Supplier Risk Monitoring – Wissensmanagement als Grundlage einer präventiven Lieferantenbewertung

vorgelegt von

Dipl.-Ing.

Maria Anja Wilde

von der Fakultät V – Verkehrs- und Maschinensysteme

der Technischen Universität Berlin

zur Erlangung des akademischen Grades

Doktorin der Ingenieurwissenschaften

- Dr.-Ing. -

genehmigte Dissertation

Promotionsausschuss:

Vorsitzender:	Prof. Dr.-Ing. Jörg Krüger
Gutachter:	Prof. Dr.-Ing. Robert Dust
Gutachter:	Univ.-Prof. Dr.-Ing. Stefan Bracke

Tag der wissenschaftlichen Aussprache: 16. Oktober 2019

Berlin 2020

Vorwort

„Information ohne Reflexion ist geistiger Flugsand."
Ernst Reinhardt (*1932)

Den Weg einer Dissertation geht niemand allein. Die Reflexion der vorliegenden Arbeit zum Forschungsthema Total Supplier Risk Monitoring hat über viele Jahre mit Vertretern aus Wissenschaft und Praxis stattgefunden. Diesen möchte ich hiermit danken.

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftliche Mitarbeiterin im Rahmen der Stiftungsprofessur des Verbandes der Automobilindustrie (VDA) am Fachgebiet Qualitätsstrategie und Qualitätskompetenz der TU Berlin sowie während meiner Tätigkeit als Head of Product bei der evan GmbH. Allen voran gilt somit mein Dank dem Leiter der Professur Prof. Dr.-Ing. Robert Dust für die fachliche Unterstützung, die er mir während der Zeit an der TU Berlin entgegengebracht hat. Prof. Dust hat mir damit die Möglichkeit für meine Weiterentwicklung auf zahlreichen Gebieten gegeben. Neben Prof. Dust gilt mein Dank auch Prof. Bracke von der Universität Wuppertal. Prof. Bracke verdanke ich wertvollen fachlichen Input im Bereich Statistik. Ebenso möchte ich dem gesamten Team der evan GmbH danken. Sie haben mir den Freiraum gegeben, die Dissertation parallel zu meinen beruflichen Aufgaben fertig stellen zu können.

Wertvolle wissenschaftliche Unterstützung bekam ich von meinen Kollegen Arne Ramm und Julian Alvarez (TU Berlin) sowie Dr. Katharina Peters (AQI GmbH). Vielen Dank für den Input. Auf meinem Weg durch die Statistik begleiteten mich ebenso Dr. Henning Preis (TU Dresden), Dr.-Ing. Stefan Frank (TU Dresden). Vielen Dank für die Beratung.

Die vorliegende Arbeit verwendet zwar theoretische Modelle, richtet sich aber an Industrieunternehmen, diese Modelle umzusetzen. Für den praktischen Input im Bereich des Lieferantenmanagements danke ich besonders Jan-Henner Theissen (targetP!). Als Fachexperte im Bereich Einkauf und Supply Chain Risk Management habe ich durch unsere vielen Diskussionen sehr von seinen Erfahrungen profitieren können. Aber auch ich hatte durch meine eigenen Erfahrungen als ehemalige strategische Einkäuferin einen Vorteil. Für die Chance in diesem Bereich arbeiten zu können, möchte ich vor allem Dr.-Ing. Andreas Kannt (Fraunhofer Gesellschaft) danken. Durch ihn habe ich auch den initialen Mut gefasst, diese Dissertation zu verfassen.

Mein herzlichster Dank geht an Anna Nowak (TU Berlin). Als ehemalige studentische Hilfskraft hat sie mich als konstruktive Diskussionspartnerin mit ihrem kritischen Blick sehr unterstützt.

Als Kenner der IT danke ich Michael Poitz (p-sysnet.de) und auch Michael Hempel (Vmware, Inc.) für die Inspirationen im Bereich der Informations- und Kommunikationstechnologie. Michael Poitz danke ich zusätzlich für das „Asyl" in seinem Büro. Er hat mir damit eine Oase der Ruhe und des Denkens geschaffen. Bei der Umsetzung der Cluster- und Assoziationsanalyse standen mir Dr.-Ing. Steffen Tomschke (B-S-S GmbH) und Matthias Richter (B-S-S GmbH) zur Seite. Diesen beiden danke ich für die Beratung und den Input zur Umsetzung der Validierung.

Ich danke meiner Familie und meinen Freunden für die Motivation, wohltuenden Worte und Zuversicht. Jeder einzelne hat auf seine Weise zum Gelingen der Arbeit beigetragen. Meine Eltern und Großeltern haben mich dabei besonders unterstützt.

Ein ganz besonderer Dank geht ebenfalls an meinen Mann Stefan und meinen Sohn Ferry. Sie haben mit viel Verständnis, Geduld und großem Verzicht diese Arbeit erst ermöglicht.

Meinem Mann, meinem Sohn sowie meinen Eltern und Großeltern widme ich dieses Buch.

Anja Wilde

Inhaltsverzeichnis

Abbildungsverzeichnis VI
Abkürzungsverzeichnis X
Formelverzeichnis XI
Tabellenverzeichnis XII
1 Einleitung 1
1.1 Motivation und Forschungsbedarf 2
1.2 Aufgabenstellung 7
1.3 Forschungsmethode und Vorgehensweise 8
1.4 Begriffsdefinition 11
2 Stand der Wissenschaft im Lieferantenmanagement 16
2.1 Das Lieferantenmanagement im Beschaffungsprozess 16
2.2 Das Lieferantenmanagement 19
2.2.1 Definition des Lieferantenmanagements 19
2.2.2 Ausprägungen des Lieferantenmanagements 21
2.3 Risikobetrachtung im Lieferantenmanagement 25
2.3.1 Ziele und Nutzen der Risikobetrachtung 25
2.3.2 Anforderungsprofil an eine Lieferantenbewertung 28
2.3.3 Bewertungskriterien 30
2.3.4 Stufen der Lieferantenbewertung 31
2.3.4.1 Stufe 1: Betrachtung einer Dimension 34
2.3.4.2 Stufe 2: Betrachtung verschiedener Dimensionen 35
2.3.4.3 Stufe 3: Verknüpfung von Daten zu interpretierbaren Informationen 41
2.3.4.4 Stufe 4: Vernetzung verschiedener Informationen zu Wissen 42
2.4 Wissensgenerierung durch Lieferantenbewertungsverfahren 45
2.5 Zusammenfassung und Fazit 54
3 Total Supplier Management 55
3.1 Ziele und Nutzen des Total Supplier Managements 55
3.2 Anforderungsprofil 59
3.3 Differenzierte Risikokategorisierung 62
3.3.1 Kategorisierung von Risiken nach SCOR 62
3.3.2 Kategorisierung nach Risiken entlang der Supply Chain 63

