitpunkt vor dem 266. Saisontag, ist der Auftrag aus Kreditgründen storniert worden. Wurde mit der Artikelzuweisung später begonnen, waren zu geringe Lagerbestände der Stornierungsgrund.

Die *Neuheit* der Segmententeilung wurde anhand der Merkmalsähnlichkeiten beurteilt, durch die sich die Datensätze innerhalb der Segmente auszeichnen. Hierbei waren folgende Erkenntnisse neu:

- Überraschend war, dass zum einen 74% der kreditstornierten Aufträge aus Segment zwei, zum anderen aber auch 82% der lagerstornierten Aufträge aus Segment drei bereits nach der ersten Kreditprüfung gesperrt waren (siehe Zeile 3).
- Ebenso neu war die Erkenntnis, dass rund drei Viertel der lagerstornierten Aufträge des dritten Segments im Zuge der zweiten Kreditprüfung gesperrt wurden, bevor sie anschließend trotz manueller bzw. automatischer Freigabe dennoch storniert wurden (siehe Zeile 4: Statussequenzen BBDC 20% und BBAC 56%).
- Neu war auch die Information, dass die Artikelzuweisung bei den lagerstornierten Aufträgen des ersten und dritten Segments sehr viel später begonnen wurde (siehe Zeile 9: 263. bzw. 292. Tag) als bei den kreditstornierten Aufträgen des vierten Segments (siehe Zeile 9: 214. Tag).

Beim Entscheidungsbaum wurde nur die zweite Entscheidungsregel als neu betrachtet. Dass gegen Saisonende die Lagerstornierungen überwiegen, war bereits bekannt. Neu war hingegen, dass anscheinend auch der Zuweisungsbeginn über die Art der Stornierung entscheidet.

Bezüglich der *Gültigkeit* der Analyseergebnisse wurden weder die Segmententeilung noch der Entscheidungsbaum angezweifelt. Beide Ergebnisse erschienen den Mitarbeitern plausibel. Auch die prozentuale Verteilung der Datensätze auf die vier Segmente deckte sich mit den Erfahrungen der Mitarbeiter im Kundenservice.

Die *Nützlichkeit* der Analyseergebnisse lässt sich nur durch die Formulierung interessanter Kausalhypothesen belegen. Die Datenanalyse sollte zeigen, welche Aufträge der Kundenservice typischerweise storniert, um auf der Ereignisebene zwischen verschiedenen Stornierungsereignissen differenzieren zu können. Deren Auswirkungen und Wechselwirkungen sollen dann in Form neuer Kausalhypothesen beschrieben werden (siehe das in Abschnitt 7.2.2.1 erläuterte Modellziel). Abbildung 103 zeigt, zwischen welchen Stornierungsereignissen auf Basis der Segmenteinteilung differenziert wurde.

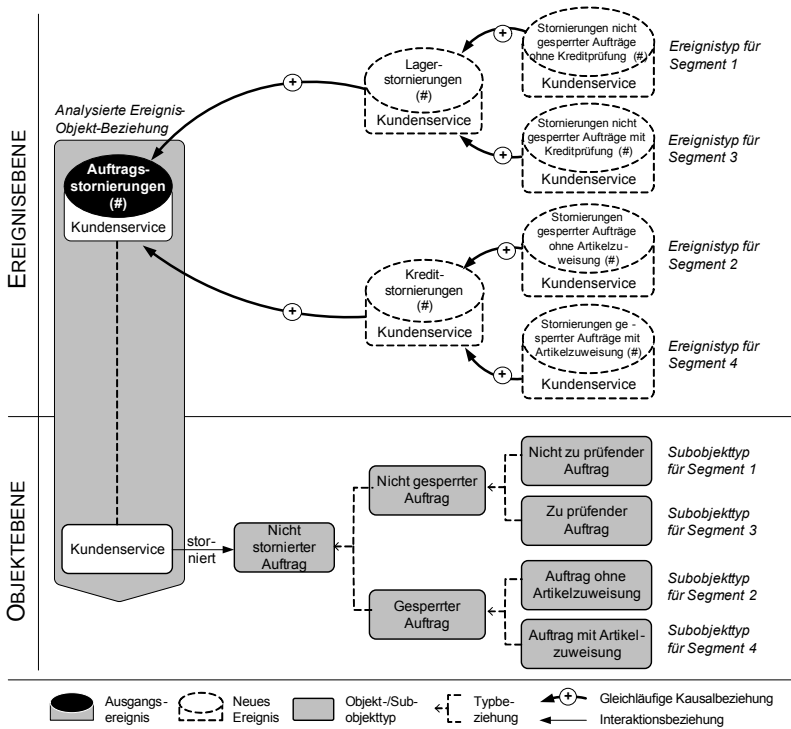


Abbildung 103: Ereignis- und Objektdifferenzierung als Ergebnis der Segmentierung

Gemäß den vier Segmenten der Segmenteinteilung lassen sich die vom Kundenservice stornierten Aufträge in vier Auftragsklassen einteilen. Jede dieser vier Auftragsklassen ist auf der Objektebene als ein eigener Subobjekttyp modelliert, der das Resultat einer Spezialisierung des Objekttyps NICHT STORNIRTER

AUFTRAG ist (siehe Abbildung 103: Objektebene). Bei der Typbildung wurden zunächst die Subobjekttypen GESPERRTER AUFTRAG und NICHT GESPERRTER AUFTRAG unterschieden. Im Zuge einer weiteren Spezialisierung wurden die nicht gesperrten Aufträge in Aufträge mit und ohne Artikelzuweisung aufgeteilt, während bei den gesperrten Aufträgen zwischen solchen mit und ohne Kreditprüfung differenziert wurde.

Da der ereignistragende Objekttyp KUNDENSERVICE mit dem Objekttyp NICHT STORNIERTER AUFTRAG interagiert, überträgt sich diese Interaktionsbeziehung auch auf alle Subobjekttypen. Das bedeutet, dass sich die Stornierungen von Instanzen eines Subobjekttyps zu einem eigenen Ereignistyp zusammenfassen lassen. Aus diesem Grund wurde auf der Ereignisebene die Stornierung eines GESPERRTEN AUFTRAGS als Ereignistyp Kreditstornierung, die Stornierung eines NICHT GESPERRTEN AUFTRAGS als Ereignistyp Lagerstornierung modelliert. Auch die vier Subobjekttypen, die den vier Segmenten der Segmenteinteilung entsprechen, begründen vier unterschiedliche Stornierungsereignisse. Auf diese Weise konnte das ursprüngliche Ausgangsereignis der Auftragsstornierung in insgesamt sechs Ereignistypen differenziert werden, die sich aufgrund der Typbeziehungen ihrer ereignistragenden Subobjekttypen kausal verknüpfen lassen (siehe Abbildung 103: Ereignisebene).

Mithilfe dieser neuen Stornierungsereignisse lassen sich zum einen die bereits vorhandenen Kausalbeziehungen differenzieren, zum anderen neue Kausalbeziehungen knüpfen. Abbildung 104 fasst die differenzierten und neu entwickelten Kausalhypothesen zusammen. Folgende Kausalbeziehungen sind Differenzierung bereits bestehender Kausalhypothesen:

- Anstatt alle Stornierungen als Erhöhung der Umsatzeinbußen anzusehen (siehe Abbildung 91: d2), wurde der Zusammenhang auf den Ereignistyp der Lagerstornierung eingegrenzt (siehe Abbildung 104: d2*).
- Reduziert/erhöht sich der zuweisbare Lagerbestand, erhöhen/reduzieren sich dadurch nicht alle Auftragsstornierungen gleichermaßen (siehe Abbildung 89: b8), sondern nur die beiden Stornierungsarten, die aus Lagergründen erfolgen (siehe Abbildung 104: b8.1* und b8.2*).
- Der zuweisbare Lagerbestand wird nicht mehr durch alle Auftragsstornierungen erhöht (siehe Abbildung 89: b12), sondern nur noch durch Stornierungen gesperrter Aufträge, denen bereits Artikel zugewiesen wurden (siehe Abbildung 104: b12*).

- Nicht mehr die Erhöhung aller Auftragsstornierungen reduziert die Anzahl der zu prüfenden Aufträge (siehe Abbildung 89: b2), sondern ausschließlich Stornierungen von Aufträgen mit Kreditprüfung (siehe Abbildung 104: b2.1* und b2.2*).
- Die Anzahl der Kundenaufträge ohne Kreditprüfung sinkt nicht bei allen Auftragsstornierungen (siehe Abbildung 91: d8), sondern nur, falls ein nicht gesperrter Auftrag ohne Kreditprüfung (aus Lagergründen) storniert wird (siehe Abbildung 104: d8*).
- Verzögert sich die automatische Auftragsfreigabe, hat dies keine Auswirkung mehr auf alle Auftragsstornierungen (siehe Abbildung 89: b5), sondern nur auf Kreditstornierungen von gesperrten Aufträgen mit bzw. ohne Artikelzuweisung (siehe Abbildung 104: b5.1* und b5.2*).

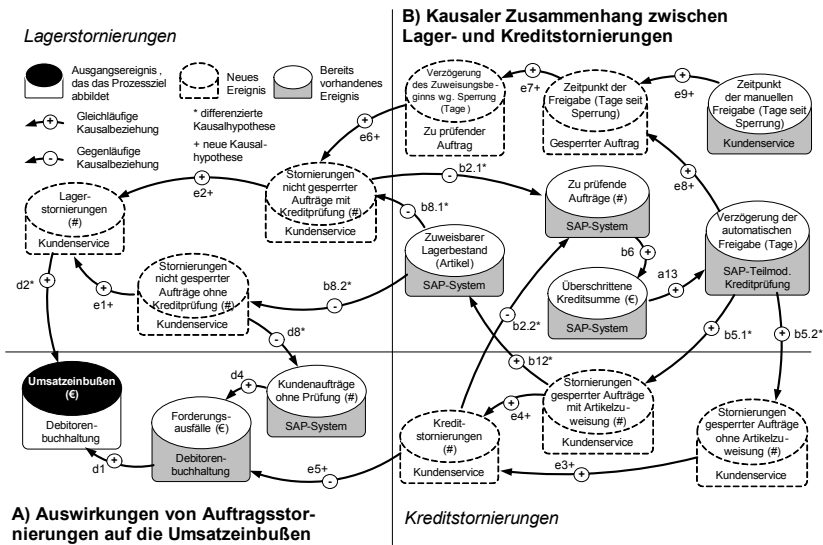


Abbildung 104: Kausalhypothesen der datenzentrierten Hypothesenentwicklung

Neben der Differenzierung bereits bekannter Kausalhypothesen boten die Analyseergebnisse auch die Gelegenheit zur Formulierung neuer Kausalbeziehungen. Zusätzlich zu Kausalbeziehungen der spezialisierten Stornierungsereignisse (siehe Abbildung 104: e1+, e2+, e3+ und e4+) wurde die Annahme getroffen, dass Kreditstornierungen ihren Zweck erfüllen und Forderungsausfälle ver-

hindern (e5+). Während Lagerstornierungen die Umsatzeinbußen erhöhen, reduzieren Kreditstornierungen diese.

Zuletzt wurde das Analyseergebnis des Entscheidungsbaums genutzt, um folgende Kausalhypothese zu formulieren: Je mehr sich der Zuweisungsbeginn aufgrund einer Auftragsperrung verzögert, desto häufiger werden die Aufträge nach ihrer manuellen oder automatischen Freigabe aus Lagergründen storniert (siehe Abbildung 104: e6+). Diese Kausalhypothese bezieht sich somit nur auf Aufträge mit Kreditprüfung, da sich der Beginn der Artikelzuweisung nur bei dieser Auftragsart aufgrund einer Auftragsperrung verschieben kann. Die Zuweisung verzögert sich, wenn sich infolge einer Auftragsperrung der Zeitpunkt der Auftragsfreigabe verzögert (e7+). Dies ist entweder einer verspäteten manuellen oder automatischen Auftragsfreigabe geschuldet (e8+ und e9+), wobei die automatische Auftragsfreigabe umso später erfolgt, je höher die überschrittene Kreditsumme (a13) und die Anzahl der zu prüfenden Aufträge sind (b6).

Abschließend wurden die Kausalhypothesen hinsichtlich ihrer Verständlichkeit, Neuheit, Gültigkeit und Nützlichkeit bewertet. Unter dem Aspekt der *Verständlichkeit* konnten die Mitarbeiter der Sport AG alle Kausalhypothesen auf Anhieb nachvollziehen. Das lag auch daran, dass die Kausalhypothesen e1+, e2+, e3+ und e4+ auf Basis der typologischen Objektbeziehungen der Subobjekttypen entwickelt wurden (siehe Abbildung 103). Dennoch wurden alle Kausalhypothesen als *neu* bewertet. Vor allem der kausale Zusammenhang zwischen Lager- und Kreditstornierungen war bislang noch nicht so differenziert betrachtet worden. Zudem wurde mit dem Zeitpunkt der Artikelzuweisung eine neue Ursache für eine Lagerstornierung entdeckt (e6+). Angesichts der Qualität und des Umfangs der Analysedaten wurde auch die *Gültigkeit* der Kausalhypothesen nicht angezweifelt.

Als letztes Kriterium wurde die *Nützlichkeit* der Kausalhypothesen beurteilt, insbesondere ihre Erklärungskraft und der dadurch eröffnete Handlungsspielraum. Ziel war es, differenzierte Kausalhypothesen zu entwickeln, die erklären, welche Auftragsstornierungen die Umsatzeinbußen erhöhen und welche sie reduzieren. Hierbei musste der Kausalhypothese d2* eine größere Erklärungskraft auf die Höhe der Umsatzeinbußen zugesprochen werden als der Hypothese e5+. Denn obwohl das zahlenmäßige Verhältnis von lager- und kreditstornierten Aufträgen mit 55% zu 45% nahezu ausgewogen ist (siehe Abbildung 102), überwiegen die Lagerstornierungen unter monetären Gesichtspunkten, da sie 67% des stornierten Auftragsvolumens stellen. Das bedeutet, dass der

Umsatzeinbußen erhöhende Effekt der Lagerstornierungen größer ist als der gegenteilige Effekt der Kreditstornierungen, auf die nur 33% des stornierten Auftragsvolumens entfällt. Betrachtet man die 67% Auftragsvolumen der Lagerstornierungen alleine, dann sind es speziell die Stornierungen der nicht gesperrten Aufträge ohne Kreditprüfung, auf die mit 45% der größte Anteil des stornierten Gesamtvolumens entfällt (e1+). Bei den beiden Stornierungsarten der Kreditstornierung ist das Verhältnis mit 14% zu 19% hingegen ausgewogen (e3+ und e4+).

Bei der Bewertung des Handlungsspielraums ist zu klären, inwiefern sich die Kausalhypothesen zur Begründung kausaler Kennzahlbeziehungen nutzen lassen. Auf Basis des Analyseergebnisses wurde beschlossen, für jede der sechs Stornierungsarten eine eigene Kennzahl auszuweisen, die das stornierte Auftragsvolumen enthält. Zusätzlich sollen der zuweisbare Lagerbestand und das Auftragsvolumen von gesperrten Aufträgen mit Artikelzuweisung als Frühindikatoren verfolgt werden (b12*). Dieser Frühindikator kann auf folgende Weise dazu beitragen, die Zielkonflikte auszubalancieren:

Können aufgrund zu geringer Lagerbestände nicht allen Aufträgen Artikel zugewiesen werden, da bereits anderen Aufträge Artikel zugewiesen wurden, die aber gesperrt sind, dann zeigen die Kausalhypothesen b12* und b8.1*, mit welchen Maßnahmen gegengesteuert werden kann: Verkürzt man bei den gesperrten Aufträgen mit Artikelzuweisung die Wartezeit bis zur Kreditstornierung (siehe Abbildung 89: b7), werden zwar einerseits mehr Aufträge aus Kreditgründen storniert, andererseits kann dies in Kauf genommen werden, falls sich dank des erhöhten zuweisbaren Lagerbestands eine sonst drohende Lagerstornierung mit einem höheren Auftragswert abwenden lässt. Die Frage, wann die Wartezeit wie stark verkürzt werden soll, würde jedoch eine neue Untersuchungssituation begründen.

7.2.3 Datenzentrierte Überprüfung von Kausalhypothesen

Obwohl zahlreiche Kausalhypothesen modellzentriert entwickelt wurden, konzentrieren sich die folgenden Abschnitte auf die datenzentrierte Überprüfung nur einer, aber dafür umso umstritteneren Kausalhypothese. Diese besagt, dass die manuellen Auftragsfreigaben des Kundenservice die Forderungsausfälle erhöhen (siehe Abbildung 91: d4/d6). Im Gegensatz zur datenzentrierten Hypothesenentwicklung dauerte die datenzentrierte Überprüfung nur knapp eine Woche. Dies war im Wesentlichen der Tatsache geschuldet, dass für die Analyse

ein bereits vorhandenes Data-Warehouse zur Verfügung stand, was dazu führte, dass die Phase der Modellkonstruktion übersprungen werden konnte.

7.2.3.1 Zieltransformation

Im *ersten Prozessschritt* der Zieltransformation ist neben dem originären Untersuchungsproblem vor allem die zu überprüfende Kausalhypothese zu spezifizieren (siehe Abschnitt 6.4.1). Auf die erneute Spezifikation des originären Untersuchungsziels kann an dieser Stelle verzichtet werden, da unmittelbar an die modellzentrierte Hypothesenentwicklung angeknüpft wird. Das Untersuchungsziel besteht nach wie vor darin, aussagekräftige Kennzahlen abzuleiten und diese mittels kausaler Kennzahlbeziehungen zu verknüpfen (siehe Abschnitt 7.2.1.1). Auch das Untersuchungsobjekt, der Kundenauftragsprozess, bleibt unverändert.

Wie in Abschnitt 7.1.2 bereits erwähnt, vermuteten die Mitarbeiter der Finanzabteilung bereits seit längerem, dass der Kundenservice unverhältnismäßig viele Aufträge manuell freigibt, was wiederum zu mehr Forderungsausfällen führt. Obwohl die kausale Infrastruktur dieses Zusammenhangs bereits im Rahmen der modellzentrierten Hypothesenentwicklung beschrieben wurde (siehe Abschnitt 7.2.1.3), lehnten es die Mitarbeiter des Kundenservice ab, die Anzahl ihrer manuellen Auftragsfreigaben als Frühindikator für Forderungsausfälle in das Kennzahlensystem aufzunehmen. Man stimmte zwar zu, dass manuell freigegebene Aufträge zu Forderungsausfällen führen können. Allerdings war der Kundenservice davon überzeugt, dass diese Betrachtung rein theoretischer Natur sei. Gesperrte Aufträge würden vom Kundenservice mit viel Bedacht freigegeben, weshalb die manuelle Auftragsfreigabe in keinem Zusammenhang mit den Forderungsausfällen stehe.

Da dieses Argument die Finanzabteilung nicht wirklich überzeugte, wurde beschlossen, mit der Datenanalyse die Auswirkungen von manuellen Auftragsfreigaben auf die Höhe der Forderungsausfälle zu überprüfen. Abbildung 105 zeigt den zu überprüfenden Ausschnitt aus dem Kausalmodell der modellzentrierten Entwicklung (siehe Abbildung 91). Hierbei handelt es sich um einen transitiven Kausalzusammenhang, bei dem die manuellen Auftragsfreigaben die Kundenaufträge ohne Kreditprüfung erhöhen (d6), die als Ursache für Forderungsausfälle gelten (d4).




Abbildung 105: Untersuchte Kausalhypothesen der datenzentrierten Überprüfung

Nach der Festlegung der zu überprüfenden Kausalhypothesen besteht der *zweite Prozessschritt* darin, das Untersuchungsziel in ein Modellziel zu transformieren. Es muss angegeben werden, welche der vier generischen Zielsetzungen mit der Datenanalyse verfolgt werden sollen (siehe Abbildung 73, Seite 208).

Mit der Analyse der *Objekt-Ereignis-Beziehungen* soll in einer ersten Untersuchungssituation der Nachweis erbracht werden, dass sich die angegebenen Ursachen- und Wirkungsereignisse tatsächlich ereignet haben. Anschließend folgt in einer zweiten Untersuchungssituation die *Analyse der Ereignisbeziehungen* und somit die eigentliche Überprüfung des Kausalzusammenhangs. Hierzu werden die für jeden Ereignistyp identifizierten Ereignisinstanzen zu komplementären Ereignispaaren verknüpft. Die Aufgabe der Lösungstransformation ist es dann, die Gültigkeit der Kausalhypothese hinsichtlich der Kriterien Gesetzmäßigkeit und Chronologie zu beurteilen.

7.2.3.2 Modellkonstruktion

In Abschnitt 7.2.2.2 wurde bereits auf den grundlegenden Unterschied zwischen dem Modellsystem einer OLAP- und einer Data-Mining-Analyse hingewiesen. Während die Daten einer Data-Mining-Analyse speziell im Hinblick auf eine einzelne Fragestellung selektiert und aufbereitet werden, decken die Daten eines Data-Warehouse einen weiter gefassten Themenbereich ab. Welche konkreten Fragen aus diesem Themenbereich dann zu beantworten sind, ist zum Zeitpunkt der Modellkonstruktion noch weitgehend offen. Datenzugriff und -selektion erfolgen erst durch den Nutzer, der seine Fragestellungen nicht selten erst im Verlauf der Analyse entwickelt und konkretisiert. Da im Rahmen dieser Fallstudie auf ein bereits existierendes Data-Warehouse zurückgegriffen wurde, konnte die Phase der Modellkonstruktion übersprungen und unmittelbar mit der Phase der Verfahrensanwendung begonnen werden.

7.2.3.3 Verfahrensanwendung

Die Phase der Verfahrensanwendung gliedert sich in zwei Prozessschritte: die *Sicherstellung der Datenverfügbarkeit* und die eigentliche *Durchführung der Analyse* (siehe Abschnitt 6.4.3). Die Datenverfügbarkeit ist sichergestellt, wenn der Datenbestand des Data-Warehouses die für die Analyse benötigten Kennzahlen, Dimensionen, Hierarchiestufen und Dimensionselemente enthält. Diese ergeben sich wiederum aus den zu überprüfenden Kausalhypothesen, speziell aus den Ereignis- und Objektmerkmalen der Ereignis- und Objekttypen.

Das erste Ereignis beschreibt eine *Veränderung der Forderungsausfälle*. Eine Forderungssumme wird von der DEBITORENBUCHHALTUNG im SAP-SYSTEM als zweifelhafte Forderung verbucht (siehe Abbildung 86: 25), falls ein KUNDE einen in Rechnung gestellten Auftrag (23) trotz Mahnung nicht innerhalb von acht Wochen nach Rechnungsstellung bezahlt (24). Obwohl zu diesem Zeitpunkt noch nicht endgültig feststeht, ob die gesamte Forderungssumme abzuschreiben ist, werden diese zweifelhaften Forderungen vorsorglich auf ein Sonderkonto ausgebucht. Diese vorsorglich gebuchten Forderungsausfälle lassen sich im Data-Warehouse in verschiedenen Dimensionen sowohl auftrags- als auch kundenbezogen analysieren. Da jede Buchung einer zweifelhaften Forderung mit Datum erfasst ist, kann eine Erhöhung oder Reduzierung des zweifelhaften Forderungsvolumen auf Jahres-, Monats-, Wochen- und Tagesbasis flexibel ausgewertet werden.

Das zweite Ereignis beschreibt eine *Veränderung in der Anzahl der Kundenaufträge ohne Kreditprüfung*. Hierzu zählen all die Aufträge, bei denen entweder aufgrund der Risikoklasse oder infolge einer manuellen Freigabe keine Kreditprüfung durchgeführt wird. Im Data-Warehouse lassen sich die Aufträge in den Dimensionen Risikoklasse und Auftragsstatus zum Prozessende auswerten. In der Dimension Risikoklasse stehen die Dimensionselemente Z01, ZD2, ZD3 und Z09 als Filterkriterium zur Verfügung, während in der Dimension Auftragsstatus das Dimensionselement „Status D“ eine manuelle Auftragsfreigabe signalisiert. Um alle Aufträge ohne Kreditprüfung selektieren zu können, werden in der Dimension Auftragsstyp auch die Dimensionselemente Standard Order und Rush Order als Filterkriterien benötigt. Denn in der Risikoklasse ZD2 wird die Kreditprüfung nur für Vorbestellungen, nicht aber für Nachbestellungen vom Typ Standard Order oder Rush Order angewandt (siehe Abschnitt 7.1.1.2). Ebenso wie die Forderungsausfälle lassen sich auch die Kundenaufträge auf Jahres-,

Monats-, Wochen- und Tagesbasis analysieren. Die Aufträge können sowohl nach ihrem Anlagedatum als auch nach dem Datum der Lieferscheinerstellung ausgewertet werden.

Das dritte Ereignis bezieht sich auf die manuellen Auftragsfreigaben des Kundenservice. Bei der Überprüfung der Datenverfügbarkeit fiel auf, dass die Transaktion selbst im Data-Warehouse zwar nicht abgebildet ist, aber dass die Auswirkungen einer manuellen Auftragsfreigabe, der Wechsel des Auftragsstatus, sehr wohl verzeichnet ist. Indem manuell freigegebene Aufträge den Status D erhalten, können diese Aufträge im Data-Warehouse gezielt selektiert werden.

Der zweite Prozessschritt, die *Durchführung der Analyse*, beginnt mit der Einschränkung des Datenraums auf den interessierenden Teilbereich. Erst im Anschluss folgt die Analyse der *Objekt-Ereignis-Beziehungen*, mit der zunächst die Ereignisinstanzen identifiziert werden, deren *Ereignisbeziehungen* anschließend im Hinblick auf Gesetzmäßigkeit und Chronologie zu analysieren sind.

Zunächst wurde beschlossen, sich mit der OLAP-Analyse ebenfalls nur auf das Vertriebsgebiet Deutschland zu fokussieren, da man bei der datenzentrierten Hypothesenentwicklung bereits festgestellt hatte, dass die überwiegende Anzahl der Aufträge von deutschen Kunden stammt (siehe Abbildung 99). Auch der Analysezeitraum wurde dem der datenzentrierten Hypothesenentwicklung angeglichen. Analysiert wurden ausschließlich Daten der Saison Frühjahr/Sommer 2005.

Die Analyse von Objekt-Ereignis-Beziehungen ist eine Suche nach Ereignissen. Hierbei gilt, dass die Hierarchieebene der Zeitdimension darüber entscheidet, ob und wie viele Ereignisse man identifiziert. Mit einer Analyse auf Tagesbasis lassen sich weit mehr Merkmalsänderungen innerhalb eines Zeitraums ermitteln, als mit einer Analyse auf Wochen-, Monats- oder Jahresbasis. Da die Daten einer gesamten Saison betrachtet wurden, beschloss man, die Analyse auf Wochenbasis durchzuführen.

Für den Nachweis des ersten Kausalzusammenhangs (siehe Abbildung 105: d3) sind nur solche Forderungsausfälle interessant, die sich auf Kundenaufträge ohne Kreditprüfung zurückführen lassen. Würde man die Summe aller Forderungsausfälle betrachten, wären darin auch Forderungsausfälle von Kundenaufträgen mit Kreditprüfung enthalten. Untersucht werden soll jedoch der Kausaleinfluss von Kundenaufträgen *ohne* Kreditprüfung. Daher wurden die wöchentlichen Forderungsausfälle im Vertriebsgebiet Deutschland mithilfe der Dimensionen Auftragstyp, Risikoklasse und Auftragsstatus zum Prozessende weiter eingeschränkt; und zwar so, dass die Daten nur noch die Forderungsausfälle

von Kundenaufträgen ohne Kreditprüfung enthielten. Analog wurde auch die Anzahl der bearbeiteten Kundenaufträge auf die Aufträge ohne Kreditprüfung eingegrenzt.

Auf Basis dieser Einschränkungen folgte die Analyse der *Objekt-Ereignis-Beziehungen*. Abbildung 106 zeigt für den gesamten Zeitraum der Saison Frühjahr/Sommer 2005, welche Ereignisinstanzen für einen Anstieg und eine Reduzierung der Kundenaufträge ohne Kreditprüfung bzw. der Forderungsausfälle identifiziert werden konnten.

Während sich in dem betrachteten Zeitraum die Forderungsausfälle von Kundenaufträgen ohne Kreditprüfung 18-mal reduziert und 18-mal erhöht haben, kam es bei der Anzahl der erfolgreich bearbeiteten Kundenaufträge ohne Kreditprüfung 16-mal zu einer Reduzierung und 20-mal zu einer Erhöhung.¹




Abbildung 106: Identifizierte Ereignisinstanzen zur Überprüfung der Auswirkungen von Kundenaufträgen ohne Kreditprüfung auf die Forderungsausfälle

Bei der nun folgenden Analyse der *Ereignisbeziehungen* sind die Ereignisinstanzen zu komplementären Ereignispaaren zu verknüpfen (siehe Abschnitt 6.4.3). Ursachen- und Wirkungseignisse lassen sich auf Basis der achtwöchigen Frist einander zuordnen, da die zweifelhaften Forderungen in der achten Woche nach Rechnungsstellung gebucht werden. So sind zum Beispiel die in der Kalenderwoche 33 gebuchten Forderungsausfälle in der Kalenderwoche 25 bearbeitet worden (siehe Abbildung 106). Bei diesem paarweisen Vergleich erhält man 29 komplementäre Ereignispaare sowie je sieben „wirkungslöse“ Ursachenereignisse und „ursachenlose“ Wirkungseignisse. Als Maß für die Stärke des Kausal-

¹ In Kalenderwoche n liegt eine Erhöhung bzw. Reduzierung vor, wenn die darauffolgende Kalenderwoche n + 1 einen höheren bzw. niedrigeren Merkmalswert ausweist.

zusammenhangs wurde zusätzlich der Korrelationskoeffizient nach Pearson berechnet. Mit 0,76 weist dieser eine starke Korrelation zwischen den Kundenaufträgen ohne Kreditprüfung und den zugehörigen Forderungsausfällen aus.

Um speziell den Kausaleinfluss von manuellen Auftragsfreigaben zu überprüfen, müssen die Forderungsausfälle auf den Teilbereich eingeschränkt werden, der allein auf manuell freigegebene Aufträge zurückzuführen ist. Andernfalls wären in den Daten auch die Forderungsausfälle von Aufträgen enthalten, die aufgrund der Risikoklasse des Kunden ohne Kreditprüfungen bearbeitet wurden (siehe Abbildung 91: d5).

Abbildung 107 zeigt, welche Ereignisinstanzen bei der Analyse der *Objekt-Ereignis-Beziehungen* für die manuell freigegebenen Aufträge sowie die daraus resultierenden Forderungsausfälle identifiziert wurden.




Abbildung 107: Identifizierte Ereignisinstanzen zur Überprüfung der Auswirkungen manueller Auftragsfreigaben auf die Forderungsausfälle

Bei den Forderungsausfällen konnten 18 erhöhende und 15 reduzierende Ereignisinstanzen identifiziert werden. Die manuell freigegebenen Aufträge haben sich 19-mal reduziert und 16-mal erhöht.

Der Analyse der *Ereignisbeziehungen* lag ebenfalls die Zuordnungsbeziehung der achtwöchigen Buchungsfrist nach Rechnungsstellung zugrunde (siehe Abbildung 106). Bei der Analyse wurden 27 komplementäre Ereignispaare sowie acht „wirkungslöse“ Ursachenergebnisse und fünf „ursachenlose“ Wirkungsergebnisse identifiziert. Dementsprechend konnte mit einem Korrelationskoeffizienten von 0,82 ein starker Zusammenhang nachgewiesen werden.

Wie diese Analyseergebnisse im Hinblick auf die Gültigkeit der Kausalhypothesen zu interpretieren sind, zeigt der folgende Abschnitt der Lösungstransformation.

7.2.3.4 Lösungstransformation

Bei der Lösungstransformation sind die Analyseergebnisse hinsichtlich ihrer Verständlichkeit, Neuheit, Gültigkeit und Nützlichkeit zu bewerten (siehe Abschnitt 6.2.4).

In Bezug auf die *Verständlichkeit* konnten die Analyseergebnisse auf Anhand in nachvollziehbare Aussagen über den Objektbereich übersetzt werden: Die Anzahl der bearbeiteten Aufträge ohne Kreditprüfung nimmt von der ersten Kalenderwoche bis zur Kalenderwoche 26, dem Ende der Verkaufssaison, relativ gleichmäßig zu (siehe Abbildung 106). Anders hingegen die manuell freigegebenen Aufträge, die von der zweiten bis zur 14. Kalenderwoche sehr langsam ansteigen, um dann fast exponentiell anzusteigen (siehe Abbildung 107). Im Nachsaisonbereich - nach Kalenderwoche 27 - fallen beide Kurven erwartungsgemäß ab. Verständlich war auch, dass die Kurven der zweifelhaften Forderungen um acht Kalenderwochen nach rechts verschoben sind, da diese bei Zahlungsverzug acht Wochen nach der Rechnungsstellung gebucht werden.

Unter dem Aspekt der *Neuheit* fiel auf, dass die manuell freigegebenen Aufträge über einen Zeitraum von 20 Wochen zunehmend schwanken und eine Art Sägezahnkurve bilden (siehe Abbildung 106). Im zweiwöchigen Rhythmus erhöhen und reduzieren sich die Aufträge mit manuellen Auftragsfreigaben. An diesem Verlauf entzündete sich anfangs eine Diskussion über die Frage nach der *Gültigkeit* der Analyseergebnisse. Diese wurde aber letztlich aus zwei Gründen nicht angezweifelt: zum einen, weil die Daten des Data-Warehouses im Rahmen des ETL-Prozesses bereits bereinigt und verschiedenen Plausibilitätsprüfungen unterzogen wurden, zum anderen, weil dieses merkwürdige Datenmuster mit dem zweiwöchigen Reviewzyklus erklärt werden konnte, in dem die Mitarbeiter des Kundenservice sich über Auftragsrückstände und -sperrungen informieren und schließlich über manuelle Auftragsfreigaben entscheiden (siehe Abschnitt 7.1.1.2). Dass Abbildung 106 dennoch für *jede* Woche manuell freigegebene Aufträge ausweist, liegt daran, dass die Aufträge nicht zum Zeitpunkt ihrer manuellen Auftragsfreigabe, sondern zum Zeitpunkt der Lieferscheinerstellung verzeichnet sind.

Diese Interpretation bestätigte die Mitarbeiter der Finanzabteilung in ihrer Vermutung, dass der Kundenservice den Großteil der Aufträge zu schnell und vor allem unnötig freigibt. Denn aus der Kurve sei ersichtlich, dass der Kundenservice vorrangig solche Aufträge freigibt, die erst in den letzten Tagen unmittelbar vor dem zweiwöchigen Review gesperrt wurden. Sehr viel weniger Aufträge werden hingegen manuell freigegeben, die unmittelbar nach dem letzten Review und somit in der *ersten* Woche des zweiwöchigen Reviewzyklus gesperrt wurden. Denn die meisten dieser Aufträge, so die Vermutung der Finanzabteilung, wurden bereits in der Zwischenzeit wieder vom SAP-System automatisch freigegeben, so dass keine manuelle Auftragsfreigabe mehr nötig war.

Zuletzt galt es, die Frage nach der *Nützlichkeit* der Ergebnisse zu beurteilen. Inwiefern belegen die Ergebnisse die Gesetzmäßigkeit und Chronologie des Kausalzusammenhangs zwischen den manuellen Auftragsfreigaben und der Höhe der Forderungsausfälle? Dass für beide Kausalzusammenhänge ein Korrelationskoeffizient von 0,78 bzw. 0,82 ausgewiesen werden konnte, kann als eindeutiger Hinweis auf die Gültigkeit der Kausalhypothesen gewertet werden. Dass die manuellen Auftragsfreigaben einen kausalen Einfluss auf die Höhe der Forderungsausfälle ausüben, sieht man auch daran, dass ihr sägezahnartiges Muster vor allem am Saisonende den Verlauf der Forderungsausfälle *aller* Kundenaufträge ohne Kreditprüfung prägt (siehe Abbildung 106: Kalenderwochen 26 bis 38). Allerdings belegen die „wirkungslosen“ Ursachenereignisse eindeutig, dass der kausale Geltungsbereich beider Kausalhypothesen nicht korrekt abgegrenzt ist. Um genauer zu verstehen, welche manuellen Auftragsfreigaben Forderungsausfälle verursachen und welche nicht, müsste eine *Analyse der Ereignis-Objekt-Beziehungen* durchgeführt werden. Ziel dieser Analyse wäre es, die beiden Arten der manuell freigegebenen Aufträge anhand ihrer spezifischen Merkmalswerte voneinander abzugrenzen. Wie sich eine solche Analyse datengetrieben durchführen lässt, wurde bereits in Abschnitt 7.2.2.3 gezeigt, als mithilfe von Entscheidungsbaumverfahren die Unterschiede zwischen verschiedenen Arten von Auftragsstornierungen entdeckt wurden.