3.3.3 Kategorisierung nach der fachlichen und thematischen Orientierung 66
3.3.4 Zwischenfazit zu den diskutierten Kategorisierungsmodellen 68
3.3.5 Kategorisierung von Risiken nach der Workfloworientierung im TSM 69
3.4 Workflow im Total Supplier Management 71
3.4.1 Informieren 71
3.4.2 Entscheiden 74
3.4.3 Durchführen 76
3.4.4 Lessons Learned 78
3.5 Zusammenfassung und Fazit 80
4 Wissensmanagement im Total Supplier Management 82
4.1 Aufgaben und Nutzen des Wissensmanagements 83
4.2 Methoden zur Wissensgenerierung 88
4.3 Verfahren zur Wissensgenerierung im Data Mining 90
4.3.1 Trend- und Prognosemodell 91
4.3.2 Clusteranalyse 95
4.3.3 Assoziationsanalyse 97
4.3.4 Relevanzprüfung 101
4.4 Potenzielle Data Mining-Prozesse 109
4.4.1 Data Mining im KDD-Prozess 109
4.4.2 Data Mining-Prozess nach SEMMA 112
4.4.3 Data Mining-Prozess nach CRISP-DM 113
4.4.4 Kritische Auseinandersetzung 117
4.5 Entwicklung eines Data Mining-Prozesses 124
4.5.1 Treiber und Aufgaben des Data Mining-Prozesses 124
4.5.2 Data Mining zur Risikobetrachtung im Total Supplier Management 126
4.6 Data Mining im Rahmen des Wissens- und Total Supplier Managements 130
4.6.1 Umfeldverständnis 130
4.6.2 Datensammlung 132
4.6.3 Datenprüfung 134
4.6.4 Datentransformation 135
4.6.5 Datenmodellierung 137
4.6.6 Evaluation und Anwendung der Ergebnisse 140
4.7 Zusammenfassung und Fazit 142

5 Datenqualität 145
5.1 Ziele und Nutzen einer hohen Datenqualität 147
5.2 Data Profiling durch Data Checker 151
5.2.1 Konzeptioneller Data Checker 152
5.2.2 Formaler Data Checker 154
5.2.3 Statistischer Data Checker 156
5.2.4 Logischer Data Checker 159
5.3 Absicherung der Datenqualität durch Data Cleaning 163
5.4 Zusammenfassung und Fazit 165
6 Konzeptionsprüfung 168
7 Zusammenfassung und Ausblick 184
7.1 Zentrale Forschungsergebnisse 184
7.2 Weiterführende Forschungsvorschläge 188
7.3 Schlusswort 191
Glossar XII
Literaturverzeichnis XV
Anhang A XXXVI
Anhang B XXXVIII
Anhang C XLI
Anhang D XLV
Anhang E LXIII

Abbildungsverzeichnis

Bild 1-1: Umsetzung eines ganzheitlichen Lieferantenmanagements 4
Bild 1-2: Forschungsmodell der vorliegenden Arbeit 8
Bild 1-3: Aufbau der vorliegenden Arbeit 9
Bild 1-4: Abgrenzung der Begriffe Verfahren, Methode und Modell 11
Bild 1-5: Datenbasis im Data Mining 12
Bild 1-6: Abgrenzung der Begriffe Datenbasis, Datensatz sowie Werte und Zeichen 13
Bild 2-1: Anstieg des Anspruchs vom klassischen Einkauf zum Supply Chain Management 17
Bild 2-2: Prozess des Lieferantenmanagements 20
Bild 2-3: Konzept integriertes Lieferantenmanagement 22
Bild 2-4: Regelprozesse und Risikofilter im Lieferantenmanagement 24
Bild 2-5: Zeitpunkte im Prozess der Lieferantenbewertung 27
Bild 2-6: Einteilung Lieferantenbewertungsverfahren aus der Literatur 32
Bild 2-7: Evolution der Lieferantenbewertung 33
Bild 2-8: Vorgehensweise zur Ermittlung einer Rangfolge zwischen besten und schlechtesten Lieferanten 37
Bild 2-9: Verteilung der Kriterien zur Auswahl der Lieferanten, die regelmäßig bewertet werden 38
Bild 2-10: Kombination von Lieferantenbewertungsverfahren innerhalb der Komplexitätsstufe 4 53
Bild 2-11: Umsetzung der Lieferantenbewertung im produzierenden Unternehmen 54
Bild 3-1: Zielkonflikte der Fachbereiche Einkauf, Logistik, Qualität und Technik 56
Bild 3-2: Abgrenzung von Organisationsstrukturen, Prozessen und Methoden im TSM 57
Bild 3-3: Total Supplier Management 58
Bild 3-4: Die zehn Bausteine des Total Supplier Managements 59
Bild 3-5: Die sechs Qualitätsmerkmale des ganzheitlichen Lieferantenmanagements im TSM 60
Bild 3-6: Umsetzungsgrad der einzelnen Bausteine im TSM 61
Bild 3-7: SCOR-Modell 62
Bild 3-8: Risikokategorisierung in der Supply Chain nach Sodhi und Tang 64
Bild 3-9: Risikokategorisierung in der Supply Chain nach Christopher und Peck 65
Bild 3-10: Risikokategorisierung in der Supply Chain nach Romeike und Hager 66

Bild 3-11: Risikokategorisierung in der Supply Chain nach Matzenbacher et al. 67
Bild 3-12: Risikokategorisierung in der Supply Chain nach Hoffmann und Roland.....67
Bild 3-13: Risikoidentifizierung.....68
Bild 3-14: Risikokategorisierung im Total Supplier Management 69
Bild 3-15: Integration der differenzierten Risiken im TSM-Modell.....70
Bild 3-16: Workflow des Total Supplier Management.....71
Bild 3-17: Gestufte Lieferantenbewertung.....72
Bild 3-18: Identifikation möglicher kritischer Lieferanten mit Hilfe des Trend- und Prognosemodells.....73
Bild 3-19: Bereichsübergreifender Lieferantensteuerkreis im Total Supplier Management.....74
Bild 3-20: Eskalationsmodell.....76
Bild 3-21: Informationen aus dem Eskalationsmodell im Kontext zum TSM-Workflow ...78
Bild 3-22: PDCA-Zyklus.....79
Bild 3-23: Anteil der Unternehmen mit Bausteinen in einer durchgängigen Prozessabfolge.....81
Bild 4-1: Abgrenzung der Begriffe Daten, Information, Wissen 82
Bild 4-2: Bausteine des Wissensmanagements 83
Bild 4-3: Wissensmanagement als Teil des Total Supplier Management Workflows....85
Bild 4-4: Ebenenmodell des Wissensmanagements 87
Bild 4-5: Die Spirale des Wissens mit den vier Prinzipien der Wissensentwicklung 88
Bild 4-6: Begriffsabgrenzung vom Wissensmanagement zum Data Mining.....89
Bild 4-7: Vernetzung verschiedener Lieferantenbewertungsverfahren zur Generierung von Wissen 90
Bild 4-8: Prozess des Trend- und Prognosemodells 91
Bild 4-9: Trend- und Prognosemodell im Rahmen der Watchlist 94
Bild 4-11: Prozess der hierarchischen Clusteranalyse 95
Bild 4-12: Allgemeine Darstellung einer Distanzmatrix.....96
Bild 4-13: Zusammensetzung der Komponenten einer Assoziationsregel in Bezug auf die Datenbasis 98
Bild 4-14: Anwendung der Assoziationsanalyse innerhalb der Lieferantenbasis 100
Bild 4-15: Zusammenhang zwischen Regelkopf und Regelrumpf 101
Bild 4-16: Stufenweises Vorgehen zur Relevanzprüfung 105
Bild 4-17: Kombination von Assoziationsregeln 106

Bild 4-18: Data Mining im KDD-Prozess 110
Bild 4-19: Data Mining-Prozess nach SEMMA 112
Bild 4-20: CRISP-Modell 114
Bild 4-21: Vergleich der Prozessschritte von KDD, SEMMA und CRISP-DM 117
Bild 4-22: Data Mining-Prozessschritte zur Anwendung im TSM 120
Bild 4-23: Abgebildeter Prozess im Analyzer zur Generierung von quantitativen Assoziationsregeln 122
Bild 4-24: Beispiel eines Ergebnisses des Analyzers 123
Bild 4-25: Treiber des Data Mining 124
Bild 4-26: Gesamtmodell des Total Supplier Risk Monitoring 128
Bild 4-27: Data Mining im Total Supplier Management 128
Bild 4-28: Data Mining-Prozessschritte im Rahmen des TSM 130
Bild 4-29: Umfeldverständnis des Data Mining-Prozesses im Kontext zum TSM sowie der Verbindung zu den acht Bausteinen des Wissensmanagements 131
Bild 4-30: Wissensgenerierung des Data Mining-Prozesses im Kontext zum TSM sowie der Verbindung zu den acht Bausteinen des Wissensmanagements 132
Bild 4-31: Vierstufiges Vorgehen zur Identifizierung relevanter Daten und Datenquellen 133
Bild 4-32: Anwendung der Datenmodellierung im Kontext des Data Mining 137
Bild 4-33: Beispiel für einen lernenden Prozess zwischen Datenmodellierung und dem TSM 139
Bild 4-34: Evaluation und Anwendung der Ergebnisse des Data Mining-Prozesses im Kontext zum TSM sowie der Verbindung zu den acht Bausteinen des Wissensmanagements 140
Bild 4-35: Interdisziplinarität des Data Mining 142
Bild 4-36: Vorteile der angewendeten Kombination von Analyseverfahren 144
Bild 5-1: Stufenleiter der Datenintegration im Lieferantenmanagement 145
Bild 5-2: Einordnung der Stufenleiter der Datenintegration im Data Mining 146
Bild 5-3: Datenqualitätsmerkmale der DGIQ 148
Bild 5-4: Ursachen schlechter Datenqualität 148
Bild 5-5: Data Profiling und Data Cleaning Prozess 149
Bild 5-6: Steigerung der Komplexität bei der Anwendung der Data Checker 151
Bild 5-7: Konzeptioneller Data Checker am Fallbeispiel der Kennzahl „Reklamationsquote“ 152

Bild 5-8: statistische Verteilung der Kennzahl ppm pro Lieferant innerhalb eines Monats....157
Bild 5-9: Vernetzung von zwei Tabellen mit RapidMiner....160
Bild 5-10: Ergebnis des logischen Data Checkers....161
Bild 5-11: Prozesse des Data Cleaning bei fehlerhaften Daten....163
Bild 5-12: Übersicht der Data Checker....165
Bild 5-13: Kosten-Nutzen-Faktor der Datenqualität....166
Bild 6-1: Watchlist als Analysetool für das Trend- und Prognosemodell – Auszug der Ergebnisse....171
Bild 6-2: Datenimport in den Analyzer als Analysetool für quantitative Assoziationsregeln – Auszug der Ergebnisse....172
Bild 6-3: Ergebnisse der Clusteranalyse für die importierte Datenbasis auf Basis von 2 Clustern je Attribut – Auszug der Ergebnisse....173
Bild 6-4: Ergebnisse der quantitativen Assoziationsanalyse für die importierte Datenbasis auf Basis von 2 Clustern oder 2 Ausprägungen nominaler Datentypen je Attribut – Auszug der Ergebnisse....174
Bild 7-1: Erweiterung des Data Mining um das Text Mining....188
Bild 7-2: Prozesskostencockpit....189
Bild 7-3: Schema einer Graphdatenbank....190

Abkürzungsverzeichnis

bspw.	beispielsweise
bzw.	beziehungsweise
d. h.	das heißt
ERP-System	Enterprise Ressource Planning-System
et al.	et alii (Maskulinum), et aliae (Femininum) oder et alia (Neutrum)
ggf.	gegebenenfalls
IKT	Informations- und Kommunikationstechnik
IT	Informationstechnik
IuK-Systeme	Informations- und Kommunikationssysteme
KPI	Key Performance Indicator
KVP	Kontinuierlicher Verbesserungsprozess
LT	Liefertreue (Logistikkennzahl)
OEM	Original Equipment Manufacturer
OLAP	Online Analytical Processing
ppm	parts per million (Qualitätskennzahl)
RQ	Reklamationsquote (Qualitätskennzahl)
SCM	Supply Chain Management
TSM	Total Supplier Management
u. a.	unter anderem
u. U.	unter Umständen
WM	Wissensmanagement
z. B.	zum Beispiel

Formelverzeichnis

(1) Regressionsgerade....92
(2) Achsenabschnitt....92
(3) Anstieg der Regressionsgerade....92
(4) L_p-Metrik....96
(5) Manhattan-Distanz....96
(6) Minimaler Abstand für eine hierarchische Clusterbildung....96
(7) Zusammenhang zwischen Prämisse und Implikation....97
(8) Interessantheitsmaß Support....99
(9) Interessantheitsmaß Support im Zusammenhang zwischen Prämisse und Implikation....99
(10) Interessantheitsmaß Konfidenz....99
(11) Interessantheitsmaß Lift....99
(12) Binomialkoeffizient....103
(13) Formel für die Gesamtanzahl aller möglichen, quantitativen Assoziationsregeln....104
(14) Interessantheitsmaß Support in der Anwendung zur Relevanzprüfung in Stufe 3....107
(15) Qualitätskennzahl Reklamationsquote....153
(16) Qualitätskennzahl ppm....160

Tabellenverzeichnis

Tabelle 1-1: Forschungsbedarf und Forschungsvorhaben zum Thema Wissensmanagement 5

Tabelle 1-2: Forschungsbedarf und Forschungsvorhaben zum Thema Wissensgenerierung 6

Tabelle 1-3: Forschungsbedarf und Forschungsvorhaben zum Thema Prävention durch Lieferantenbewertung 6

Tabelle 2-1: Typische Vertreter aus der Literatur in Bezug auf die Prozesskomplexität der Wertschöpfung 18

Tabelle 2-2: Literarischer Auszug der verschiedenen Aufgaben des Lieferantenmanagements 19