7.2.4 Modellzentrierte Überprüfung von Kausalhypothesen

Anknüpfungspunkt der modellzentrierten Hypothesenprüfung waren die Kausalhypothesen der datenzentrierten Entwicklung (siehe Abschnitt 7.2.2). Nachdem mit der Data-Mining-Analyse konkrete Hinweise auf gültige Kausalhypothesen vorliegen, gilt es nun, diese auf modellzentriertem Wege zu überprüfen. Die

modellzentrierte Überprüfung konnte sehr viel schneller durchgeführt werden als deren datenzentrierte Entwicklung. Insgesamt dauerte die modellzentrierte Überprüfung etwas mehr als eine Woche. Ebenso wie die anderen drei Gestaltungsoptionen gliedert sich auch dieser Teil des Analyseprozesses in die vier Phasen der Zieltransformation, Modellkonstruktion, Verfahrensanwendung und Lösungstransformation.

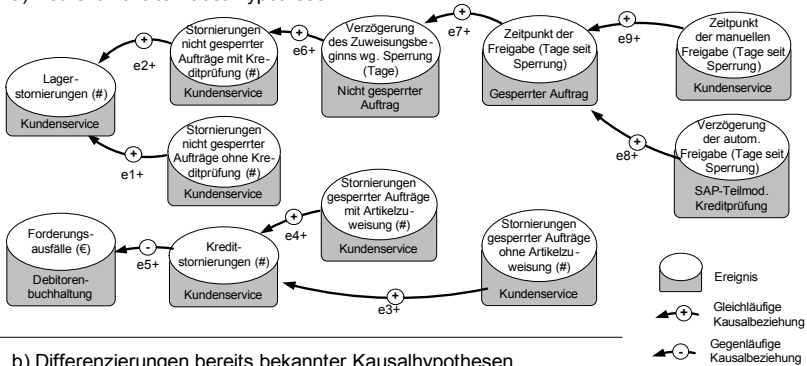
7.2.4.1 Zieltransformation

Die Phase der Zieltransformation besteht aus zwei Prozessschritten: der Spezifikation des originären Untersuchungsproblems sowie der Transformation des Untersuchungsziels in ein Modellziel (siehe Abschnitt 6.3.1).

Das Untersuchungsobjekt ist nach wie vor der Kundenauftragsprozess, für dessen Performance-Management ein aussagekräftiges Kennzahlensystem zu entwickeln ist. Die Kausalhypothesen der datenzentrierten Entwicklung beschreiben die Auswirkungen von Lager- und Kreditstornierungen auf die Umsatzeinbußen sowie die kausalen Abhängigkeiten zwischen den beiden Stornierungsarten (siehe Abbildung 104). Während die einen Hypothesen diejenigen Kausalzusammenhänge differenzieren, die modellzentriert entwickelt wurden (siehe Abschnitt 7.2.1), knüpfen die anderen Hypothesen neue Kausalbeziehungen zwischen bereits vorhandenen und neu formulierten Ereignissen. Abbildung 108 fasst die zu überprüfenden Kausalbeziehungen der datenzentrierten Hypothesenentwicklung unter diesem Aspekt zusammen.

Das Modellziel besteht darin, für beide Arten von Kausalhypothesen eine kausale Infrastruktur zu finden, die aufzeigt, auf welchen Objektbeziehungen die Kausalbeziehungen beruhen. Um das Modellziel zu konkretisieren, sind die Ursachen- und Wirkungereignisse jeder Kausalhypothese zu spezifizieren und jeweils dem Objekttyp zuzuordnen, der als Ereignisträger fungiert. Diese Objekttypen bilden in der darauf folgenden Phase die Startpunkte für die Modellkonstruktion. Da jedoch bereits sämtliche Ereignisse und Ereignisträger im Zuge der modell- und datenzentrierten Hypothesenentwicklung spezifiziert wurden, kann dieser Schritt übersprungen und unmittelbar mit der nächsten Phase, der Modellkonstruktion, begonnen werden.

a) Neu entwickelte Kausalhypothesen



b) Differenzierungen bereits bekannter Kausalhypothesen

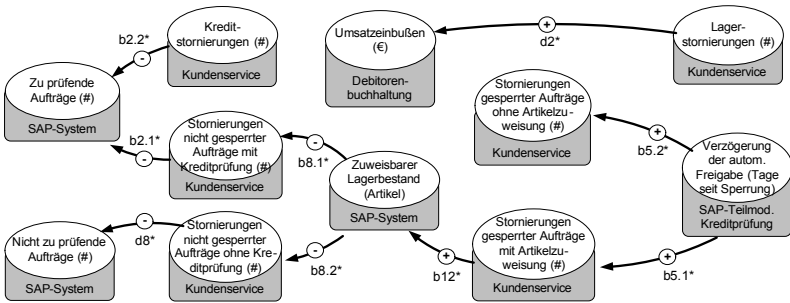


Abbildung 108: Zu überprüfende Kausalhypothesen der datenzentrierten Entwicklung

7.2.4.2 Modellkonstruktion

Aufgaben der Modellkonstruktion ist es, all die Objekttypen und -beziehungen in einem Modell abzubilden, die für die zu überprüfenden Kausalhypothesen als kausale Infrastruktur infrage kommen. Dies geschieht in zwei Prozessschritten: Zuerst ist zu prüfen, ob sich die Ursachen- oder Wirkungsereignisse präzisieren lassen. Im zweiten Schritt nutzt man die ereignistragenden Objekttypen als Ausgangspunkt für die Modellierung des Objektbereichs (siehe Abschnitt 6.3.2).

Im *ersten Prozessschritt* konnten lediglich zwei Ereignisse präzisiert werden: die Erhöhung bzw. Reduzierung der zu prüfenden bzw. nicht zu prüfenden Kundenaufträge im SAP-SYSTEM (siehe Abbildung 109). Beide Ereignisse sind als Aggregationsereignisse dem aggregierten Objekttyp SAP-SYSTEM zugeordnet und

beziehen sich auf den Teilobjekttyp KUNDENAUFTRAG und dessen Subobjekttypen ZU PRÜFENDER AUFTRAG und NICHT ZU PRÜFENDER AUFTRAG. Da beide Ereignisse die Auswirkung einer Stornierung beschreiben, lassen sie sich auch als unidirektionale Typwechselereignisse beschreiben, bei denen der jeweilige Auftrag im Zuge einer Stornierung seine aktuelle Typzuordnung verliert und ein stornierter Auftrag wird.

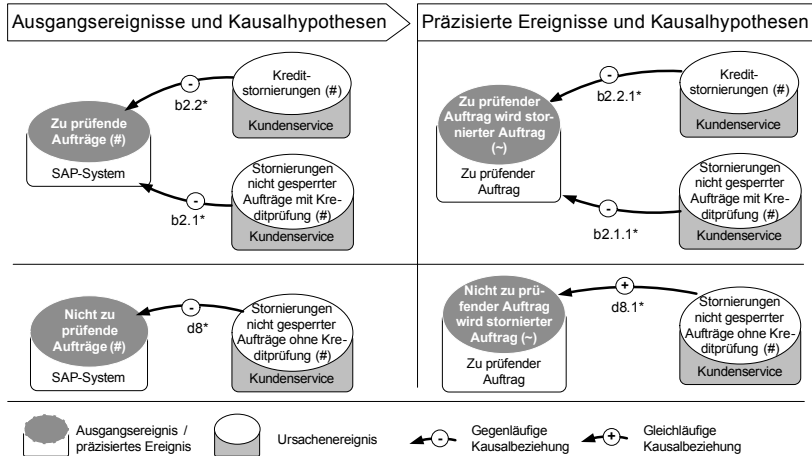


Abbildung 109: Präzisierung von Ereignissen und Kausalhypothesen

Beim *zweiten Prozessschritt*, der Modellierung des Objektbereichs, konnte zwar an das bereits vorhandene Objektmodell der modellzentrierten Hypothesenentwicklung angeknüpft werden (siehe Abschnitt 7.2.1.2), es mussten allerdings weitere Objekttypen und -beziehungen hinzugefügt werden, die im Folgenden erläutert werden (siehe Abbildung 110).

Ausgehend von den Ereignis- und Objektdifferenzierungen der datenzentrierten Hypothesenentwicklung (siehe Abbildung 103, Seite 282) wurden zunächst dem Objekttyp NICHT STORNIERTER AUFTRAG zwei neue Subobjekttypen zugeordnet: AUFTRAG MIT ARTIKELZUWEISUNG und AUFTRAG OHNE ARTIKELZUWEISUNG. Diese Subobjekttypen bieten neben der Unterscheidung in ZU PRÜFENDE AUFTRÄGE und NICHT ZU PRÜFENDE AUFTRÄGE eine weitere Möglichkeit zur Auftragsdifferenzierung.

Die zweite Ergänzung des Objektmodells bezieht sich auf das SAP-SYSTEM, dem der neue Teilobjekttyp LAGERARTIKEL hinzugefügt wurde. Dieser unterteilt

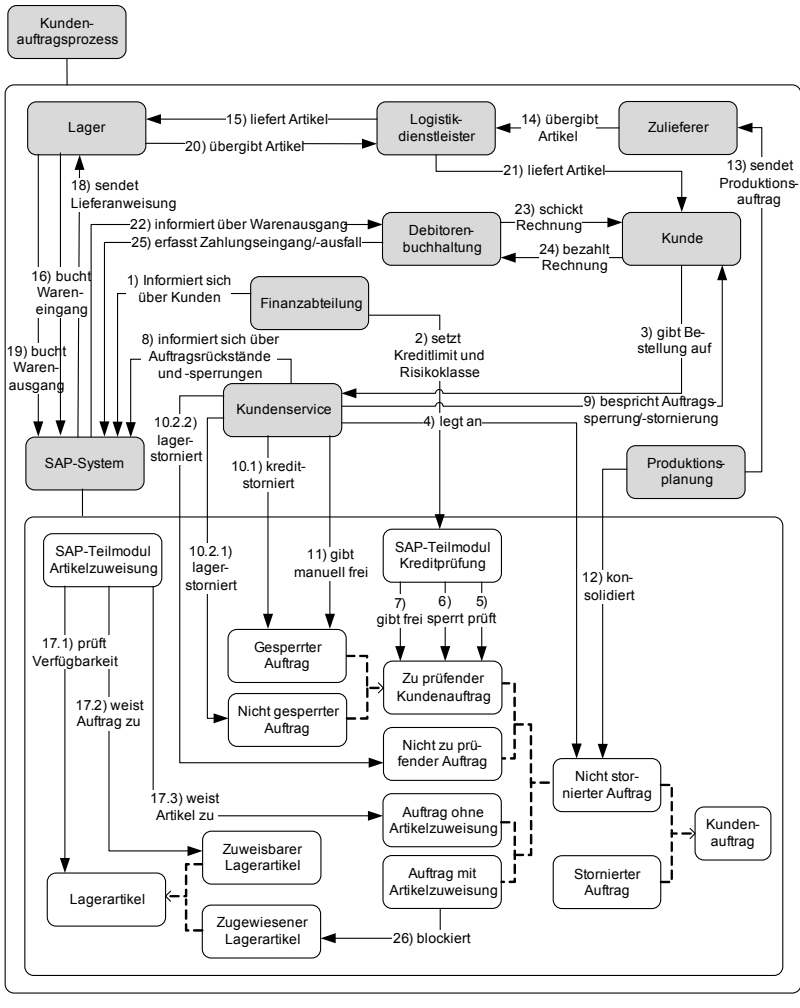


Abbildung 110: Objektmodell der modellzentrierten Hypothesenprüfung

sich in die beiden Subobjekttypen ZUWEISBARER LAGERARTIKEL und ZUGEWIESENER LAGERARTIKEL. Auf Basis dieses erweiterten Objektvokabulars lässt sich nun auch die Interaktion der Artikelzuweisung differenzierter beschreiben. Vor der

Zuweisung überprüft das SAP-TEILMODUL DER ARTIKELZUWEISUNG die Verfügbarkeit der LAGERARTIKEL (siehe Abbildung 110: 17.1). Ist ein bestellter Artikel im Lager verfügbar, wird ihm der Auftrag zugewiesen (17.2). Gleichzeitig werden einem AUFTRAG OHNE ARTIKELZUWEISUNG die Lagerartikel zugewiesen (17.3). Dadurch verliert ein Artikel vom Typ ZUWEISBARER LAGERARTIKEL seine Typzugehörigkeit und wird ein ZUGEWIESENER LAGERARTIKEL. Als solcher wird er von seinem zugewiesenen Auftrag für andere Zuweisungen geblockt (26).

Die letzte Ergänzung trägt der in Abschnitt 7.2.2.4 getroffenen Ereignisdifferenzierung Rechnung (siehe Abbildung 103, Seite 282). Parallel zu den auf der Ereignissebene unterschiedenen Stornierungsarten wurden auch auf der Objektebene die zugehörigen Interaktionen spezifiziert. Statt eines NICHT STORNIERTEN AUFTRAGS storniert der KUNDENSERVICE einen GESPERRTEN AUFTRAG aus Kreditgründen (10.1), einen NICHT GESPERRTEN AUFTRAG (10.2.1) bzw. einen NICHT ZU PRÜFENDEN AUFTRAG aus Lagergründen (10.2.2). Die anderen Objekttypen und -beziehungen wurden unverändert aus dem Objektmodell der modellzentrierten Hypothesenentwicklung übernommen.

Auf Basis dieses erweiterten Objektmodells kann nun in der Phase der Verfahrensanwendung untersucht werden, ob sich die kausalen Wirkmechanismen auf der Objektebene nachvollziehen und begründen lassen.

7.2.4.3 Verfahrensanwendung

Um die Bedingtheit der Kausalhypothesen nachzuweisen, ist im *ersten Prozessschritt* die kausale Infrastruktur zu bestimmen. Gelingt es nicht, diese auf Basis des konstruierten Objektmodells adäquat zu beschreiben, ist die Kausalhypothese im *zweiten Prozessschritt* zu plausibilisieren. Hierbei können dem Objektmodell entweder neue Infrastrukturbeziehungen hinzugefügt, bereits vorhandene Objektbeziehungen präzisiert oder der kausale Geltungsbereich angepasst werden (siehe Abschnitt 6.3.3). Das in Abbildung 110 dargestellte Objektmodell ist somit zwar die gemeinsame Ausgangsbasis aller Hypothesenprüfungen, allerdings wurden die darin enthaltenen Objektbeziehungen für einige Kausalhypothesen unterschiedlich erweitert oder präzisiert (siehe Abbildung 111).

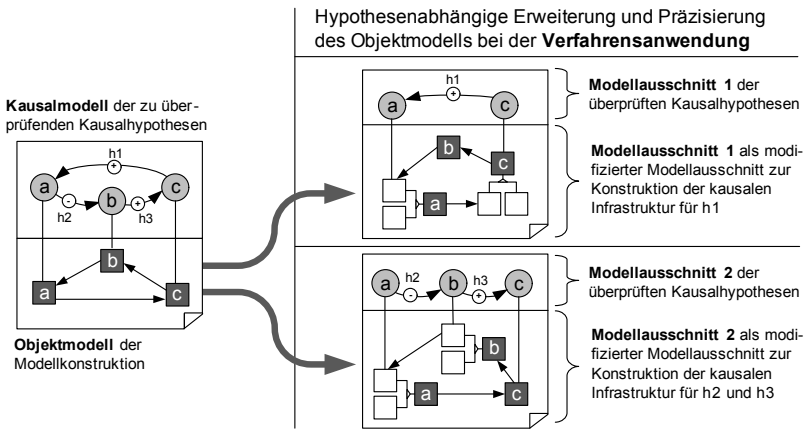


Abbildung 111: Hypothesenabhängige Erweiterung und Präzisierung des Objektmodells

Als Erstes wurden die Kausalhypothesen untersucht, deren Wirkungsereignisse im Rahmen der Modellkonstruktion präzisiert wurden (siehe Abbildung 109). Die beiden Kausalhypothesen b2.1.1* und b2.2.1* sagen aus, dass ein ZU PRÜFENDER AUFTRAG zu einem STORNIERTEN AUFTRAG wird, falls der KUNDENSERVICE eine Kreditstornierung vornimmt (10.1) oder einen NICHT GESPERRTEN AUFTRAG mit Kreditprüfung aus Lagergründen storniert (10.2.1). Aus dem Objektmodell ergibt sich, dass ein GESPERRTER AUFTRAG automatisch ein ZU PRÜFENDER AUFTRAG ist (siehe Abbildung 110). Und eine Kreditstornierung die Stornierung eines GESPERRTEN AUFTRAGS ist (10.1), wird damit auch ein ZU PRÜFENDER AUFTRAG zu einem STORNIERTEN AUFTRAG. Dasselbe gilt für die Lagerstornierung eines NICHT GESPERRTEN AUFTRAGS (10.2.1), der ebenfalls ein ZU PRÜFENDER AUFTRAG ist. Laut der Kausalhypothese d8.1* sorgt die Stornierung eines nicht gesperrten Auftrags ohne Kreditprüfung dafür, dass ein NICHT ZU PRÜFENDER AUFTRAG ein STORNIERTER AUFTRAG wird. Die dem Stornierungsereignis zugrunde liegende Interaktion 10.2.2 verursacht genau diesen Typwechsel.

Als Nächstes wurde die Bedingtheit der beiden Kausalhypothesen b5.1* und b5.2* überprüft. Beide Kausalhypothesen sagen aus, dass sich die Anzahl der Kreditstornierungen, speziell die von gesperrten Aufträgen mit und ohne Artikelzuweisung, erhöht, falls sich beim SAP-TEILMODUL DER KREDITPRÜFUNG die automatische Auftragsfreigabe verzögert. Dieser Zusammenhang lässt sich in seinen Grundzügen bereits auf Basis des ursprünglichen Objektmodells nachvollziehen: Von einem GESPERRTEN AUFTRAG, der nach Ablauf der 60-Tage-Frist nach Kun-

denwunschtermin noch immer gesperrt ist, erfährt der KUNDENSERVICE aus dem SAP-SYSTEM (8). Diese Aufträge kann er daraufhin aus Kreditgründen stornieren (10.1). Diese kausale Infrastruktur erklärt an dieser Stelle aber noch nicht eindeutig, warum die verzögerte Auftragsfreigabe nicht auch Lagerstornierungen (10.2.1, 10.2.2) verursachen könnte. Um dies zu verdeutlichen, wurde das ursprüngliche Objektmodell in Abbildung 112 wie folgt modifiziert. Insbesondere mussten die drei Auftragsdifferenzierungen folgender Subobjekttypen neu kombiniert werden:

- GESPERRTER AUFTRAG und NICHT GESPERRTER AUFTRAG
- ZU PRÜFENDER AUFTRAG und NICHT ZU PRÜFENDER AUFTRAG
- AUFTRAG MIT ARTIKELZUWEISUNG und AUFTRAG OHNE ARTIKELZUWEISUNG

Zunächst wurde die Information des SAP-Systems über Auftragsrückstände und -sperrungen auf zwei Interaktionsbeziehungen aufgeteilt (siehe Abbildung 112: 8.1 und 8.2). Abhängig davon, ob sich der KUNDENSERVICE über Rückstände oder Sperrungen informiert, nimmt er eine Kredit- oder Lagerstornierung vor. Für die Kausalhypothesen b5.1* und b5.2* bedeutet das, dass gemäß der kausalen Infrastruktur ein ÜBER SPERRUNGEN INFORMIERTER KUNDENSERVICE nur eine Kreditstornierung (10.1, 10.1.1, 10.1.2), nicht aber eine Lagerstornierung (10.2, 10.2.1, 10.2.2) vornehmen kann.