Tabelle 2-3: Ziele einer Risikobetrachtung im Lieferantenmanagement 26

Tabelle 2-4: Anforderungen an eine Lieferantenbewertung 28

Tabelle 2-5: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 1 45

Tabelle 2-6: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 2 47

Tabelle 2-7: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 3 49

Tabelle 2-8: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 4 51

Tabelle 4-1: Zuordnung von zwei Attributen zu Regelkopf und Regelrumpf 102

Tabelle 4-2: Zuordnung von drei Attributen zu Regelkopf und Regelrumpf 103

Tabelle 4-3: Validierung der Formel zur Errechnung der Gesamtanzahl aller möglichen, quantitativen Assoziationsregeln anhand der definierten Rahmenbedingungen 104

Tabelle 4-4: Erfüllungsgrad zur Wissensgenerierung durch KDD und SEMMA 118

Tabelle 4-5: Erfüllungsgrad zur Wissensgenerierung durch CRISP-DM 119

Tabelle 4-6: Anwendung der Data Mining-Prozesse 121

Tabelle 4-7: Anwendungsfelder des Data Mining 127

Tabelle 4-8: Datentransformation von Big Data zu Smart Data für die Data Mining-Verfahren 136

Tabelle 4-9: Abgrenzung der Verfahren im Rahmen der Datenmodellierung 138

Tabelle 5-1: Überblick formaler Analyseverfahren 154

Tabelle 5-2: Beispiele zur Prüfung der formalen Datenqualität 155

Tabelle 5-3: Überblick statistischer Analyseverfahren 156

Tabelle 5-4: Überblick statistischer Analyseverfahren 158

Tabelle 5-5: Beispiele zur Prüfung der statistischen Datenqualität 158

Tabelle 5-6: Überblick logischer Analyseverfahren 159

Tabelle 5-7: Beispiele zur Prüfung der logischen Datenqualität 162
Tabelle 6-1: Importierte Datenbasis 169
Tabelle 6-2: Datenqualität auf Basis der Data Checker 170
Tabelle 6-3: Ergebnis der Relevanzprüfung 180
Tabelle 7-1: Bezug zwischen Forschungsvorhaben und Alleinstellungsmerkmalen der vorliegenden Arbeit 186

1 Einleitung

In der Vergangenheit hat sich der klassische Einkauf im Unternehmen durch den Fokus auf die Verhandlung von Materialkosten und Einstandspreisen definiert [GRO80]. Die Einkaufsziele sind somit weitgehend material- bzw. produktbezogen. Über diese Ziele hat der klassische Einkauf zum Unternehmensgewinn beigetragen [WES72].

Die Beschaffung von Rohstoffen, Komponenten und Systemen wird auch in Zukunft für das Unternehmensergebnis von großer Bedeutung sein. Auf Grund der steigenden Komplexität der Wertschöpfungsnetzwerke [SYD15] liegen jedoch die weitaus größeren Potenziale in einer effizienten Steuerung der Supply Chain [DUS10a]. Mit Hilfe einer bereichsübergreifenden und koordinierenden Steuerung werden Synergieeffekte bei den Faktoren Zeit, Aktivitäten sowie Ressourcen genutzt [THO08]. Deshalb wird die Steuerung und Bewertung dieser heterogenen Partnernetzwerke mit konventionellen Methoden zunehmend schwieriger [DUS10b, BAU14].

Der zunehmende Wettbewerb, gepaart mit einem schnellen technologischen Wandel und verkürzten Produktlebenszyklen, stellt durch die entstehende Komplexität immer höhere Anforderungen an Unternehmen in zahlreichen Branchen. Die steigende Produktvielfalt, kürzere Innovationszyklen sowie branchenübergreifende Geschäftsmodelle mit digitalen Geschäftsprozessen erweitern zusätzlich die Komplexität der zukünftigen Steuerung der Wertschöpfungsnetzwerke [KLE06, SCH09b]:

Externe Wertschöpfung der steigenden Produktvielfalt

Ein anhaltender Trend ist in diesem Zusammenhang das Outsourcing von Kernkompetenzen und somit der steigende Wertschöpfungsanteil der Zulieferer [GÖP16]. Daraus resultiert, dass die Wertschöpfung eines Unternehmens erheblich von der Leistungsfähigkeit der Lieferanten abhängt [LAR09, DÖL11]. Die steigende Produktvielfalt [EIG17a] mit kurzen Innovationszyklen [EIG17b] wird dabei durch die hohe Volatilität der produktspezifischen Anforderungen zur Herausforderung.

Neue, branchenübergreifende Geschäftsmodelle

Zunehmend kooperieren verschiedene Branchen sehr eng miteinander oder verschmelzen mitunter. Beispielsweise wird der Fahrer eines Autos zunehmend den Service der Mobilität in Verbindung mit modernen Informations- und Kommunikationsmitteln nutzen [RAN17]. Somit werden die Lieferantennetzwerke zukünftig branchenübergreifend gesteuert.

Digitalisierung der Geschäftsprozesse

Neue Formen der Datenerhebung und -verarbeitung bieten Unternehmen vielfältige Ansätze, um die externe Wertschöpfung abzusichern und zu steuern [WIL18b, HER19]. Dabei zählt Big Data zu den aktuellen Megatrends [GLU16]. Quantitativ nimmt die weltweit gespeicherte Datenmenge stets zu [STE15, SCH16]. Diese Daten bilden die Basis für eine Lieferantenbewertung, um präventive Maßnahmen einleiten zu können. Aufgrund der vielfältigen Datenmenge und der neuen Möglichkeiten der Datenverarbeitung werden andere Methoden als die klassischen Verfahren zur Lieferantenbewertung und somit zur Steuerung des Wertschöpfungsnetzwerkes notwendig [LÜN16a].

Aus diesen beschriebenen Anforderungen resultiert die steigende Komplexität der Steuerung von externen Wertschöpfungsnetzwerken. Diese Steuerung wird bisher durch das Lieferantenmanagement abgedeckt [GLA94, ARN08b, JAN08]. Doch moderne Lieferantenstrukturen werden zunehmend volatiler. So beschreiben WAGNER UND BODE [WAG08a] diese Veränderung als instabile Welt mit stetig wachsenden, sensibleren Wertschöpfungsnetzwerken. Somit muss sich auch die Steuerung der externen Wertschöpfungsnetzwerke an die neuen Anforderungen anpassen. Dafür muss zunächst Wissen über die Lieferanten generiert werden.

In der vorliegenden Arbeit wird ein Modell zur Wissensgenerierung über das externe Wertschöpfungsnetzwerk erarbeitet. Auf Grundlage des in der vorliegenden Arbeit neu entwickelten Modells soll es Unternehmen gelingen, mit effizienten Methoden Wissen über die Lieferantenbasis zu generieren, um frühzeitig und präventiv Maßnahmen zur Sicherung bzw. Wiederherstellung der Lieferantenleistung einleiten zu können. Diese Wissensgenerierung ist in einen standardisierten Workflow eingebunden. Die partnerschaftlich gestalteten Prozesse innerhalb dieses Workflows haben die Steigerung der Effizienz und damit die Verbesserung der Wettbewerbsposition zum Ziel. Somit unterstützt die vorliegende Arbeit eine effiziente Steuerung der externen Wertschöpfungsnetzwerke.

1.1 Motivation und Forschungsbedarf

Die zunehmende Komplexität der externen Wertschöpfungsnetzwerke wird in der Literatur häufig postuliert [LOC07, MÖß07, WAL10]. SCHUH beschreibt den Begriff der Komplexität unter anderem durch die „Anzahl und Verschiedenheit der Elemente und Beziehungen, die in diesem System vorkommen“ [SCH05]. Diese komplexen Netzwerke müssen gesteuert werden.

Es gibt eine Vielfalt von wissenschaftlichen Publikationen über die Steuerung und die damit verbundene Bewertung der Leistungserbringung von Lieferanten innerhalb der externen Wertschöpfungsnetzwerke [GLA94, HAR94, JAN08, POL10, IRL12, HEL16]. Die Lieferantenbewertung gilt dabei als Prozessschritt im Lieferantenmanagement (Kapitel 2.2.1). Die Ausgestaltung der Unternehmensorganisation [SYD99] sowie der partnerschaftlichen und kooperativen Beziehungen zwischen Zulieferer und Abnehmer im Bereich des Lieferantenmanagements wird im Zusammenhang mit der Lieferantenbewertung zwar immer wieder genannt [LAM05, KLE14, SCH14a, FRI15], aber nicht als ganzheitlicher Ansatz in Verbindung mit unterstützenden Methoden und IT-Systemen für eine effiziente Steuerung der Wertschöpfungsnetzwerke beschrieben [WIE17]. Die Autoren fokussieren sich auf bestimmte Teilgebiete aus dem Bereich des Lieferantenmanagements. HARTING [HAR94] betrachtet beispielsweise die Lieferantenbewertung als Grundlage für die Lieferantenwertanalyse zur Auswahl und Kontrolle der Zulieferer. GLANTSCHNIG [GLA94] identifiziert geeignete Bewertungskriterien für die Lieferantenbewertung, stellt jedoch keinen Bezug zu einer entsprechenden Bewertungsmethode her. DREYER [DRE00] empfiehlt eine lieferantentypenspezifische Bewertung mit Hilfe der Klassifikation der Zulieferer und WAGNER [WAG01] postuliert über eine empirische Studie die Bedeutung des Lieferantenmanagements. Multivariate Ansätze zur Lieferantenbewertung untersuchen JANKER [JAN08], DURST [DUR11] und IRLINGER [IRL12]. Eine Abhandlung zu Frühwarnsystemen im Rahmen der Lieferantenbewertung ist bei MODER [MOD08] enthalten. Diese Art der Lieferantenbewertung steht jedoch nicht im Kontext eines standardisierten Workflows im Rahmen des ganzheitlichen Lieferantenmanagements. Teilweise beziehen sich die genannten Autoren in ihren Ausführungen auf spezifische Lieferantenbewertungsverfahren

[HOF09, HEL16]. Folglich besteht ein Forschungsbedarf über die ganzheitliche Ausgestaltung einer Lieferantenbewertung im Rahmen eines Workflows zur präventiven Steuerung der externen Wertschöpfung.

Für eine effiziente und präventive Steuerung der Wertschöpfungsnetzwerke wird Wissen benötigt (Kapitel 2.3.4). Dieses Wissen wird unter anderem mit Hilfe von Datenmustern generiert [GRO06]. Die klassischen Lieferantenbewertungsverfahren und -methoden, wie sie in verschiedenen Abhandlungen postuliert werden [GLA94, HAR94, JAN08, POL10, IRL12], decken die gestiegenen Anforderungen, wie die Digitalisierung der Geschäftsprozesse oder auch die Entwicklung neuer Geschäftsmodelle [LÜN16b], nicht mehr ab [DUS15]. Die Verfahren sowie die zugehörigen IT-Systeme, oder auch IT-Tools genannt, sind nicht in einen ganzheitlichen Prozess oder Workflow eingebunden, sondern werden als alleinstehende Lösung beschrieben [HAR94, JAN08, IRL12]. „Allerdings entfaltet ein Tool nur dann seine Wirkung, wenn es die definierten Prozesse unterstützt, also in der Reihenfolge: erst Prozess – dann Tool“ [GAB15].

Bisher fehlt die Erarbeitung eines ganzheitlichen Workflows zur effizienten Wissensgenerierung über die Leistungserbringung der Lieferanten. Somit entsteht ein evidenter Forschungsbedarf für ein ganzheitliches Konzept mit einem entsprechenden Workflow sowie unterstützenden Methoden und IT-Tools zur Wissensgenerierung über die Zulieferer. Ansätze der Workflow-Management-Systeme, wie von HEINZ ET AL. [HEI02] postuliert, müssen erst auf diese Problemstellung adaptiert werden.

Wie wichtig dieses Wissen ist, zeigt ein aktuelles Beispiel aus der Automobilindustrie: Ein Automobilhersteller ist dazu gezwungen, die Produktion teilweise still zu legen [HAN17]. Der Grund ist ein fehlendes Bauteil eines Zulieferers. Die Kosten und auch der Imageschaden bei einem Bandstillstand sind enorm hoch [SCH99]. Ein ganzheitliches Lieferantenmanagement mit standardisierten Prozessen, Methoden und IT-Tools kann das Risiko eines Versorgungsengpasses gegebenenfalls verhindern [DUS10c]. Dazu muss das Wissen über die Lieferantenbasis zunächst generiert werden. Bisher fehlen jedoch entsprechende Ansätze [JAN08, MOD08, EBE13].

Die bisherigen Lieferantenbewertungsverfahren mit ihren IT-Tools sowie internen und externen Zusammenarbeitsmodellen reichen für die gestiegene externe Wertschöpfung nicht mehr aus. Gründe dafür sind unter anderem branchenübergreifende Geschäftsmodelle [BLU17] oder auch die stetig steigenden Datenmengen im Zuge der Digitalisierung von Geschäftsprozessen. Die Folgen daraus sind unter anderem eine verringerte Reaktionsfähigkeit auf Marktanforderungen und eine geringe Leistungserbringung der Zulieferer [DUS10b]. Diese Erkenntnis fehlender präventiver, effizienter und nachhaltiger Ansätze zur Generierung von Wissen über die Lieferantenbasis im Rahmen eines ganzheitlichen Lieferantenmanagements unterstreicht die Studie von DUST UND WILDE [DUS16d].