Die nächsten Kausalhypothesen, deren Infrastruktur nachgewiesen wurde, waren die Hypothesen e3+ und e4+. Ihr gemeinsames Wirkungsereignis, die Kreditstornierung, bezieht sich auf die Interaktion zwischen dem ÜBER SPERRUNGEN INFORMIERTEN KUNDENSERVICE und einem GESPERRTEN AUFTRAG (10.1). Die beiden Ursachenereignisse sind eine spezielle Art der Kreditstornierung und sind entsprechend als Stornierung eines Subobjekttyps eines GESPERRTEN AUFTRAGS modelliert (10.1.1, 10.1.2). Die kausale Infrastruktur erstreckt sich daher entlang der Typbeziehung zum gemeinsamen Superobjekttyp GESPERRTER AUFTRAG. Jede Stornierung eines gesperrten Auftrags ohne (10.1.1) bzw. mit Artikelzuweisung (10.1.2) ist per Definition eine Kreditstornierung eines GESPERRTEN AUFTRAGS (10.1). Dasselbe gilt für die Kausalhypothesen e1+ und e2+: Während dem gemeinsamen Wirkungsereignis der Lagerstornierung die Interaktion mit dem Superobjekttyp NICHT GESPERRTER AUFTRAG zugrunde liegt, entsprechen die beiden Ursachenereignisse den Stornierungen der Subobjekttypen (10.2.1, 10.2.2).

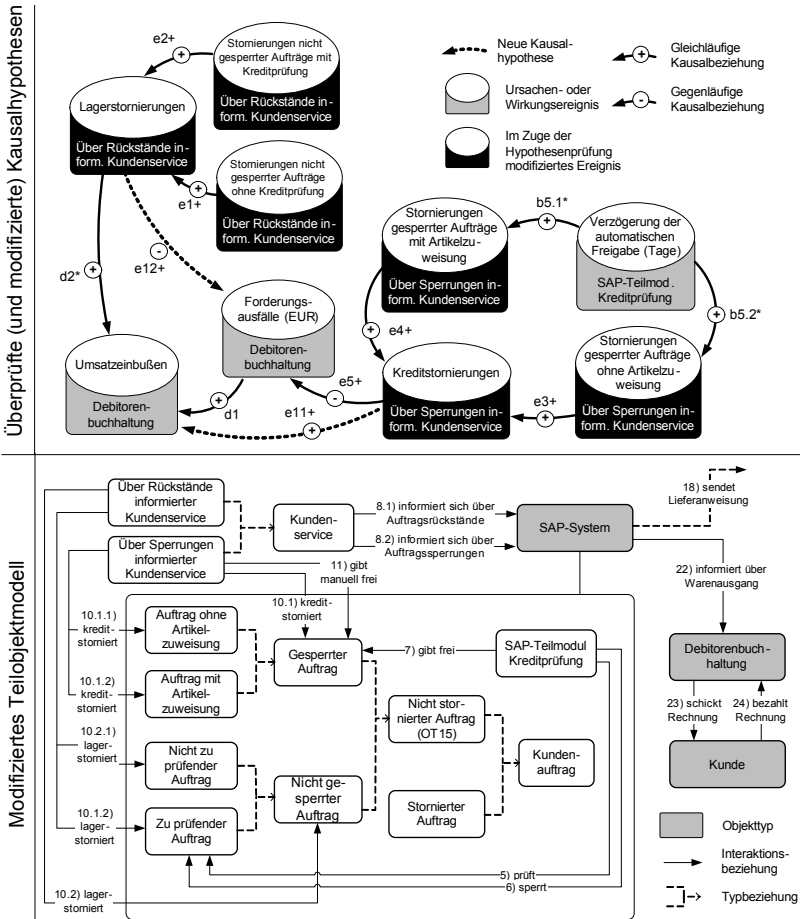


Abbildung 112: Modifiziertes Kausal- und Objektmodell (Modellausschnitt eins)

Als Nächstes wurde die kausale Infrastruktur der beiden Hypothesen d2* und e5+ untersucht. Lagerstornierungen führen zu Umsatzeinbußen, da ein STORNIERTER AUFTRAG nicht mehr bearbeitet wird und somit auch keinen Umsatz mehr erzielt; zum einen, weil ein STORNIERTER AUFTRAG keine LAGERARTIKEL mehr zugewiesen bekommt (siehe Abbildung 112: 17.3), zum anderen, weil das SAP-SYSTEM keine Lieferanweisungen an das LAGER mehr schickt (18). Hier zeigte sich, dass das Kausalmodell unvollständig war. Denn auch eine Kreditstor-

nierung bewirkt einen Abbruch des Kundenauftragsprozesses und verhindert, dass mehr Umsatz generiert wird. Deshalb wurde dem Objektmodell die Kausalhypothese e11+ hinzugefügt, die besagt, dass auch eine Kreditstornierung die Umsatzeinbußen erhöhen kann (siehe Abbildung 112).

Die beiden Hypothesen d2* und e11+ setzten jedoch voraus, dass der Kunde bei einer erfolgreichen Auftragsbearbeitung die gestellte Rechnung (23) auch ordnungsgemäß beglichen hätte (24). Andernfalls hätte man mit der Kredit- bzw. Lagerstornierung einen Forderungsausfall verhindert. Doch genau dies belegt das Objektmodell nicht eindeutig. Denn unabhängig davon, warum ein Auftrag storniert wurde, kann dadurch ein Forderungsausfall verhindert worden sein - oder auch nicht. Aus diesem Grund muss ergänzend zur Kausalhypothese e5+ auch die Hypothese e12+ eingefügt werden. Diese zeigt an, dass auch Lagerstornierungen Forderungsausfälle reduzieren können. Das bedeutet aber, dass die Auswirkungen von Lager- und Kreditstornierungen auf die Umsatzeinbußen keineswegs mehr so eindeutig sind, wie sie auf Basis der datenzentrierten Hypothesenentwicklung ursprünglich angenommen wurden (siehe Abbildung 104, Seite 284).

Um die kausale Infrastruktur der anderen Kausalhypothesen offenzulegen, wurde das Objektmodell erneut modifiziert. Gemäß der Kausalhypothesen e8+ und e9+ hängt der Zeitpunkt der Auftragsfreigabe eines GESPERRTEN AUFTRAGS davon ab, wann der KUNDENSERVICE oder das SAP-TEILMODUL DER KREDITPRÜFUNG den Auftrag manuell bzw. automatisch freigibt (siehe Abbildung 113: 7, 11). Die kausale Infrastruktur der Kausalhypothese e8+ lässt sich vom Ereignisträger des SAP-TEILMODULS DER KREDITPRÜFUNG über die Interaktionsbeziehung der automatischen Freigabe (7) hin zum GESPERRTEN AUFTRAG verfolgen, der gleichzeitig Träger des Wirkungsereignisses ist. Bei der Überprüfung der Kausalhypothese e9+ fiel jedoch auf, dass nicht mehr der Superobjekttyp KUNDENSERVICE als Ereignisträger infrage kommt, sondern nur noch sein Subobjekttyp, der ÜBER SPERRUNGEN INFORMIERTE KUNDENSERVICE. Denn schließlich erstreckt sich von diesem Subobjekttyp aus die Interaktionsbeziehung der manuellen Freigabe hin zum Träger des Wirkungsereignisses, dem GESPERRTEN AUFTRAG (12).

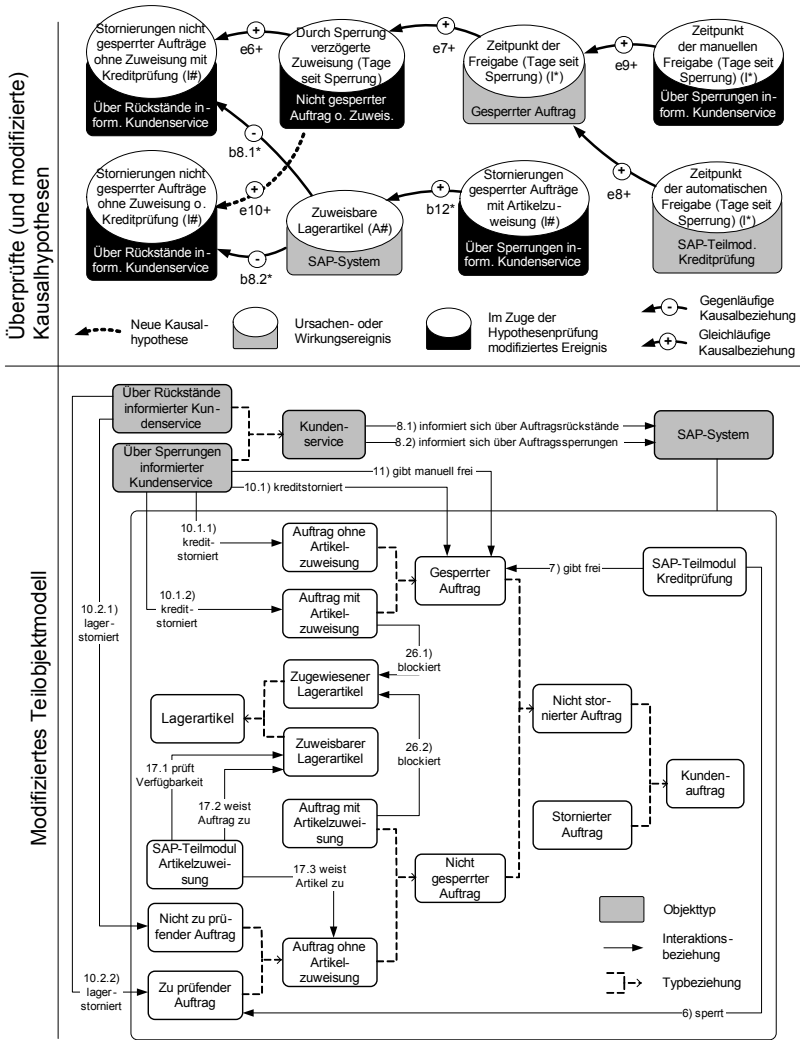


Abbildung 113: Modifiziertes Kausal- und Objektmodell (Modellausschnitt zwei)

Die Kausalhypothese e7 + gibt vor, dass der Zeitpunkt der Auftragsfreigabe den Zuweisungsbeginn beeinflusst. Während sich das Ursachenergebnis auf einen GESPERRTEN AUFTRAG bezieht, liegt dem Wirkungsereignis ein ZU PRÜFENDER AUF-

TRAG zugrunde. Mit Blick auf das in Abbildung 113 dargestellte Objektmodell erscheint der kausale Geltungsbereich allerdings unangemessen:

- Einerseits ist der Geltungsbereich *zu weit gefasst*, da sich nur bei einem AUFTRAG OHNE ARTIKELZUWEISUNG der Zuweisungsbeginn verzögern kann. Sind einem GESPERRTEN AUFTRAG bereits Artikel zugewiesen, hat der Zeitpunkt seiner Freigabe keinen Einfluss mehr auf den Zuweisungsbeginn.
- Andererseits ist der Geltungsbereich *zu eng gefasst*, da der Kausalzusammenhang nicht nur für ZU PRÜFENDE AUFTRÄGE, sondern auch für NICHT ZU PRÜFENDE AUFTRÄGE gilt. Denn gibt der KUNDENSERVICE einen ZU PRÜFENDEN AUFTRAG manuell frei, wird dieser ein NICHT ZU PRÜFENDER AUFTRAG, dessen Zuweisungsbeginn sich dadurch ebenfalls verzögern kann.

Passt man den kausalen Geltungsbereich auf Basis dieser Überlegungen an, kommt als Ereignisträger für das Wirkungsereignis nur ein NICHT GESPERRTER AUFTRAG OHNE ARTIKELZUWEISUNG infrage (siehe Abbildung 113). Die kausale Infrastruktur verläuft daher vom Ereignisträger des Ursachenereignisses, dem GESPERRTEN AUFTRAG, über die Typbeziehungen zum Ereignisträger des Wirkungsereignisses, dem NICHT GESPERRTEN AUFTRAG OHNE ARTIKELZUWEISUNG.

Da sich die Kausalhypothesen $e7+$ und $e6+$ dasselbe Ereignis als Wirkungs- bzw. Ursachenereignis teilen, betrifft der Wechsel des Ereignisträgers auch die Hypothese $e6+$. Diese besagt nun, dass eine verzögerte Artikelzuweisung bei einem NICHT GESPERRTEN AUFTRAG OHNE ARTIKELZUWEISUNG dazu führen kann, dass der Kundenservice einen NICHT GESPERRTEN AUFTRAG MIT KREDITPRÜFUNG storniert. Ausgehend vom Ereignisträger des Ursachenereignisses lässt sich die kausale Infrastruktur über die Typbeziehungen hin zum Superobjekttyp KUNDEN-AUFTRAG verfolgen. Dieser ist aufgrund der Aggregationsbeziehung ein Teilobjekttyp des SAP-SYSTEMS, auf das der KUNDENSERVICE zugreift, um sich über Auftragsrückstände zu informieren (8.1). Der ÜBER RÜCKSTÄNDE INFORMIERTE KUNDENSERVICE storniert daraufhin aber nicht nur einen nicht gesperrten Auftrag mit Kreditprüfung (10.2.2), sondern auch einen nicht gesperrten Auftrag ohne Kreditprüfung (10.2.1). Auf Basis dieser Infrastrukturbeziehungen wurde das Kausalmodell in drei Punkten angepasst (siehe Abbildung 113):

1. Ereignisträger des Wirkungsereignisses ist nicht mehr der Kundenservice, sondern der über Rückstände informierte Kundenservice ($e6+$).

2. Die Formulierung des Wirkungsereignisses wurde so abgeändert, dass der Kundenservice nicht gesperrte Aufträge mit Kreditprüfung storniert, die noch ohne Artikelzuweisung sind (e6+).
3. Es wurde die neue Kausalhypothese e10+ eingefügt, die den Zusammenhang zwischen der verzögerten Artikelzuweisung und der Stornierung von Aufträgen ohne Kreditprüfung herstellt.

Laut den Kausalhypothesen b8.1* und b8.2* verhindert eine Erhöhung des zuweisbaren Lagerbestands die beiden Arten von Lagerstornierungen. Dieser Einfluss beruht auf der Interaktionsbeziehung 17.1, über die das SAP-TEILMODUL DER ARTIKELZUWEISUNG die Verfügbarkeit der ZUWEISBAREN LAGERARTIKEL prüft. Erst wenn deren Verfügbarkeit sichergestellt ist, führt das SAP-Teilmodul die Artikelzuweisung durch (17.2, 17.3). Der NICHT GESPERRTE AUFTRAG OHNE ARTIKELZUWEISUNG wird dadurch ein NICHT GESPERRTER AUFTRAG MIT ARTIKELZUWEISUNG. Und da der KUNDENSERVICE nur einen AUFTRAG OHNE ARTIKELZUWEISUNG aus Lagergründen storniert, sorgt ein ausreichend zuweisbarer Lagerbestand dafür, dass das SAP-SYSTEM weniger Aufträge mit Zuweisungsrückstand ausweist (8.1), die der Kundenservice dann aus Lagergründen stornieren müsste (10.2.1 und 10.2.2).

Die letzte zu überprüfende Kausalhypothese stellt einen Zusammenhang zwischen der Stornierung eines gesperrten Auftrags mit Artikelzuweisung und der Anzahl der zuweisbaren Lagerartikel her (b12*). Da es sich bei dem Ursachenereignis um eine Kreditstornierung handelt, lässt sich auch hier der ereignisstragende Objekttyp austauschen und durch den ÜBER SPERRUNGEN INFORMIERTEN KUNDENSERVICE ersetzen (siehe Abbildung 113). Dieser Kreditstornierung liegt die Interaktion 10.1.2 zugrunde, die einen GESPERRTEN AUFTRAG MIT ARTIKELZUWEISUNG in einen STORNIERTEN AUFTRAG transformiert. Da ein STORNIERTER AUFTRAG keine Lagerartikel mehr blockiert, verliert mit der Stornierung auch ein bereits ZUGEWIESENER LAGERARTIKEL seine Auftragsbeziehung (26.1, 26.2) und wird wieder zu einem ZUWEISBAREN LAGERARTIKELN.

Die Phase der Verfahrensanwendung ist damit abgeschlossen. In der vierten und letzten Phase, der Lösungstransformation, sind die Analyseergebnisse zu bewerten.

7.2.4.4 Lösungstransformation

Ziel dieser Phase ist es, die Interessantheit der kausalen Infrastrukturen zu prüfen. Die Bewertungskriterien sind wiederum die Verständlichkeit, Neuheit, Gültigkeit und Nützlichkeit der Analyseergebnisse (siehe Abschnitt 6.3.4).

Unter dem Aspekt der *Verständlichkeit* wurde geprüft, ob die Mitarbeiter der Finanzabteilung und des Kundenservice die kausalen Wirkmechanismen entlang der Infrastrukturbeziehungen nachvollziehen konnten. Dies war bei allen Kausalhypothesen der Fall. Auch die drei neu hinzugefügten Kausalhypothesen e10+, e11+ und e12+ ließen sich anhand der modellierten Objekttypen und -beziehungen gut begründen.

Die *Neuheit* der Analyseergebnisse zeigte sich speziell bei der Auftragsdifferenzierung. Denn obwohl jede der verwendeten Auftragsdifferenzierungen für sich bekannt war, lag der Neuigkeitswert in ihrer flexiblen Kombination und dem Verständnis dafür, welche der daraus resultierenden Auftragsstypen wie bearbeitet werden. Auf Basis dieser Objektdifferenzierungen konnten die Interaktionsbeziehungen zwischen den Aufträgen und dem Kundenservice, der Finanzabteilung und den SAP-Teilmodulen sehr differenziert dargestellt werden. Diesem differenzierten Objektvokabular ist es zu verdanken, dass auch auf der Ereignissebene ein ebenso differenziertes Ereignisvokabular gebildet werden konnte. Dieses differenzierte Ereignis- und Objektvokabular erlaubte es schließlich, den kausalen Geltungsbereich der Hypothesen anzupassen.