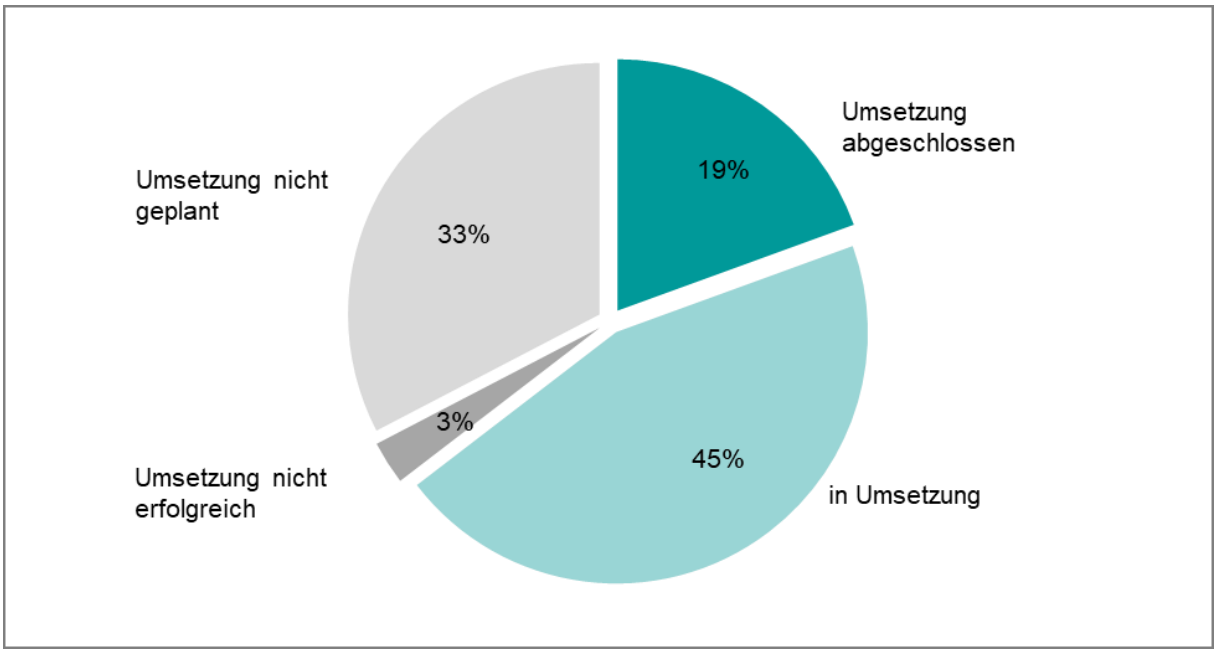


Bild 1-1: Umsetzung eines ganzheitlichen Lieferantenmanagements
Quelle: [DUS16d]

Allgemein haben 67 Prozent der Studienteilnehmer den Bedarf nach einem ganzheitlichen Lieferantenmanagement erkannt. Von diesen Studienteilnehmern haben 19 Prozent ein ganzheitliches Lieferantenmanagement erfolgreich umgesetzt. 45 Prozent befinden sich in der Umsetzungsphase. Insgesamt ist ein Drittel der Studienteilnehmer bei der Umsetzung nicht erfolgreich oder plant keine Installation eines ganzheitlichen Lieferantenmanagements. Die Schlussfolgerung liegt nahe, dass die bisherigen Methoden und IT-Tools zu ineffizient oder aber für die Geschäftsmodelle unzureichend sind [DUS16d]. Die Lieferantenleistung wird zwar innerhalb der Steuerung der externen Wertschöpfungsnetzwerke regelmäßig überprüft [JAN08]. Jedoch existiert bisher ein Verfahrenspluralismus, nach dem die Zulieferer anhand von unternehmensspezifischen Anforderungen in Bezug auf ihre Leistungsfähigkeit beurteilt werden [MÜS07, ARN08b, JAN08, MOD08, ARN10]. Somit besteht ein weiterer Forschungsbedarf für eine effiziente Wissensgenerierung zur präventiven und nachhaltigen Steuerung des externen Wertschöpfungsnetzwerkes.

Um den Forschungsbedarf an einer präventiven Lieferantenbewertung auf Grundlage des Wissensmanagements zu verdeutlichen, werden im Folgenden offene Fragen aus der Literatur zu diesem Thema zusammengestellt. Die Tabellen 1-1 bis 1-3 dienen der Übersichtlichkeit und sind nach den Themen

- Wissensmanagement zur Steuerung der Wertschöpfungsnetzwerke,
- Wissensgenerierung im Rahmen der Lieferantenbewertung und
- Prävention durch die Lieferantenbewertung gegliedert.

Zu den einzelnen Themen werden jeweils der Forschungsbedarf sowie das Forschungsvorhaben im Rahmen der vorliegenden Arbeit dargestellt.

Tabelle 1-1: Forschungsbedarf und Forschungsvorhaben zum Thema Wissensmanagement
Quelle: Eigene Darstellung

Autor	Forschungsbedarf	Forschungsvorhaben im Rahmen der vorliegenden Dissertation
JANKER [JAN08]	Neue Gestaltung eines Wissensmanagements im Bereich des Lieferantenmanagements	Das Wissensmanagement wird durch ein ganzheitliches Konzept mit dem Workflow des Total Supplier Managements sowie dem Prozess des Data Mining für eine präventive Lieferantenbewertung als durchgängiges Steuerungskonzept verbunden.
	„Entwicklung weiterer Managementansätze: Es sind durchgängige, integrierende Planungs- und Steuerungskonzepte zu entwerfen, welche sämtliche Aktivitäten des Lieferantenmanagements zielführend steuern […]."	

Bisher ist keine wissenschaftliche Arbeit bekannt, die den Bereich des Wissensmanagements (Knowledge Management, Knowledge Discovery in Databases etc.) mit dem Bereich des Lieferantenmanagements (Supply Chain Management, Total Supplier Management etc.) in Verbindung bringt. Somit entsteht ein Forschungsbedarf, diese Ansätze weiterzuentwickeln und die Synergieeffekte für eine Lieferantenbewertung zu nutzen. Das Ziel ist es, potenzielle Risiken im externen Wertschöpfungsnetzwerk frühzeitig zu erkennen und auf dieser Basis präventive Handlungsmaßnahmen zu initiieren.

In der vorliegenden Arbeit ist zu untersuchen, ob das Data Mining im Bereich des Total Supplier Managements zur Wissensgenerierung genutzt werden kann. Auf Grund der wachsenden Datenmengen wird dafür die Unterstützung der IT benötigt.

Tabelle 1-2: Forschungsbedarf und Forschungsvorhaben zum Thema Wissensgenerierung
Quelle: Eigene Darstellung

Autor	Forschungsbedarf	Forschungsvorhaben im Rahmen der vorliegenden Dissertation
SYDOW UND MÖLLERING [SYD15]	„Entscheidungstheoretische Überlegungen […] zeigen die Beschaffung als sozialen Prozess mit verschiedensten, teils konfliktären Zielen der Beteiligten, mit unvollkommenen Informationen als Entscheidungsgrundlagen und mit bisweilen (u.U. sogar bewusst) stark vereinfachten oder gar ungeordneten Entscheidungsverläufen.“	Es wird im Rahmen der Wissensgenerierung eine bereichsübergreifende Entscheidungsgrundlage erarbeitet. Dieses generierte Wissen über Risiken im externen Wertschöpfungsnetzwerk wird in einen standardisierten Workflow zur Risikominimierung und -vermeidung eingebunden.

SYDOW UND MÖLLERING [SYD15] postulieren mit der Aussage einen Bedarf zur Ausgestaltung einer präventiven Lieferantenbewertung, zur Implementierung eines ganzheitlichen Workflows sowie Defizite bei der Standardisierung der bisherigen Prozesse zur Steuerung der externen Wertschöpfungsnetzwerke. Die vorliegende Arbeit bietet für diese Problemstellungen innovative Lösungen.