Bei der Bewertung der *Gültigkeit* gilt es zu bedenken, dass die Kausalhypothesen anhand von Strukturhypothesen über Objektbeziehungen überprüft wurden, die es dem Ursachenereignis ermöglichen, das Wirkungsergebnis hervorzurufen. Ob die Kausalhypothesen gültig sind, hängt deshalb davon ab, ob die ereignistragenden Objekttypen tatsächlich von realen Objekten instanziiert werden, die in den modellierten Infrastrukturbeziehungen stehen. Untersucht wurde daher, ob im realen Kundenauftragsprozess tatsächlich die Arten von Aufträgen bearbeitet werden, wie sie als Kombination der Subjekttypen ins Modellsystem aufgenommen wurden. So ist zum Beispiel hinterfragt worden, ob sich nicht gesperrte Aufträge tatsächlich in Aufträge mit und ohne Artikelzuweisung differenzieren lassen und ob unter den Aufträgen ohne Zuweisung sowohl solche mit als auch ohne Kreditprüfung bearbeitet werden (siehe Abbildung 113). Obwohl sich derartige Strukturhypothesen sehr gut mithilfe von hypothesengetriebenen Datenanalyseverfahren überprüfen lassen, etwa mit OLAP-Verfahren

(siehe Abschnitte 6.4.1 und 6.5.2), wurde darauf im Rahmen der Fallstudie verzichtet. Sämtliche Strukturhypothesen konnten auch ohne Datenanalyse als gültig akzeptiert werden, da die Mitarbeiter des Kundenservice über langjährige Erfahrung in der Kundenauftragsbearbeitung verfügten.

Um die *Nützlichkeit* der Analyseergebnisse zu beurteilen, ist die Frage nach ihrer Erklärungskraft und des Handlungsspielraums zu bewerten, den sie dem Informationsempfänger eröffnen:

- Lassen sich die Kausalhypothesen anhand der kausalen Infrastrukturen hinreichend erklären?
- Welchen Handlungsspielraum bieten die kausalen Infrastrukturen, um die Kausalzusammenhänge zu verhindern, zu etablieren oder zu verstärken?

Die Kausalhypothesen, deren Infrastrukturbeziehung die größte Erklärungskraft zugesprochen wurde, waren die Ereignisbeziehungen, die auf typologischen Objektbeziehungen beruhten. Dies war bei den Kausalhypothesen e1+, e2+, e3+ und e4+ der Fall, die die speziellen Stornierungsarten mit den beiden generellen Stornierungsarten der Lager- bzw. Kreditstornierung verknüpfen. Die Kausalhypothesen e8+ und e9+ ließen sich ebenfalls anhand der kausalen Infrastruktur sehr gut erklären, da sie lediglich den Zeitpunkt der generellen Auftragsfreigabe mit dem Zeitpunkt der beiden speziellen Freigabearten - der automatischen und der manuellen Auftragsfreigabe - verknüpfen (siehe Abbildung 113). Auch allen anderen Kausalhypothesen wurde eine ausreichend hohe Erklärungskraft attestiert.

Lediglich bei den beiden Kausalhypothesen e11+ und e12+ stellten sich die Mitarbeiter die Frage, ob Kredit- und Lagerstornierungen *gleichermaßen* Umsatzeinbußen und Forderungsausfälle verursachen bzw. verhindern. Obwohl für beide Kausalzusammenhänge die kausale Infrastruktur vorhanden ist, war man sich einig, dass Kreditstornierungen eher Forderungsausfälle verhindern als Umsatzeinbußen verursachen. Umgekehrt sah man die Lagerstornierungen als Hauptursache für Umsatzeinbußen an. In dieser Einschätzung spiegelte sich natürlich das Vertrauen, das die Mitarbeiter der Finanzabteilung und des Kundenservice in ihre eigene Kreditprüfung setzten.

Ob dieses Vertrauen gerechtfertigt ist, kann im Rahmen einer modellzentrierten Überprüfung nicht entschieden werden. Dies ließe sich allenfalls datenzentriert überprüfen, falls die Sport AG bereit wäre, folgendes TestszENARIO zu kreieren: Es müsste bewusst eine Gruppe A von Aufträgen nicht kreditstorniert werden, obwohl es die Kreditsituation ihrer Kunden erfordern würde. In

einer zweiten Gruppe B müsste man Aufträgen zu Lasten anderer Aufträge Artikel zuweisen, um dadurch gezielt eine sonst fällige Lagerstornierung zu verhindern. Beide Testgruppen könnten am Saisonende hinsichtlich ihrer Auswirkungen auf die Höhe der Forderungsausfälle verglichen werden. Das Vertrauen ließe sich rechtfertigen, wenn sich in Gruppe A überdurchschnittlich mehr Forderungsausfälle ereignen würden und in Gruppe B unterdurchschnittlich weniger.

Zur Bewertung der Nützlichkeit gehört zuletzt auch die Beurteilung des Handlungsspielraums, der sich den Mitarbeitern der Sport AG auf Basis der kausalen Infrastrukturen bietet - sei es, um erwünschte Kausalzusammenhänge zu verstärken oder um unerwünschte Zusammenhänge zu vermeiden. Dies soll anhand der Kausalbeziehung b8.2* gezeigt werden, die den zuweisbaren Lagerbestand als Ursache für lagerstornierte Aufträge ohne Kreditprüfung ausweist (siehe Abbildung 113).

Im Gegensatz zu den Aufträgen mit Kreditprüfung stammen die Aufträge ohne Prüfung meist von Kunden, die nicht nur hinsichtlich ihrer Bonität, sondern auch bezogen auf das getätigte Auftragsvolumen von größerem Interesse sind. Um zu verhindern, dass genau diese Aufträge mangels zuweisbaren Lagerbestands storniert werden, lässt sich die zugrunde liegende kausale Infrastruktur dahingehend verändern, dass der ÜBER AUFTRAGSRÜCKSTÄNDE INFORMIERTE KUNDENSERVICE im Falle eines Lagerengpasses die von einem GESPERRTEN AUFTRAG blockierten Lagerartikel wieder freigegeben kann. Als Folge könnte das SAP-TEILMODUL DER ARTIKELZUWEISUNG die freigewordenen Artikel einem NICHT ZU PRÜFENDEN AUFTRAG zuweisen. Das Objektmodell müsste hierzu um die Interaktionsbeziehung „Artikelzuweisung lösen“ ergänzt werden, mit der der KUNDENSERVICE einen GESPERRTEN AUFTRAG MIT ARTIKELZUWEISUNG in einen GESPERRTEN AUFTRAG OHNE ARTIKELZUWEISUNG überführen kann. Eine solche Maßnahme könnte als Vorstufe zur eigentlichen Kreditstornierung eingesetzt werden, zum Beispiel falls ein Auftrag nach der Hälfte der 60-Tage-Frist noch gesperrt ist. Nach wie vielen Tagen Sperrdauer der Kundenservice die Artikelzuweisung auflöst, ließe sich aber auch an den Zeitpunkt innerhalb der Saison koppeln. Am Saisonende ist das Risiko höher, dass nach einer Kreditstornierung die vormals blockierten Artikel nur noch mit Rabatten zu verkaufen sind. Um diese Erlöschmälerungen zu vermeiden, könnten die durch Sperrungen blockierten Lagerartikel umso eher solchen Aufträgen zugewiesen werden, die nicht kreditgeprüft werden, aber aufgrund mangelnder Lagerbestände drohen storniert zu werden.

8 Zusammenfassung und Schlussbetrachtung

In dieser Arbeit wurden Kausalinformationen als eine eigenständige und notwendige Informationsart für das Performance-Management vorgestellt. Sie dienen dem Performance-Management in doppelter Hinsicht als Basisinformation, nämlich zur

- Identifikation nicht-finanzieller Kennzahlen, mit denen sich aufgrund *kausaler Kennzahlbeziehungen* frühzeitig eine Gefährdung der finanziellen Zielerreichung erkennen lässt, um dann rechtzeitig Gegenmaßnahmen ergreifen zu können,
- Begründung von *Zweck-Mittel-Beziehungen*, um wirkungsvolle Maßnahmen zur Zielerreichung zu planen und die Voraussetzungen für eine positive Performance-Entwicklung zu schaffen.

Kausalinformationen können dieser Aufgabe nur dann gerecht werden, wenn sie nicht assoziativ, sondern evidenzbasiert entwickelt und überprüft werden. Gegenstand dieser Arbeit war daher zum einen die Verwendung von Kausalinformationen im Performance-Management, zum anderen aber auch der Prozess ihrer Entstehung. Zu welchen Ergebnissen diese Arbeit gekommen ist, fasst der folgende Abschnitt zusammen.

8.1 Zusammenfassung der Ergebnisse

Im ersten Teil der Arbeit - den Kapiteln 2, 3 und 4 - stand die Frage im Mittelpunkt, wie sich die Defizite bestehender Performance-Management-Konzepte durch einen systematischeren Umgang mit Kausalinformationen überwinden lassen. Dieser Fragestellung liegen zwei Thesen zugrunde: erstens, dass die bestehenden Konzepte zum Performance-Management Defizite aufweisen, zweitens, dass speziell Kausalinformationen dazu beitragen können, diese Defizite zu beheben.

Diesen Thesen wurde in Kapitel 2 nachgegangen, das die Grundlagen und Defizite bestehender Performance-Konzepte vorstellte. Nach einer Auseinandersetzung mit dem Begriff der betrieblichen Performance wurde die Entwick-

lung des Performance-Managements als Erweiterung des Performance-Measurements nachgezeichnet. Im Anschluss wurden die Probleme erläutert, die den Unternehmen die praktische Umsetzung dieser Performance-Konzepte bereitet. Die daraus resultierenden Umsetzungsdefizite betreffen den Aufbau des Kennzahlensystems, die Analyse der Kennzahlen und die Maßnahmenplanung. Diese Defizite beruhen aber letztlich auf Mängeln in der konzeptionellen Fundierung. Den Performance-Konzepten fehlt es an einem Bezugsrahmen zur vertikalen und horizontalen Integration ihrer Ziele, Kennzahlen und Messobjekte. Während für eine vertikale Integration die Zuordnungen zwischen Zielen, Kennzahlen und Messobjekten eindeutig und konsistent festzulegen sind, verknüpft ein horizontal integriertes Performance-Management seine Ziele und Kennzahlen zusätzlich über Zweck-Mittel- und kausale Kennzahlbeziehungen.

In Kapitel 3 wurde ein ganzheitliches Performance-Management-Konzept entwickelt, das einen solchen Bezugsrahmen zur vertikalen und horizontalen Integration enthält. Der Bezugsrahmen beruht auf Konzepten der Systemtheorie und beschreibt das Performance-Management zunächst als eine Aufgabe, die sich in die beiden Teilaufgaben der Performance-Gestaltung und Performance-Lenkung zerlegen lässt. Für jede Teilaufgabe wurde ein eigenes Modellsystem entwickelt, das als Hilfsregelstrecke die Komplexität des realen Aufgabenobjekts - des Unternehmens als Realsystem - reduziert. Während die Teilaufgabe der Performance-Gestaltung ein Modell der Unternehmensarchitektur nutzt, enthält das Performance-Measure-System die Kennzahlen, die zur Performance-Lenkung - also zur Steuerung und Kontrolle der betrieblichen Performance - benötigt werden. Beide Modellsysteme zusammen bilden ein integriertes Architekturmodell, das es erlaubt, die vertikalen und horizontalen Bezüge zwischen Zielen, Kennzahlen und Messobjekten herzustellen.

Wie sich mit dem Architekturmodell und seinen beiden Teilmodellssystemen die Unternehmensperformance gestalten und lenken lässt, beschreibt das generische Prozessmodell. Dieses unterteilt sich in die beiden Teilprozesse der Performance-Gestaltung und -Lenkung, die in ihrem iterativen Prozessverlauf zwei Zyklen beschreiben: Je nachdem, ob man infolge einer Performance-Abweichung nur das Performance-Measure-System oder auch die Unternehmensarchitektur anpasst, folgt der Prozessablauf einem einfachen Lenkungszyklus bzw. einem erweiterten Gestaltungs- und Lenkungszyklus.

Welche dieser Prozessphasen und -aktivitäten wie von Kausalinformationen profitieren, wurde in Kapitel 4 untersucht. Während man diese bei der Gestaltung der Unternehmensarchitektur zur Begründung von Zweck-Mittel-Beziehun-

gen einsetzt, eignen sie sich bei der Performance-Lenkung zur Identifikation und Verknüpfung nicht-finanzieller Kennzahlen.

Damit sich die in Kapitel 4 aufgezeigten Einsatzpotenziale auch nutzen lassen, wurde im zweiten Teil der Arbeit folgende Fragestellung beantwortet: Wie lassen sich Kausalhypothesen für das Performance-Management evidenzbasiert entwickeln und überprüfen?

In Kapitel 5 wurden die methodischen und konzeptionellen Grundlagen für eine evidenzbasierte Kausalanalyse erarbeitet. Um zu wissen, wie man eine Kausalinformation erzeugt, musste zuvor geklärt werden, durch welche kausalen Wesensmerkmale sich ein Kausalzusammenhang auszeichnet. Drei Wesensmerkmale kennzeichnen einen Kausalzusammenhang: die Bedingtheit, die Gesetzmäßigkeit sowie die Chronologie seiner Ereignisse. Der Nachweis eines Wesensmerkmals lässt sich als Hinweis auf einen Kausalzusammenhang interpretieren. Nur wenn alle drei Wesensmerkmale nachgewiesen wurden - sie also evident sind - kann ein Kausalzusammenhang als (vorläufig) gültig betrachtet werden.

Um die Wesensmerkmale eines Kausalzusammenhangs nachzuweisen, muss dieser auf unterschiedlichen Ebenen betrachtet werden. Die Gesetzmäßigkeit und Chronologie erschließen sich aus der Analyse real eingetretener Ursachen- und Wirkungsereignisse, die sich in einer Datenbasis erfassen lassen. Die Bedingtheit eines Kausalzusammenhangs manifestiert sich hingegen in der spezifischen Bedingungskonstellation, die es dem Ursachenergebnis ermöglicht, das Wirkungsereignis hervorzurufen. Die Analyse der Bedingungskonstellation fokussiert daher nicht die Ereignisse selbst, sondern die Objekte, deren Zustandsänderung sie beschreiben. Diese Objekte dienen den Ereignissen als Ereignisträger. Die Bedingtheit eines Kausalzusammenhangs wird nachgewiesen, indem man dessen Bedingungskonstellation in Form einer kausalen Infrastruktur modelliert. Diese muss erklären, in welcher Objektbeziehung die beiden Ereignisträger des Ursachen- und Wirkungsereignisses stehen, damit der Kausalzusammenhang zustande kommt und das Ursachenergebnis das Wirkungsereignis hervorrufen kann.

Aus methodischer Sicht ist sowohl die Entwicklung als auch die Überprüfung einer Kausalhypothese eine Suche nach Evidenzen, also nach Hinweisen auf die Existenz der kausalen Wesensmerkmale. Abhängig davon, ob man die Gesetzmäßigkeit und Chronologie oder die Bedingtheit nachweisen möchte, ist entweder eine Datenanalyse durchzuführen oder ein Modell der kausalen Infrastruktur zu konstruieren. Auf dieser Erkenntnis beruhen die vier Gestaltungsoptionen: die modell- und datenzentrierte Hypothesenentwicklung und -überprüfung.

Jede der vier Gestaltungsoptionen ist als modellgestützte Untersuchungssituation angelegt, die auf einem kausalanalytischen Architekturmodell operiert. Mit dem kausalanalytischen Architekturmodell lassen sich die kausalen Ereignisbeziehungen zusammen mit ihren zugrunde liegenden Objektbeziehungen aus Typ- und Instanzsicht abbilden. Hierzu teilt sich das Architekturmodell in eine typ- und eine instanzbezogene Kausalarchitektur, die sich beide über zwei Modellebenen erstrecken: eine Ereignis- und eine Objektebene. Während die instanzbezogene Kausalarchitektur Daten über reale Ereignisse und Objekte enthält, betrachtet die typbezogene Kausalarchitektur dieselben Ereignisse und Objekte aus Typsicht. Indem das kausalanalytische Architekturmodell beide Sichten integriert, ermöglicht es eine integrierte Kausalanalyse - sei es in Form einer Datenanalyse zum Nachweis der Gesetzmäßigkeit und Chronologie oder in Form einer Modellanalyse zum Nachweis der Bedingtheit.

Kapitel 5 schließt mit einer Übersicht unterschiedlicher Datenanalyseverfahren. Je nachdem, ob Kausalhypothesen entwickelt oder überprüft werden sollen, eignen sich daten- oder hypothesengetriebene Verfahren. Zur datengetriebenen Analyse zählen die Verfahren des Data-Minings, während als Vertreter der hypothesengetriebenen Analyse das Online-Analytical-Processing (OLAP) vorgestellt wurde.

In Kapitel 6 folgte für jede Gestaltungsoption eine Beschreibung ihrer Prozessphasen und -aktivitäten. Insbesondere wurde erläutert, wie sich die Teilmodellsysteme des kausalanalytischen Architekturmodells konstruieren und zur modell- bzw. datenzentrierten Kausalanalyse nutzen lassen. Die Gestaltungsoptionen können zwar auch unabhängig voneinander durchgeführt werden; um allerdings gültige Kausalhypothesen zu erhalten, sind diese zu einem integrierten Analyseprozess zu kombinieren. Am Ende des Kapitels wurden daher die Kombinationsmöglichkeiten für eine sequenzielle und verschachtelte Anwendung der Gestaltungsoptionen erläutert.

Wie die vier Gestaltungsoptionen in der Praxis anzuwenden sind, verdeutlichte schließlich die Fallstudie in Kapitel 7. Es konnte gezeigt werden, wie für den Kundenauftragsprozess eines Sportartikelherstellers Kausalhypothesen auf modell- und datenzentriertem Wege entwickelt und überprüft wurden. Gleichzeitig bestätigte sich das in Kapitel 4 aufgezeigte Einsatzpotenzial für Kausalinformationen, da das Performance-Management des Sportartikelherstellers nun gezielt nicht-finanzielle Frühindikatoren identifizieren und diese mit den Finanzkennzahlen verknüpfen konnte.

8.2 Schlussbetrachtung und Ausblick

Mit dem Zitat „Wind entsteht, weil sich die Bäume schütteln“ [Prat08, S. 72] begann diese Arbeit mit einem Beispiel für eine falsche Kausalannahme (siehe Kapitel 1). In einem Unternehmen besteht speziell im Performance-Management die Gefahr, auf Basis falscher Kausalannahmen zu entscheiden und zu handeln - zumal wenn sie nur assoziativ und auf Basis von Intuition formuliert werden. Um dieser Gefahr entgegenzuwirken, wurde in dieser Arbeit ein methodisches Vorgehen ausgearbeitet, mit dem sich derartige Kausalannahmen sowohl gezielt überprüfen als auch durch systematisch entwickelte Kausalhypothesen ersetzen lassen.

Der wesentliche Beitrag dieser Arbeit besteht darin, dass neben der Datenanalyse erstmals ein zweiter - und bis dato noch unbeschrittener Weg - zur Kausalanalyse ausgearbeitet und vorgestellt wurde. Die Kernidee dieser modellzentrierten Analyse besteht darin, den Blick von der kausalen Struktur der Ereignisse und ihren Kausalbeziehungen zu lösen und stattdessen auf die Objekte und Objektbeziehungen zu richten, die die kausale Infrastruktur bilden. Dass aber Kausalzusammenhänge einer spezifischen Bedingungskonstellation bedürfen, ist für sich betrachtet keine neue Erkenntnis und fällt in die Kategorie des gesunden Menschenverstands. Der Neuigkeitswert dieser Arbeit besteht vielmehr darin, dass man dem gesunden Menschenverstand methodengestützt auf die Sprünge helfen kann, und zwar indem man die kausale Bedingungskonstellation systematisch erfasst und zusammen mit den begründeten Kausalzusammenhängen in einem integrierten Modellsystem abbildet.

Dieser Modellierungsansatz der objektorientierten Kausalmodellierung beruht auf einem klar umrissenen Begriffsverständnis darüber, was ein Kausalzusammenhang ist, welche Ereignistypen sich wie in der Objektebene verankern lassen und dass sich anhand der Objektbeziehungen entscheidet, ob eine Kausalhypothese plausibel ist oder nicht. Dass man mit einem solchen Objektmodell sowohl Kausalhypothesen überprüfen als auch neue Hypothesen entwickeln kann, stellt die zentrale Erkenntnis dieser Arbeit dar. Denn nun besteht die Möglichkeit, auch dort Kausalzusammenhänge evidenzbasiert zu analysieren, wo eine datenzentrierte Analyse aufgrund fehlender Daten nicht möglich ist.

Stehen hingegen ausreichend Daten in guter Qualität zur Verfügung, eignen sich auch die datengetriebenen Analyseverfahren des Data-Minings, um Kausalhypothesen zu entwickeln. Data-Mining- und OLAP-Verfahren werden angesichts

der stetig wachsenden Datenbestände in den Unternehmen weiter an Bedeutung gewinnen. Sie sind vor allem dann ein mächtiges Instrument zur Kausalanalyse, wenn sie mit der modellzentrierten Kausalanalyse zu einem integrierten Analyseprozess kombiniert werden.

Die bewusste Analyse und Gestaltung kausaler Strukturen und Infrastrukturen wird in den Unternehmen noch nicht als eigenständige Aufgabe wahrgenommen. Aktuell sind die Unternehmen noch vollends damit beschäftigt, dem Prozessparadigma zu folgen und den Übergang von einer funktionalen Aufbauorganisation in eine Prozessorganisation zu bewältigen. Hier zeigt sich, dass die Unternehmenspraxis der wissenschaftlichen Forschung zuweilen Jahrzehnte hinterherhinken kann, schließlich werden Prozesse in der Betriebswirtschaftslehre bereits seit 1930 als eigenständiger Forschungsgegenstand betrachtet (siehe Abschnitt 3.2.1). Die Analyse und Gestaltung von Prozessen hat heute sowohl in methodischer Hinsicht als auch bei der Unterstützung durch Anwendungssysteme einen Reifegrad erreicht, den die Analyse und Gestaltung von Kausalzusammenhängen noch nicht aufweist. Da in dieser Arbeit methodische Grundlagen der Kausalanalyse erarbeitet wurden, stellt sich nun die Frage nach einer adäquaten IT-Unterstützung. Zwei Antworten zeichnen sich ab, bedürfen aber einer näheren Betrachtung und sind somit Ansatzpunkte für weitere Forschungen.

Die objektorientierte Kausalmodellierung erfordert sowohl auf der Ereignis- als auch auf der Objektebene ein Denken in abstrakten Zusammenhängen, das allerdings umso leichter fällt, je besser es gelingt, die Modellkomplexität zu beherrschen und zu reduzieren. Im kausalanalytischen Architekturmodell bieten die Aggregations- und Typbeziehungen der Objektebene zwei wichtige Ansatzpunkte, um die Komplexität entlang der Aggregations- und Typebenen stufenweise zu reduzieren oder zu erhöhen. Indem die Ereignistypen des Kausalmodells den Objekttypen der Objektebene eindeutig zugeordnet sind, ließe sich parallel zur Objektebene auch die Modellkomplexität der Ereignisebene stufenweise anpassen. Ein kausales Wollknäuel, wie es Abbildung 1 zeigt, könnte dann auf Basis der Aggregations- und Typbeziehungen der Objektebene schrittweise entflechtet und vom Anwender interaktiv exploriert werden.

Das zweite Potenzial einer IT-Unterstützung bestünde in der Wiederverwendung bereits entwickelter Kausal- und Objektmodelle. Gelingt es, die zur Lösung einzelner Untersuchungsprobleme entwickelten Modelle in einer gemeinsamen Modelldatenbank (Repository) zu speichern, können einzelne Modellbausteine in anderen Untersuchungssituationen wiederverwendet werden. Dies gilt speziell

für die Objektebene, deren Objekttypen und Objektbeziehungen gerade auf höheren Aggregations- und Typebenen eine hohe Stabilität aufweisen.

Letztlich bleibt es abzuwarten, wann sich die Analyse und Gestaltung kausaler Strukturen und Infrastrukturen als eigenständige Aufgabe in den Unternehmen etablieren werden. Zu erwarten ist allerdings Folgendes: Heute verschaffen sich Unternehmen noch durch die konsequente Gestaltung ihrer Prozesse einen Vorteil gegenüber den Unternehmen, die nach wie vor in ihrer funktionalen Aufbauorganisation verharren. Zukünftig werden aber diejenigen Unternehmen im Vorteil sein, denen es gelingt, die für die Erreichung ihrer Ziele relevanten Kausalzusammenhänge zu verstehen und deren kausale Infrastruktur aktiv zu gestalten.

Literaturverzeichnis

- [AdZa96] Adriaans, P.; Zantinge, D.: Data Mining, Harlow (Addison Wesley) 1996.
- [AgIS93] Agrawal, R.; Imielinski, R.; Swami, A.: Mining Association Rules between Sets of Items in Large Databases, <http://rakesh.agrawal-family.com/papers/sigmod93assoc.pdf>, 1993 (Zugriff am 26.07.2007).
- [AgSr94] Agrawal, R.; Ramakrishnan, S.: Fast Algorithms for Mining Association Rules, <http://www.sigmod.org/vldb/conf/1994/P487>. PDF, 1994 (Zugriff am 26.07.2007).
- [Alex07] Alexander, S.: Business Intelligence und Performance-Management finden zusammen, <http://www.computerwoche.de/548526>, 2007 (Zugriff am 04.10.2007).
- [AlNi00a] Alpar, P.; Niedereichholz, J. (Hrsg.): Data Mining im praktischen Einsatz – Verfahren und Anwendungsfälle für Marketing, Vertrieb, Controlling und Kundenunterstützung, Braunschweig (Vieweg) 2000.
- [AlNi00b] Alpar, P.; Niedereichholz, J.: Einführung zu Data Mining, in: [AlNi00a], S. 1-27.
- [Andr75] Andrä, B.O.: Die Zielhierarchie des Betriebes – Versuch einer Darstellung der Eigenschaften eines rationalen Zielsystems erwerbswirtschaftlicher Betriebe, Frankfurt am Main (Peter Lang) 1975.
- [AnFa02] Andersen, B.; Fagerhaug, T.: Performance Measurement Explained, Milwaukee (ASQ Quality Press) 2002.
- [Arms94] Armstrong, M.: Performance Management, London (Kogan Page) 1994.
- [AtWW97] Atkinson, A.A.; Waterhouse, J.H.; Wells, R.B.: A Stakeholder Approach to Strategic Performance Measurement, in: Sloan Management Review 38 (1997) 3, S. 25-37.
- [Aust96] Austin, R.D.: Measuring and Managing Performance in Organizations, New York (Dorset House) 1996.

- [Bago80] Bagozzi, R.P.: Causal Models in Marketing, New York (Wiley) 1980.
- [BaGr04] Baumgartner, M.; Graßhoff, G.: Kausalität und kausales Schließen - eine Einführung mit interaktiven Übungen, Bern (Bern Studies in the History and Philosophy of Science) 2004.
- [Balz00] Balzert, H.: Lehrbuch der Software-Technik, Band 1 Software-Entwicklung, Heidelberg (Spektrum Akademischer Verlag) 2000.
- [BaTh04] Backhausen, W.; Thommen, J.-P.: Coaching - Durch systematisches Denken zu innovativer Personalentwicklung, 2., aktualisierte Auflage, Wiesbaden (Gabler) 2004.
- [Baum02] Baumgartner, C.: Umsetzung und Realisierung von Performance Measurement, in: HMD - Praxis der Wirtschaftsinformatik (2002) 227, S. 17-25.
- [Beck90] Becker, W.: Funktionsprinzipien des Controlling, in: Zeitschrift für Betriebswirtschaft (ZfB) 60 (1990) 3, S. 295-318.
- [Beck92] Becker, F.G.: Grundlagen betrieblicher Leistungsbeurteilungen: Leistungsverständnis und -prinzip, Beurteilungsproblematik und Verfahrensprobleme, Stuttgart (Schäffer-Poeschel) 1992.
- [BeLi97] Berry, M.J.A.; Linoff, G.S.: Data Mining Techniques - For Marketing, Sales and Customer Support, New York (Wiley) 1997.
- [BeLi00] Berry, M.J.A.; Linoff, G.S.: Mastering Data Mining: The Art and Science of Customer Relationship Management, New York (Wiley) 2000.
- [BeLi04] Berry, M.J.A.; Linoff, G.S.: Data Mining Techniques - For Marketing, Sales, and Customer Relationship Management, 2. Auflage, Indianapolis (Wiley) 2004.
- [BePi04] Becker, W.; Piser, M.: Strategische Kontrolle in der Unternehmenspraxis - Bekanntheit, Anwendung, Instrumente, in: Controlling 16 (2004) 8/9, S. 445-450.
- [Bert73] Berthel, J.: Zielorientierte Unternehmenssteuerung, Stuttgart (Poeschel) 1973.
- [BiHa96] Bissantz, N.; Hagedorn, J: Data Mining im Controlling - Arbeitsberichte des Instituts für mathematische Maschinen und Datenverarbeitung (Informatik), Band 29, Nr. 7, Erlangen 1996.

-
- [Biss96] Bissantz, N.: CLUSMIN - Ein Beitrag zur Analyse von Daten des Ergebniscontrollings mit Datenmustererkennung (Data Mining), Dissertation, in: [BiHa96], Teil A.
- [Biss02] Bissantz, N.: Stand und Weiterentwicklung softwaregestützter Datenanalysen im betriebswirtschaftlichen Umfeld, in: [Hann02], S. 229-245.
- [Blan99] Blankenburg, D.A.: Evaluation von Performance Measurement Systemen - Eine empirische Analyse, Regensburg (Transfer Verlag) 1999.
- [Blei95] Bleicher, K.: Das Konzept Integriertes Management - St. Galler Management-Konzept Band 1, 3. Auflage, Frankfurt am Main (Campus Verlag) 1995.
- [BMW + 00] Bourne, M.; Mills, J.F.; Wilcox, M.; Neely, A.; Platts, K.: Designing, implementing and updating performance measurement systems, in: International Journal of Operations & Production Management 20 (2000) 7, S. 754-771.
- [Böhn01] Böhnlein, M.: Konstruktion semantischer Data Warehouse-Schemata, Dissertation, Wiesbaden (Deutscher Universitäts-Verlag) 2001.
- [BoKr02] Borgelt, C.; Kruse, R.: Graphical Models - Methods for Data Analysis and Mining, Chichester (Wiley) 2002.
- [BöU100] Böhnlein, M.; Ulbrich-vom Ende, A.: Grundlagen des Data Warehousing - Modellierung und Architektur, Bamberger Beiträge zur Wirtschaftsinformatik, Nr. 55, Otto-Friedrich-Universität, Bamberg 2000.
- [BrBr95] Bredrup, H.; Bredrup, R.: Performance Planning to Ensure Business Achievements, in: [Rols95], S. 103-134.
- [Bred95a] Bredrup, H.: Background for Performance Management, in: [Rols95], S. 61-87.
- [Bred95b] Bredrup, H.: Performance Measurement, in: [Rols95], S. 169-190.
- [Bred95c] Bredrup, H.: Performance Evaluation, in: [Rols95], S. 191-198.
- [BrFr05] Broda, B.; Frey, J.: Data Warehouse gestützte Werttreiberanalyse, in: Controlling 17 (2005) 2, S. 117-124.
- [Brun99] Brunner, J.: Value-based Performance Management: Wertsteigernde Unternehmensführung, Wiesbaden (Gabler) 1999.

- [Buck01] Buckler, F.: NEUSREL - Neuer Kausalanalyseansatz auf Basis Neuronaler Netze als Instrument der Marketingforschung, Dissertation, Göttingen (Cuviller) 2001.
- [BuWG04a] Buytendijk, F.; Wood, B.; Geishecker, L.: Mapping the Road to Corporate Performance Management, <http://www.gartner.com>, 2004 (Zugriff am 28.02.2005).
- [BuWG04b] Buytendijk, F.; Wood, B.; Geishecker, L.: Drivers and Challenges of Corporate Performance Management, <http://www.gartner.com>, 2004 (Zugriff am 28.02.2005).
- [Card04] Card, D.N.: Understanding Causal Systems, in: CrossTalk 17 (2004) 10, S. 15-18.
- [Cart97] Cartwright, N.: What is a causal structure?, in: [McTu97], S. 343-357.
- [CDF + 00] Chennell, A.F.; Dransfield, S.B.; Field, J.B.; Fisher, N.I.; Saunders, I.W.; Shaw, D.E.: OPM: A System For Organisational Performance Measurement, in: [Neel00], S. 96-103.
- [Cham01] Chamoni, P.: On-Line Analytical Processing (OLAP), in: [HKMW01], S. 543-558.
- [ChGl99] Chamoni, P.; Gluchowski, P. (Hrsg.): Analytische Informationssysteme, 2., neubearbeitete Auflage, Berlin (Springer) 1999.
- [CHS + 98] Cabena, P.; Hadjinian, P.; Stadler, R.; Verhees, J.; Zanasi, A.: Discovering data mining - from concept to implementation, Upper Saddle River (Prentice Hall) 1998.
- [Coas60] Coase, R.H.: The Problem of social cost, in: Journal of Law and Economics (1960) 3, S. 1-44.
- [CoCS93] Codd, E.F.; Codd, S.B.; Salley, C.T.: Providing OLAP (on-line Analytical Processing) to User-Analysts: An IT Mandate, White Paper, http://www.minet.uni-jena.de/dbis/lehre/ss2005/sem_dwh/lit/Cod93.pdf (Zugriff am 10.06.2009).
- [Codd70] Codd, E.F.: A Relational Model of Data for Large Shared Data Banks, in: Communications of The ACM 13 (1970) 6, S. 377-387.
- [Coki04] Cokins, G.: Performance Management - Finding the Missing Pieces (to Close the Intelligence Gap), Hoboken (Wiley) 2004.
- [Coop99] Cooper, G.F.: An Overview of the Representation and Discovery of Causal Relationships Using Bayesian Networks, in: [GlCo99], S. 3-62.

-
- [Corv95] Corvellec, H.: Stories of Achievements: Narrative Features of Organizational Performance, Lund (Lund University Press) 1995.
- [Dave06] Davenport, T.H.: Aus Daten Geld machen, in: Harvard Business Manager (2006) 4, S. 72-85.
- [Demi02] Deming, W.E.: Out of the Crisis, 2. Auflage, Cambridge (MIT Press) 2002.
- [DeMu88] Devlin, B.A.; Murphy, P.T.: An Architecture for a Business and Information System, in: International Business Machine (IBM) System Journal, 27 (1988) 1, S. 50-80.
- [Dörn03] Dörner, D.: Die Logik des Misslingens - Strategisches Denken in komplexen Situationen, 5. Auflage, Reinbeck (Rowohlt) 2003.
- [Dowe00] Dowe, P.: Physical Causation, Cambridge (Cambridge University Press) 2000.
- [Drei94] Dreier, V.: Datenanalyse für Sozialwissenschaftler, München (Oldenbourg) 1994.
- [Drex00] Drexler, A.: Das kausale Band. Zur Theorie des Ursache-Wirkung-Zusammenhangs, Frankfurt am Main (Peter Lang) 2000.
- [Druc98] Drucker, P.F. (Hrsg.): Harvard Business Review on Measuring Corporate Performance, Boston (Harvard Business School Press) 1998.
- [Düsi99] Düsing, R.: Knowledge Discovery in Databases und Data Mining, in: [ChGl99], S. 345-353.
- [EaWa00] Eagleson, G.K.; Waldersee, R.: Monitoring the strategically important: Assessing and improving strategic tracking systems, in: [Neel00], S. 137-144.
- [Eccl91] Eccles, R.G.: The Performance Measurement Manifesto, in: [Druc98], S. 25-45.
- [EcPy92] Eccles, R.G.; Pyburn, P.J.: Creating a comprehensive system to measure performance, in: Management Accounting 74 (1992) 4, S. 41-44.
- [Erdm03] Erdmann, M.-K.: Supply Chain Performance Measurement - Operative und strategische Management- und Controllingansätze, Dissertation, Lohmar (Josef Eul) 2003.
- [EsSa00] Ester, M.; Sander, J.: Knowledge Discovery in Databases. Techniken und Anwendungen, Berlin (Springer) 2000.