Eine empirische Untersuchung von WAGNER [WAG01] verdeutlicht die steigende Bedeutung des Lieferantenmanagements. Effiziente Methoden zur frühzeitigen Risikoerkennung über die externen Wertschöpfungsnetzwerke sind in der Literatur jedoch nicht zu finden.

Tabelle 1-3: Forschungsbedarf und Forschungsvorhaben zum Thema Prävention durch Lieferantenbewertung
Quelle: Eigene Darstellung

Autor	Forschungsbedarf	Forschungsvorhaben im Rahmen der vorliegenden Dissertation
MODER [MOD08]	„Es ist […] ein starker Nachholbedarf erkennbar, um Supply Frühwarnsysteme in einen ganzheitlichen Supply Risk Management-Ansatz zu integrieren und die Prozesse zu gestalten.“	Es wird ein Prozess der Lieferantenbewertung erarbeitet, damit präventive Maßnahmen zur Absicherung oder Wiederherstellung der Lieferantenleistung initiiert werden können.

Mit Hilfe des Data Mining wird in der vorliegenden Arbeit ein Prozess zur Lieferantenbewertung auf Grundlage des Wissensmanagements im Total Supplier Management erarbeitet, damit die Risiken im externen Wertschöpfungsnetzwerk frühzeitig erkennbar sind. Somit wird der Forderung nach einen ganzheitlichen Supply Risk Management-Ansatz Rechnung getragen. Zusammenfassend besteht ein Forschungsbedarf im Bereich der frühzeitigen Lieferantenbewertung auf Grundlage des Wissensmanagements, um präventive Maßnahmen zur Absicherung bzw. Wiederherstellung der Leistungserbringung zwischen Lieferant und Abnehmer einleiten zu können.

1.2 Aufgabenstellung

Ziel der vorliegenden Dissertation ist die Erarbeitung eines effizienten Konzeptes zur Wissensgenerierung mit Hilfe des Data Mining, welches in den Workflow des Total Supplier Managements eingegliedert wird. Dafür wird die primäre Forschungsfrage wie folgt formuliert:

Wie muss eine Lieferantenbewertung auf Grundlage des Wissensmanagements mit Hilfe der Analyse von Datenmustern gestaltet werden, damit die Risiken im externen Wertschöpfungsnetzwerk im Rahmen eines effizienten Entscheidungsprozesses frühzeitig erkannt werden, um auf dieser Basis präventive Maßnahmen zur Absicherung oder Wiederherstellung der Leistungsfähigkeit von Lieferanten einleiten zu können?

Durch diese Fragestellung wird der explorative Charakter sowie das Forschungsspektrum der Wissensgenerierung im Zusammenhang mit dem Lieferantenmanagement hervorgehoben. Der Umfang der vorliegenden Dissertation stützt sich auf weitere sekundäre Forschungsfragen. Diese sind auch als Leitfaden für die Erstellung der Arbeit zu sehen.

- Welche Risiken existieren im Lieferantenmanagement und wie sieht die derzeitige Risikobetrachtung im Lieferantenmanagement aus?
- Welche Schwächen weist das derzeitige Lieferantenmanagement hinsichtlich der Wissensgenerierung mit Hilfe der Lieferantenbewertung auf?
- Wie muss ein ganzheitliches Konzept zur Wissensgenerierung für eine präventive und effiziente Steuerung der externen Wertschöpfungsnetzwerke gestaltet werden?
- Wie kann die Analyse von Datenmustern zur präventiven Lieferantenbewertung beitragen?
- Wie sehen die Möglichkeiten und Grenzen im Rahmen der Anwendbarkeit des neu entwickelten Konzeptes aus?

Die Aufgabenstellung lässt sich aus den Forschungsfragen ableiten. Dabei steht die Entwicklung eines ganzheitlichen Modells zur Wissensgenerierung für die präventive Steuerung der externen Wertschöpfungsnetzwerke im Vordergrund.

1.3 Forschungsmethode und Vorgehensweise

Nachdem der Forschungsbedarf begründet und die zugrundeliegende Forschungsfrage formuliert worden ist, werden nun die Forschungsmethode sowie der Aufbau der Arbeit näher erläutert. Ziel ist es, beides im Überblick darzustellen.

In Bezug auf das Forschungsgebiet der vorliegenden Arbeit lassen sich Formal- und Realwissenschaften differenzieren [WEB14]. *Formalwissenschaften* beziehen sich auf ein System aus Regeln und Zeichen, mit deren Hilfe Aussagen getroffen werden können. Diese Aussagen sind, beispielsweise durch die Mathematik und die Logik, auf ihre logische Wahrheit überprüfbar. Die *Realwissenschaften* befassen sich mit beobachtbaren Erscheinungen. Sie beschreiben beispielsweise menschliche Handlungsalternativen.

In dieser Arbeit werden beide Wissenschaftsformen Anwendung finden. Zum einen werden die Formalwissenschaften für die Modellierung der mathematischen Verfahren und Methoden aus dem Bereich der Statistik benötigt. Zum anderen unterstützen die Realwissenschaften die Ausgestaltung der Prozesse im Bereich des Lieferantenmanagements.

Die Generierung von Wissen über das externe Wertschöpfungsnetzwerk als Grundlage der Managemententscheidungen ermöglicht die *angewandte Forschung*. Dabei stehen die Bedürfnisse der Praxis vor denen der Wissenschaftlichkeit und Präzision [KRO09].