- [Ezza92] Ezzamel, M.: Business Unit & Divisional Performance Management, London (Academic Press) 1992.
- [FaPS96] Fayyad, U.M.; Piatetsky-Shapiro, G.; Smyth, P.: From Data Mining to Knowledge Discovery: An Overview, in: [FPSU96], S. 1-34.
- [Fers79] Ferstl, O.K.: Konstruktion und Analyse von Simulationsmodellen, Königstein/Ts. (Hain) 1979.
- [FeSi93] Ferstl, O.K.; Sinz, E.J.: Geschäftsprozessmodellierung, in: Wirtschaftsinformatik 35 (1993) 6, S. 589-592.
- [FeSi96] Ferstl, O.K.; Sinz, E.J.: Geschäftsprozessmodellierung im Rahmen des Semantischen Objektmodells, in: [VoBe96], S. 47-61.
- [FeSi08] Ferstl, O.K.; Sinz, E.J.: Grundlagen der Wirtschaftsinformatik, 6., überarbeite und erweiterte Auflage, München (Oldenbourg) 2008.
- [FJB + 91] Fitzgerald, L.; Johnston, R.; Brignall, T.J.; Silvestro, R.; Voss, C.: Performance Measurement in Service Businesses, London (The Chartered Institute of Management Accountants) 1991.
- [Forr61] Forrester, J.W.: Industrial Dynamics, Portland (MIT Press) 1961.
- [FPSU96] Fayyad, U.M.; Piatestsky-Shapiro, G.; Smyth, P.; Uthurusamy, R. (Hrsg.): Advances in Knowledge Discovery and Data Mining, Menlo Park (AAAI Press) 1996.
- [Fran03] Frank, U.: Ebenen der Abstraktion und ihre Abbildung auf konzeptionelle Modelle - oder Anmerkungen zur Semantik von Spezialisierungs- und Instanzierungsbeziehungen, in: EMISA FORUM 23 (2003) 2, S. 14-18.
- [FrCo89] Fry, T.D.; Cox, J.F.: Manufacturing performance - local versus global measures, in: Production and Inventory Management Journal 30 (1989) 2, S. 52-56.
- [Free84] Freeman, R.E.: Strategic Management – A Stakeholder Approach, Marshfield (Pitman) 1984.
- [Fric98] Frick, D.: Die Akquisition betriebswirtschaftlichen Wissens zum Aufbau von wissensbasierten Entscheidungsunterstützungssystemen, Frankfurt am Main (Peter Lang) 1998.
- [Frie04] Friedman, T.: Corporate Performance Management Demands Data Quality, <http://www.gartner.com>, 2004 (Zugriff am 28.02.2005).

-
- [From04] Fromm, E.: Wege aus einer kranken Gesellschaft - Eine sozialpsychologische Untersuchung, 4. Auflage, München (dtv) 2004.
- [Frös02] Frösche, H.-P.: Editorial, in: HMD - Praxis der Wirtschaftsinformatik (2002) 227, S. 1.
- [FrPM91] Frawley, W.J.; Piatetsky-Shapiro, G.; Matheus, C.J.: Knowledge Discovery in Databases: An Overview, in: [PiFr91], S. 1-27.
- [Gait83] Gaitanides, M.: Prozeßorganisation - Entwicklung, Ansätze und Programme prozeßorientierter Organisationsgestaltung, München (Vahlen) 1983.
- [GaSV94] Gaitanides, M.; Scholz, R.; Vrohings, A.: Prozessmanagement - Grundlagen und Zielsetzung, in: [GSVR94], S. 1-19.
- [Glad01] Gladen, W.: Kennzahlen- und Berichtssysteme: Grundlagen zum Performance Measurement, Wiesbaden (Gabler) 2001.
- [Glad02] Gladen, W.: Performance Measurement als Methode der Unternehmenssteuerung, in: HMD - Praxis der Wirtschaftsinformatik (2002) 227, S. 5-16.
- [GlCo99] Glymour, C; Cooper, G.F.: Computation, causation and discovery, Cambridge (MIT Press) 1999.
- [Glei97] Gleich, R.: Performance Measurement, in: DBW - Die Betriebswirtschaft 57 (1997) 1, S. 114-117.
- [Glei01] Gleich, R.: Das System des Performance Measurements, Habilitation, München (Vahlen) 2001.
- [GlGC97] Gluchowski, P.; Gabriel, R.; Chamoni, P.: Management Support Systeme - Computergestützte Informationssysteme für Führungskräfte und Entscheidungsträger, Berlin (Springer) 1997.
- [GlKi02] Gleich, R.; Kitzelmann, V.: Performance Measurement in einem produzierenden Unternehmen, in: HMD - Praxis der Wirtschaftsinformatik (2002) 227, S. 89-96.
- [Gome81] Gomez, P.: Modelle und Methoden des systemorientierten Managements, Bern (Haupt) 1981.
- [GoPr99] Gomez, P.; Probst, G.: Die Praxis des ganzheitlichen Problemlösens, 3. Auflage, Bern (Haupt) 1999.
- [Grab01] Grabmeier, J.: Segmentierende und clusterbildende Methoden, in: [HKMW01], S. 299-361.

- [GrGe00] Grothe, M.; Gentsch, P.: Business Intelligence - Aus Informationen Wettbewerbsvorteile gewinnen, München (Addison Wesley) 2000.
- [GrHZ96] Grünig, R.; Heckner, F.; Zeus, A.: Methoden zur Identifikation strategischer Erfolgsfaktoren, in: Die Unternehmung 50 (1996) 1, S. 3-12.
- [GSGK02] Gleich, R.; Sasse, A.; Gräf, J.; Kogler, S.: Corporate Reporting - Empirische Erkenntnisse und Impulse zur Performancesteigerung, in: Controlling 14 (2002) 6, S. 337-345.
- [GSVR94] Gaitanides, M.; Scholz, R.; Vrohlings, A.; Raster, M. (Hrsg.): Prozessmanagement - Konzepte, Umsetzungen und Erfahrungen des Reengineering, München (Hanser) 1994.
- [Hach02] Hachmeister, D.: Performancemaße, erfolgsorientierte, in: [KüWa02], S. 1385-1395.
- [HaFa56] Hall, A.D.; Fagen, R.E.: Definition of System, in: General System (1956) 1, S. 18-28.
- [Hage96] Hagedorn, J.: Die automatische Filterung von Controlling-Daten unter besonderer Berücksichtigung der Top-Down-Navigation (BETREX II), Dissertation, in: [BiHa96], Teil B.
- [HaMS01] Hand, D.; Mannila, H.; Smyth, P.: Principles of Data Mining, Cambridge (MIT Press) 2001.
- [Hann02] Hannig, U. (Hrsg.): Knowledge Management und Business Intelligence, Berlin (Springer) 2002.
- [Harr91] Harrington, H.J.: Business process improvement: the breakthrough strategy for total quality, productivity and competitiveness, New York (McGraw-Hill) 1991.
- [HeHi01] Hettich, S.; Hippner, H.: Assoziationsanalyse, in: [HKMW01], S. 427-463.
- [Hein76] Heinen, E.: Grundlagen betriebswirtschaftlicher Entscheidungen - Das Zielsystem der Unternehmung, Wiesbaden (Gabler) 1976.
- [Hein77] Heinen, E.: Einführung in die Betriebswirtschaftslehre, 6., verbesserte und erweiterte Auflage, Wiesbaden (Gabler) 1977.
- [Henn71] Hennig, K.W.: Betriebswirtschaftliche Organisationslehre, 5., neu bearbeitete Auflage, Wiesbaden (Gabler) 1971.
- [Heue97] Heuer, A.: Objektorientierte Datenbanken, Bonn (Addison Wesley) 1997.

-
- [HiWi01] Hippner, H.; Wilde, K.D.: Der Prozess des Data Mining im Marketing, in: [HKMW01], S. 21-91.
- [HKMW01] Hippner, H.; Küsters, U.; Meyer, M.; Wilde, K. (Hrsg.): Handbuch Data Mining im Marketing – Knowledge Discovery in Marketing Data-bases, Braunschweig/Wiesbaden (Vieweg) 2001.
- [Hoff00] Hoffmann, O.: Performance Management - Systeme und Implementierungsansätze, 2., unveränderte Auflage, Bern (Haupt) 2000.
- [HoMa99] Hornung, K.; Mayer, J.H.: Erfolgsfaktoren-basierte BSC zur Unterstützung einer wertorientierten Unternehmensführung - Ergebnisse einer Pilotanwendung zur bedarfsgerechten Informationsversorgung oberster Führungskräfte, in: Controlling 11 (1999) 8/9, S. 389-398.
- [Homb88] Homburg, C.: Exploratorische Ansätze der Kausalanalyse als Instrument der Marketingplanung, Frankfurt am Main (Peter Lang) 1988.
- [Horv02] Horváth, P.: Controlling, 8., vollständig überarbeitete Auflage, München (Vahlen) 2002.
- [Horv04] Horváth & Partner (Hrsg.): Balanced Scorecard umsetzen, 3. Auflage, Stuttgart (Schäffer-Poeschel) 2004.
- [Hron96] Hronec, S.M.: Vital Signs - Indikatoren für die Optimierung der Leistungsfähigkeit Ihres Unternehmens, Stuttgart (Schäffer-Poeschel) 1996.
- [HuZi76] Hummell, H.J.; Ziegler, R. (Hrsg.): Korrelation und Kausalität, Band 1, Stuttgart (Ferdinand Enke) 1976.
- [Inmo05] Inmon, W.H.: Building the Data Warehouse, 4. Auflage, New York (Wiley) 2005.
- [ItLa04] Ittner, C.D.; Larcker, D.F.: Wenn die Zahlen versagen, in: Harvard Business Manager (2004) 2, S. 70-81.
- [JeMe76] Jensen, M.; Meckling, W.: Theory of the firm: Managerial behavior, agency costs, and ownership structure,, in: Journal of Financial Economics 3 (1976) 4, S. 305--360.
- [JoFi00] Johnston, R.; Fitzgerald, L.: Performance Measurement: Flying in the face of fashion, in: [Neel00], S. 275-282.
- [JoKa87] Johnson, H.T.; Kaplan, R.S.: Relevance lost - the rise and fall of management accounting, 10. Auflage, Boston (Harvard Business School Press) 1987.

- [JuWi00] Jung, R.; Winter, R. (Hrsg.): Data Warehouseing 2000 - Methoden, Anwendungen, Strategien, Heidelberg (Physica) 2000.
- [KaNo96a] Kaplan, R.S.; Norton, D.P.: The Balanced Scorecard, Bosten (Harvard Business School Press) 1996.
- [KaNo96b] Kaplan, R.S.; Norton, D.P.: Using The Balanced Scorecard as a Strategic Mangement System, in: Harvard Business Review 74 (1996) 1, S. 75-85.
- [KaNo01] Kaplan, R.S.; Norton, D.P.: The Strategy-Focused Organization - How Balanced Scorecard Companies Thrive in the New Business Environment, Boston (Harvard Business School Press) 2001.
- [KaNo04] Kaplan, R.S.; Norton, D.P.: Strategy Maps - Der Weg von imateriellen Werten zum materiellen Erfolg, Stuttgart (Schäffer-Poeschel) 2004.
- [Kilg88] Kilger, W.: Flexible Plankostenrechnung und Deckungsbeitragsrechnung, 9., verbesserte Auflage, Wiesbaden (Gabler) 1988.
- [Kirs79] Kirsch, W.: Die verhaltenswissenschaftliche Fundierung der Betriebswirtschaftslehre, in: [RaAb79], S. 105-120.
- [Klad01] Kladroba, A.: Was ist neu am Data Mining? Einige Anmerkungen zur „neuen“ Datenanalyse aus Sicht der Statistik, in: Allgemeines Statistisches Archiv, 85, 2001, S. 455-462.
- [Klin00] Klingebiel, N.: Integriertes Performance Measurement, Wiesbaden (Deutscher Universitäts-Verlag) 2000.
- [Klin97] Klingebiel, N.: Leistungscontrolling im New Public Management, in: Betriebswirtschaftliche Forschung und Praxis 49 (1997) 6, S. 629-652.
- [Klin99] Klingebiel, N.: Performance Measurement - Grundlagen, Ansätze, Fallstudien, Wiesbaden (Gabler) 1999.
- [Klir69] Klir, G.: An Approach to General Systems Theory, New York (Van Nostrand Reinhold) 1969.
- [Knob00] Knobloch, B.: Der Data-Mining-Ansatz zur Analyse betriebswirtschaftlicher Daten, Bamberger Beiträge zur Wirtschaftsinformatik Nr. 58, Bamberg 2000.
- [KnWe00] Knobloch, B.; Weidner, J.: Eine kritische Betrachtung von Data-Mining- Prozessen - Ablauf, Effizienz und Unterstützungspotentiale, in: [JuWi00], S. 345-365.

-
- [KoBr72] Koontz, H.; Brandspies, R.W: Managing through feedforward control, in: Business Horizons 15 (1972) 3, S. 25-36.
- [Koch08] Koch, S.: Analytisches Performance Management, Edeweicht (OIWIR) 2008.
- [Kosi76] Kosiol, E.: Organisation der Unternehmung, 2. Auflage, Wiesbaden (Gabler) 1976.
- [Kräm01] Krämer, W.: Statistik in den Wirtschaftswissenschaften, in: Allgemeines Statistisches Archiv 85 (2001), S. 187-199.
- [Krcm03] Krcmar, H.: Informationsmanagement, 3., neu überarbeitete und erweiterte Auflage, Berlin (Springer) 2003.
- [Krie71] Krieg, W.: Kybernetische Grundlagen der Unternehmensgestaltung, Bern (Haupt) 1971.
- [KrMü93] Krystek, U.; Müller-Stewens, G.: Frühaufklärung für Unternehmen, Stuttgart (Schäffer-Poeschel) 1993.
- [KrWZ98] Krahl, D.; Windheuser, U; Zick, F.-K.: Data Mining: Einsatz in der Praxis, Bonn (Addison Wesley) 1998.
- [KüBe01] Küsters, U.; Bell, M.: Zeitreihenanalyse und Prognoseverfahren, in: [HKMW01], S. 255-297.
- [Kude01] Kudernatsch, D.: Operationalisierung und empirische Überprüfung der Balanced Scorecard, Dissertation, Wiesbaden (Deutscher Universitäts-Verlag) 2001.
- [KüKr01] Küng, P.; Krahn, A.: Performance-Measurement-Systeme im Dienstleistungssektor - Das Denken in Wirkungsketten ist noch wenig verbreitet, in: io Management 70 (2001) 1/2, S. 56-63.
- [KüKr99] Kueng, P.; Krahn, A.: Building a Process Performance Measurement System: some early experiences, in: Journal of Scientific & Industrial Research, 58 (1999) 3/4, S. 149-159.
- [Kump01] Kumpf, A.: Balanced Scorecard in der Praxis: in 80 Tagen zur erfolgreichen Umsetzung, Landsberg (Verlag moderne Industrie) 2001.
- [Küng00] Küng, P.: Leistungsmessung von Geschäftsprozessen mit Hilfe der Informationstechnologie, in: WISU (2000) 6, S. 829-835.
- [Küpp97] Küpper, H.-U.: Controlling, 2., aktualisierte und ergänzte Auflage, Stuttgart (Schäffer-Poeschel) 1997.

- [Küpp99] Küppers, B.: Data Mining in der Praxis - ein Ansatz zur Nutzung der Potentiale von Data Mining im betrieblichen Umfeld, Dissertation, Frankfurt am Main (Peter Lang) 1999.
- [Kups79] Kupsch, P.: Unternehmungsziele, Stuttgart (Fischer) 1979.
- [Küst01] Küsters, U.: Data Mining Methoden: Einordnung und Überblick, in: [HKMW01], S. 95-130.
- [Kütz03] Kütz, M.: Kennzahlen in der IT - Werkzeuge für Controlling und Management, Heidelberg (dpunkt) 2003.
- [KüWa02] Küpper, H.-U.; Wagenhofer, A. (Hrsg.): Handwörterbuch Unternehmensrechnung und Controlling, 4. Auflage, Stuttgart (Schäffer-Poeschel) 2002.
- [KüWe03] Küng, P.; Wettstein, T.: Ganzheitliches Performance-Measurement mittels Informationstechnologie, Bern (Haupt) 2003.
- [Lach79] Lachnit, L.: Systemorientierte Jahresabschlussanalyse, Wiesbaden (Gabler) 1979.
- [Leba94] Lebas, M.: Management accountants: the challenges for the next decade, in: International Federation of Accountants: A View of Tomorrow - Management Accountancy in the Year 2004, New York 1994, S. 35-54.
- [LeEu02] Lebas, M.; Euske, K.: A conceptual and operational delineation of performance, in: [Neel02], S. 65-79.
- [Lehn03] Lehner, W.: Datenbanktechnologie für Data Warehouse-Systeme, Heidelberg (dpunkt) 2003.
- [LiSc96] Lingle, J.H.; Schieman, W.A.: From Balanced Scorecard to Strategic Gauges - Is Measurement Worth It?, in: Management Review 85 (1996) 3, S. 56-61.
- [LoCD00] Lobo, C.; Cochran, D.; Duda, J.: Using Axiomatic Design To Support the Development of a Balanced Scorecard, in: [Neel00], S. 347-354.
- [LoLa90] Locke, E.A.; Latham, G.P.: A Theory of Goal Setting & Task Performance, Englewood Cliffs (Prentice Hall) 1990.
- [Luhm73] Luhmann, N.: Zweckbegriff und Sytemrationalität, Frankfurt am Main (Suhrkamp) 1973.
- [Mack74] Mackie, J.L.: The Cement of the Universe, Oxford (Clarendon) 1974.

-
- [Mart98a] Martin, W. (Hrsg.): Data Mining, OLAP, Data Warehouse, Bonn (International Thomson Publishing) 1998.
- [Mart98b] Martin, W.: Data Warehouse, Data Mining und OLAP: Von der Datenquelle zum Informationsverbraucher, in: [Mart98a], S. 19-37.
- [Mart03] Martin, W.: Business Performance Management und Real Time Enterprise, [http://www.competence-site.de/bisysteme.nsf/CECF-CEA982E6DF93C1256DB0006729BC/\\$File/bulletin_bi_2003-web-version.pdf](http://www.competence-site.de/bisysteme.nsf/CECF-CEA982E6DF93C1256DB0006729BC/$File/bulletin_bi_2003-web-version.pdf), 2003 (Zugriff am 23.09.04).
- [May99] May, M.: Kausales Schließen - Eine Untersuchung über kausale Erklärungen und Theoriebildung, Bericht Nr. 64 des Graduiertenkolleg Kognitionswissenschaft, Hamburg 1999.
- [McTu97] McKim, V.R.; Turner, S.P. (Hrsg.): Causality in Crisis? Statistical Methods and the Search for Causal Knowledge in the Social Sciences, Notre Dame (University of Notre Dame Press) 1997.
- [MeBH95] Mertens, P.; Bissantz, N.; Hagedorn, J.: Computergestützte Analysemethoden für das Kosten- und Erfolgscontrolling, in: [Reic95], S. 229-251.
- [Meix01] Meixner, U.: Theorie der Kausalität. Ein Leitfaden zum Kausalbegriff in zwei Teilen, Paderborn (Mentis) 2001.
- [Mell63] Mellerowicz, K.: Kosten und Kostenrechnung, Band 1, Berlin (de Gruyter) 1963.
- [MeWi04] Melchert, F.; Winter, R.: The Enabling Role of Information Technology for Business Performance Management, <http://www.alexandria.unisg.ch/EXPORT/DL/28273.pdf>, 2004 (Zugriff am 23.03.09).
- [MeWK04] Melcher, F.; Winter, R.; Klesse, M.: Aligning Process Automation and Business Intelligence to Support Corporate Performance Management, http://verdi.unisg.ch/org/iwi/iwi_pub.nsfwwwPublRecentGer/9B83F2C93EADA9A1C1256EED00605DE8, 2004 (Zugriff am 01.09.04).
- [Meye02] Meyer, M.W.: Finding performance: The new discipline in management, in: [Neel02], S. 51-62.
- [Meye94] Meyer, C.: Betriebswirtschaftliche Kennzahlen und Kennzahlensystemen, 2., erweiterte und überarbeitete Auflage, Stuttgart (Schäffer-Poeschel) 1994.
- [MeZu89] Meyer, M.W.; Zucker, L.G.: Permanently Failing Organizations, Newbury Park (Sage Publications) 1989.

- [Mill75] Mill, J.S.: A system of logic – ratiocinative and inductive, being a connected view of the principles of evidence and the methods of scientific investigation, 9. Auflage, London (Longmans) 1975.
- [Mörc06] Mörchen, F.: Time Series Knowledge Mining, Dissertation, <http://www.mybytes.de/moerchen06tskm.pdf>, 2006 (Zugriff am 04.09.2007).
- [MüHS98] Müller, M.; Hausdorf, C.; Schneeberger, J.: Zur Interessantheit bei der Entdeckung von Wissen in Datenbanken, in: [Nakh98], S. 248-264.
- [Müll98] Müller-Stewens, G.: Performance Measurement im Lichte eines Stakeholderansatzes, in: [ReTD98], S. 34-43.
- [Müll00] Müller, A.: Strategisches Management mit der Balanced Scorecard, Stuttgart (Kohlhammer) 2000.
- [Mult00] Mulhaupt, M.: Data Mining und Text Mining im strategischen Controlling, Dissertation, Aachen (Shaker) 2000.
- [Nakh98] Nakhaeizadeh, G. (Hrsg.): Data Mining – Theoretische Aspekte und Anwendung, Heidelberg (Physica) 1998.
- [NaWi02] Nagel, R.; Wimmer, R.: Systematische Strategieentwicklung - Modell und Instrumente für Berater und Entscheider, Stuttgart (Klett-Cotta) 2002.
- [Neel98] Neely, A.: Measuring Business Performance, London (Profile Books) 1998.
- [Neel00] Neely, A. (Hrsg.): Performance Measurement - Past, Present and Future, Cranfield University (Centre for Business Performance) 2000.
- [Neel02] Neely, A. (Hrsg.): Business Performance Measurement - theory and practice, Cambridge (Cambridge University Press) 2002.
- [NeGP95] Neely, A.; Gregory, M.; Platts, K.: Performance Measurement System Design - A Literature Review and Research Agenda, in: International Journal of Operations & Production Management 15 (1995) 4, S. 80-116.
- [NeKn05] Neckel, P.; Knobloch, B.: Customer Relationship Analytics - Praktische Anwendungen des Data Mining im CRM, Heidelberg (dpunkt) 2005.
- [Niem77] Niemeyer, G.: Kybernetische System- und Modelltheorie: system dynamics, München (Vahlen) 1977.

-
- [NMR + 03] Neely, A.; Marr, B.; Roos, G.; Pike, S.; Gupta, O.: Towards the Third Generation of Performance Measurement, in: *Controlling* 15 (2003) 3/4, S. 129-135.
- [NöFo99] Nölken, D.; Form, S.: Implikationen moderner Informations- und Kommunikationstechnologien für das Controlling am Beispiel des OLAP, in: *Controlling* 11 (1999) 2, S. 87-92.
- [Nölk02] Nölken, D.: *Controlling mit Intranet- und Business Intelligence Lösungen*, Dissertation, Frankfurt am Main (Peter Lang) 2002.
- [Nord31] Nordsieck, F.: Grundprobleme und Grundprinzipien der Organisation des Betriebsaufbaus, in: *Die Betriebswirtschaft* 14 (1931) 6, S. 158-162.
- [Nord72] Nordsieck, F.: *Betriebsorganisation - Betriebsaufbau und Betriebsablauf*, 4. Auflage, Stuttgart (Poeschel) 1972.
- [Oehl00] Oehler, K.: DV-gestützte Gestaltung der BSC, in: [Töpf00a], S. 382-404.
- [Oehl06] Oehler, K.: *Performance Management mit Business Intelligence Werkzeugen*, München (Hanser) 2006.
- [OIRW99] Olve, N.-G.; Roy, J.; Wetter, M.: *Performance Drivers - A Practical Guide to Using the BSC*, Chinchester (Wiley) 1999.
- [OtOK04] Otte, R.; Otte, V.; Kaiser, V.: *Data mining für die industrielle Praxis*, München (Hanser) 2004.
- [Paul04] Paul, J.: Wann Kennzahlen schaden, in: *Harvard Business Manager* (2004) 6, S. 108-111.
- [Pear00] Pearl, J.: *Causality. Models, Reasoning, and Inference*, Cambridge (Cambridge University Press) 2000.
- [PeSc02] Pedell, B.; Schwihel, A.: Balanced Scorecard als strategisches Führungsinstrument in der Energiewirtschaft, in: *Controlling* 14 (2002) 1, S. 45-53.
- [PiDF98] Picot, A.; Dietl, H.; Frank, E.: *Organisation - Eine ökonomische Perspektive*, Stuttgart (Schäffer-Poeschel) 1997.
- [PiFr91] Piatetsky-Shapiro, G.; Frawley, W.J. (Hrsg.): *Knowledge Discovery In Databases*, Menlo Park (AAAI Press/MIT Press) 1991.
- [PiMe03] Pietsch, T.; Memmel, T.: *Balanced Scorecard erstellen - Kennzahlenermittlung mit Data Mining*, Berlin (Erich Schmidt) 2003.

- [Pise04] Piser, M.: Strategisches Performance Management - Performance Measurement als Instrument der Strategischen Kontrolle, Dissertation, Wiesbaden (Deutscher Universitäts-Verlag) 2004.
- [Popp66] Popper, K.R.: Logik der Forschung, 2., erweiterte Auflage, Tübingen (Mohr) 1966.
- [PoSi01] Podding, T.; Sidorovitch, I.: Künstliche neuronale Netze: Überblick, Einsatzmöglichkeiten und Anwendungsprobleme, in: [HKMW01], S. 363-402.
- [Prat08] Terry Pratchett: Die Schlacht der Nomen – Trucker, Wühler, Flügel, 4. Auflage, München (Piper) 2008.
- [PrGo91] Probst, G.J.B.; Gomez, P. (Hrsg.): Vernetztes Denken: ganzheitliches Führen in der Praxis, 2., erweiterte Auflage, Wiesbaden (Gabler) 1991.
- [Pyle99] Pyle, D.: Data Preparation for Data Mining, San Francisco (Morgan Kaufmann) 1999.
- [Pyle03] Pyle, D.: Business Modeling and Data Mining, San Francisco (Morgan Kaufmann) 2003.
- [RaAb79] Raffée, H.; Abel, B.: Wissenschaftstheoretische Grundfragen der Wirtschaftswissenschaften, München (Vahlen) 1979.
- [RaWi85] Raffée, H.; Wiedmann, K.-P.: Strategisches Marketing, Stuttgart (Poeschel) 1985.
- [Reic95] Reichmann, T. (Hrsg.): Handbuch Kosten- und Erfolgscontrolling, Stuttgart (Vahlen) 1995.
- [Reic97] Reichmann, T. (Hrsg.): Controlling mit Kennzahlen und Managementberichten. 5. Auflage, München (Vahlen) 2001.
- [RePo02] Rechenberg, P.; Pomberger, G. (Hrsg.): Informatik-Handbuch, 3., aktualisierte und erweiterte Auflage, München (Hanser) 2002.
- [Resc05] Resch, O.: Data-Mining-gestützte Identifikation von Kausalbeziehungen, in: Information Management & Consulting 20 (2005) 1, S. 63-68.
- [ReTD98] Reinecke, S.; Tomczak, T.; Dittrich, S. (Hrsg.): Marketingcontrolling, St. Gallen (Thesis) 1998.
- [Ried00] Riedl, J.B.: Unternehmungswertorientiertes Performance Measurement - Konzeption eines Performance-Measure-Systems zur Imple-

- mentierung einer wertorientierten Unternehmensführung, Dissertation, Wiesbaden (Deutscher Universitäts-Verlag) 2000.
- [Rock79] Rockart, J.F.: Chief executives define their own data needs, in: Harvard Business Review 57 (1979) 2, S. 81-92.
- [Rols95] Rolstadas, A. (Hrsg.): Performance Management - A Business Process Benchmarking Approach, New York (Chapman & Hall) 1995.
- [RuBr95] Rummler, G.A.; Brache, A.P.: Improving Performance - How to manage the white space on the organization chart, San Francisco (Jossey Bass) 1995.
- [SaBH02] Santos, S.P.; Belton, V.; Howick, S.: Adding value to performance management by using system dynamics and multicriteria analysis, in: International Journal of Operations & Production Management 22 (2002) 11, S. 1246-1272.
- [Säub00] Säuberlich, F.: KDD und Data Mining als Hilfsmittel zur Entscheidungsunterstützung, Dissertation, Frankfurt am Main (Peter Lang) 2000.
- [Scha79] Schanz, G.: Die Betriebswirtschaftslehre und ihre sozialwissenschaftlichen Nachbardisziplinen: Das Integrationsproblem, in: [RaAb79], S. 121-137.
- [Scha88] Schanz, G.: Methodologie für Betriebswirte, 2., überarbeitete und erweiterte Auflage, Stuttgart (Poeschel) 1988.
- [Sche01] Scheffler, U.: Ereignis und Zeit. Ontologische Grundlagen der Kausalrelationen, Berlin (Logos) 2001.
- [ScHE95] Schnell, R.; Hill, P.B.; Esser, E.: Methoden der empirischen Sozialforschung, München (Oldenbourg) 1995.
- [Schm97] Schmid, U.: Das Anspruchsgruppen-Konzept, in: WISU - Das Wirtschaftsstudium 26 (1997) 7, S. 633-635.
- [Schö04] Schöneborn, F.: Strategisches Controlling mit System Dynamics, Dissertation, Heidelberg (Physica) 2004.
- [Schu96] Schulte, C.: Lexikon des Controlling, München (Oldenbourg) 1996.
- [Schw02] Schwarz, R.: Controlling-Systeme: Eine Einführung in Grundlagen, Komponenten und Methoden des Controlling, Wiesbaden (Gabler) 2002.
- [Sear06] Searle, J.R.: Geist - Eine Einführung, Frankfurt am Main (Suhrkamp) 2006.

- [Seng03] Senge, P.M.: Die fünfte Disziplin, 9. Auflage, Stuttgart (Klett-Cotta) 2003.
- [ShLA00] Shulver, M.; Lawrie, G.; Andersen, H.: A Process For Developing Strategically Relevant Measures Of Intellectual Capital, in: [Neel00], S. 547-554.
- [Simo76] Simon, H.A.: Scheinkorrelationen: ihre kausale Interpretation, in: [HuZi76], S. 55-67.
- [Simo99] Simons, R.: Performance Measurement & Control Systems for Implementing Strategy - Text and Cases, Upper Saddle River (Prentice Hall) 1999.
- [Sinz02] Sinz, E.J.: Architektur von Informationssystemen, in: [RePo02], S. 1055-1068.
- [Sinz04] Sinz, E.J.: Unternehmensarchitekturen in der Praxis - Architekturdesign vs. Situationsbedingte Realisierung von Informationssystemen, in: Wirtschaftsinformatik 46 (2004) 4, S. 315-316.
- [SoVr94] Scholz, R.; Vrohling, A.: Prozeß-Leistungs-Transparenz, in: [GSVR94], S. 57-98.
- [Span94] Spangenberg, H.: Understanding and implementing performance management, Plumstead (Juta) 1994.
- [Spet04] Speth, H.-T.: Methodenberichte - Komponentenzerlegung und Saisonbereinigung ökonomischer Zeitreihen mit dem Verfahren BV4.1, http://www.destatis.de/jetspeed/portal/cms/Sites/destatis/Internet/DE/Content/Wissenschaftsforum/MethodenVerfahren/Infos/Heft3_2004,property=file.pdf, 2004 (Zugriff am 25.07.2007).
- [Steio3] Steiner, E.: Wertorientiertes Risikocontrolling mit Künstlichen Neuronalen Netzen, in: Controlling 16 (2004) 11, S. 631-639.
- [Ster00] Serman, J.D.: Business Dynamics - Systems Thinking and Modeling for a Complex World, London (McGraw-Hill) 2000.
- [StSc93] Steinmann, H.; Schreyögg, G.: Management: Grundlagen der Unternehmensführung: Konzepte - Funktionen - Fallstudien, Wiesbaden (Gabler) 1993.
- [Töpf00a] Töpfer, A. (Hrsg.): Das Management der Werttreiber - Die Balanced Scorecard für die Wertorientierte Unternehmenssteuerung, Frankfurt am Main (Frankfurter Allgemeine Zeitung GmbH) 2000.

-
- [Töpf00b] Töpfer, A.: Balanced Score Card als ganzheitliches Managementkonzept - Gestaltungsfelder, Einführungsprozess und Stolpersteine, in: [Töpf00a], S.69-106.
- [UlHi79] Ulrich, P.; Hill, W.: Wissenschaftstheoretische Aspekte ausgewählter betriebswirtschaftlicher Konzeptionen, in: [RaAb79], S. 161-190.
- [Ulri01] Ulrich, H.U.: Systemorientiertes Management: das Werk von Hans Ulrich, Bern (Haupt) 2001.
- [Ulri84] Ulrich, H.U.: Management - Gesammelte Beiträge, Bern (Haupt) 1984.
- [VoBe96] Vossen G.; Becker, J.: Geschäftsprozessmodellierung und Workflow Management - Modelle, Methoden, Werkzeuge, Bonn (International Thomson Publishing) 1996.
- [Wade01] Wade, D.: Corporate performance management, Boston (Butterworth-Heinemann) 2001.
- [Wall01] Wall, F.: Ursache-Wirkungsbeziehungen als ein zentraler Bestandteil der BSC - Möglichkeiten und Grenzen ihrer Gewinnung, in: Controlling 13 (2001) 2, S. 65-74.
- [Wats05] Watson, P.: Ideen - Eine Kulturgeschichte von der Entdeckung des Feuers bis zur Moderne, München (Bertelsmann) 2005.
- [WeGS99] Weber, J.; Grothe, M.; Schäffer, U.: Business Intelligence, Reihe Advanced Controlling, Band 13, WHU Koblenz, Vallendar 1999.
- [Wein75] Weinberg, G.: An Introduction to General Systems Thinking, New York (Wiley) 1975.
- [WeKM01] Wettstein, T.; Küng, P.; Meier, A.: Performance Measurement als Ausweg aus dem Information Overload: Ein zielorientierter Ansatz, in: HMD - Praxis der Wirtschaftsinformatik (2001) 222, S. 49-58.
- [WeSa01] Weber, J.; Sandt, J.: Erfolg durch Kennzahlen - Neue empirische Erkenntnisse, Reihe Advanced Controlling, Band 21, WHU Koblenz, Vallendar 2001.
- [Wett02] Wettstein, T.: Gesamtheitliches Performance Measurement - Vorgehensmodell und informationstechnische Ausgestaltung, Dissertation, Bern (Haupt) 2002.
- [Wied85] Wiedmann, K.-P.: Konzeptionelle und methodische Grundlagen der Früherkennung, in: [RaWi85], S. 301-341.

- [WiEi05] Witten, I.H.; Eibe, F.: Data Mining - Practical Machine Learning Tools and Techniques, 2. Auflage, San Francisco (Morgan Kaufmann) 2005.
- [Wies00] Wiese, J.: Implementierung der Balanced Scorecard - Grundlagen und IT-Fachkonzept, Dissertation, Wiesbaden (Deutscher Universitäts-Verlag) 2000.
- [Wild01] Wilde, K.D.: Data Warehouse, OLAP und Data Mining im Marketing, in: [HKMW01], S. 1-19.
- [Wild82] Wild, J.: Grundlagen der Unternehmensplanung, 4. Auflage, Opladen (Westdeutscher Verlag) 1982.
- [Will93] Willke, H.: Systemtheorie, 4. Auflage, Stuttgart (Fischer) 1993.
- [Witt59] Wittmann, W.: Unternehmung und unvollkommene Information, Köln (Westdeutscher Verlag) 1959.



Viele Unternehmen setzen moderne Performance-Management-Konzepte, wie zum Beispiel die Balanced Scorecard, ein. Hierbei werden Ursache-Wirkungs-Vermutungen aufgestellt, um nicht-finanzielle Kennzahlen zu identifizieren und deren Einfluss auf nachgelagerte Finanzkennzahlen abzubilden. Darüber hinaus werden kausale Abhängigkeiten zwischen Maßnahmen und Zielen in Form von Zweck-Mittel-Beziehungen unterstellt. Die hierfür benötigten Kausalhypothesen werden aber nicht systematisch, sondern meist assoziativ und allein auf Basis von Intuition entwickelt. Man verlässt sich auf vage Vermutungen und hypothetische Zusammenhänge, ohne diese zu überprüfen. Dies birgt die Gefahr einer Fehlsteuerung, indem nutzlose, konfliktäre oder sogar schädliche Maßnahmen aus den nur unzureichend begründeten Ziel- und Kennzahlbeziehungen abgeleitet werden.

Es stellt sich daher die Frage, wie Unternehmen im Performance-Management ein anderer, systematischerer Umgang mit Ursache-Wirkungs-Beziehungen gelingen kann. Auf welchen Wegen können die benötigten Kausalhypothesen entwickelt und überprüft werden?

Um diese Fragen zu beantworten, entwirft diese Arbeit einen generischen Performance-Management-Prozess, der Kausalhypothesen als zentrales Mittel zur ganzheitlichen Gestaltung und Lenkung der betrieblichen Performance nutzt. Daran anknüpfend werden Gestaltungsoptionen für einen Analyseprozess ausgearbeitet, der Kausalhypothesen evidenzbasiert entwickelt und überprüft.

Der wesentliche Beitrag dieser Arbeit besteht darin, dass neben der Datenanalyse ein zweiter - und bis dato noch unbeschrittener - Weg zur Kausalanalyse vorgestellt wird: die modellzentrierte Kausalanalyse. Welche Synergien sich aus der Kombination modell- und datenzentrierter Analyseverfahren ergeben, insbesondere mit den Verfahren des On-Line-Analytical-Processing (OLAP) und Data-Minings, wird empirisch am Beispiel eines Sportartikelherstellers gezeigt.

ISBN 978-3-923507-94-8

ISSN 1867-7401

18,70 Euro