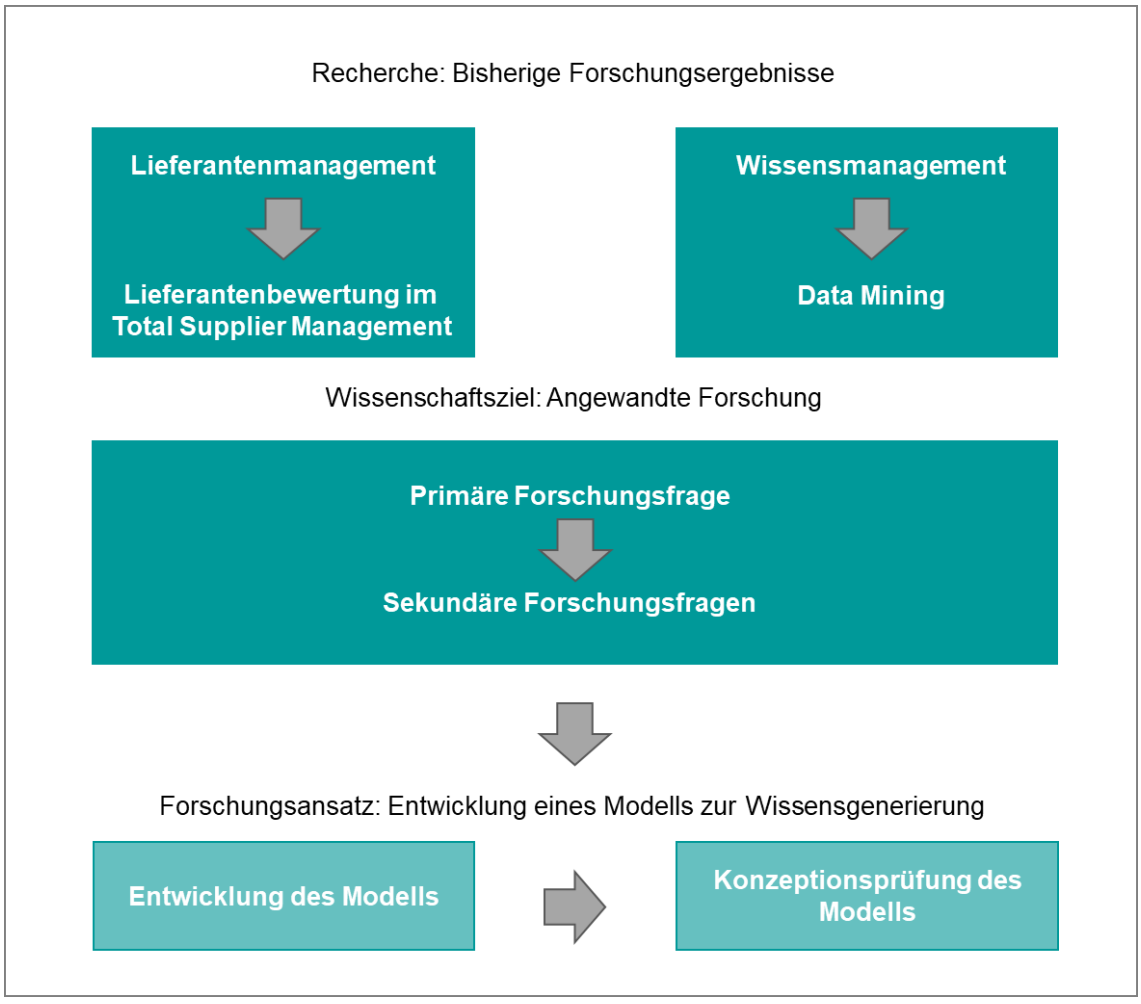


Bild 1-2: Forschungsmodell der vorliegenden Arbeit
Quelle: Eigene Darstellung

Das Forschungsmodell findet sich im Aufbau der Arbeit wieder. Bild 1-3 verdeutlicht durch den Aufbau der Arbeit die Vorgehensweise und den Inhalt der einzelnen Kapitel.



Bild 1-3: Aufbau der vorliegenden Arbeit
Quelle: Eigene Darstellung

Kapitel 1 bietet einen Überblick über die Problemstellung und wissenschaftlichen Defizite im Bereich des Lieferantenmanagements zur Begründung des Forschungsvorhabens. Das Forschungsvorhaben und der Aufbau der vorliegenden Arbeit werden skizziert.

Ausgangspunkt in *Kapitel 2* ist die Einordnung des Lieferantenmanagements in den Beschaffungsprozess und damit in das Supply Chain Management. Zur Steuerung des externen Wertschöpfungsnetzwerkes werden Verfahren der Lieferantenbewertung zur Wissensgenerierung angewendet. Um methodische Defizite im Bereich der Wissensgenerierung über das externe Wertschöpfungsnetzwerk kritisch zu würdigen, wird eine Abgrenzung der Lieferantenbewertungsverfahren mit dem Ziel der Wissensgenerierung vorgenommen. Unterstützt wird dies durch eine umfangreiche Literaturanalyse.

Kapitel 3 beschreibt den Workflow des Total Supplier Managements. Dieses Kooperations-, Koordinations- und Kommunikationsmodell bildet die Grundlage zur Einordnung der Wissensgenerierung in ein ganzheitliches Modell zur Steuerung der Lieferantenbasis.

Kapitel 2 und 3 bilden den theoretischen Rahmen zur Ausgestaltung der Wissensgenerierung im Bereich des Lieferantenmanagements. Dabei werden bisher bekannte Verfahren zur Lieferantenbewertung kritisch gewürdigt. Durch das herausgearbeitete Defizit zwischen dem IST-Zustand und den definierten Anforderungen wird der Forschungsbedarf weiter konkretisiert.

Das in dieser Arbeit zu entwickelnde Konzept wird in *Kapitel 4* erörtert. Dazu wird zunächst die Wissensgenerierung in das Konstrukt des Wissensmanagements eingeordnet. Aus Kapitel 2 und 3 ergeben sich Verfahren zur Wissensgenerierung über das externe Wertschöpfungsnetzwerk. Dieses wird in den definierten Workflow des Total Supplier Managements (Kapitel 3)

integriert. Diese Verfahren zur Wissensgenerierung werden in den Kontext des Wissensmanagements, des Total Supplier Managements und des Data Mining integriert

Da für die Methode des Data Mining viele Daten notwendig sind, wird der Umgang mit der Datenqualität in *Kapitel 5* näher betrachtet. Eine hinreichende Datenmenge in einer hohen Datenqualität stellt die Grundlage für das Data Mining sowie den Workflow dar. Dabei wird das Grundkonzept der Datenprüfung im Rahmen von Data Checkern erarbeitet.

Das erarbeitete Konzept wird in *Kapitel 6* auf die Machbarkeit sowie die Aussagekraft der Analyseergebnisse hin überprüft. Die Vorteile, welche durch die Kombination verschiedener Verfahren im Bereich des Data Mining erzielt werden, sind dargestellt. Zur Unterstützung der Konzeptionsprüfung ist im Rahmen der vorliegenden Arbeit der *Analyzer* entwickelt worden. Das Ziel ist dabei, große Datenmengen bei der Analyse von Datenmustern zu verarbeiten. Dieses IT-Tool stellt, neben dem erarbeiteten Modell, einen wesentlichen Teil der vorliegenden Dissertation dar. Dieser *Analyzer* wird in Kapitel 6 anhand eines Beispiels eingesetzt.

In Kapitel 4 bis 6 wird das Gesamtkonzept der Wissensgenerierung beschrieben und die Machbarkeit des Konzeptes auf Basis des *Analyzers* überprüft. Mit der Konzeptionsprüfung finden anhand eines konkreten Beispiels auch eine kritische Würdigung des Modells und sowie eine Darstellung der Möglichkeiten und Grenzen des *Analyzers* statt.

Die wesentlichen Erkenntnisse der Arbeit werden in *Kapitel 7* zusammengefasst und kritisch gewürdigt. Der Prozess zur Wissensgenerierung sowie die entsprechenden Verfahren werden über statistische Modelle in den vorhergehenden Kapiteln näher betrachtet, sodass nun die Alleinstellungsmerkmale der vorliegenden Arbeit erörtert werden. Abschließend wird ein Ausblick für die weiteren Forschungsmöglichkeiten gegeben.

1.4 Begriffsdefinition

Im Folgenden werden Begriffe näher erläutert, die für die vorliegende Arbeit wesentlich sind. Als Wesentlich wird dabei angenommen, wenn der Begriff etwas „über das Wesen der Sache“ [BIR11] im Zusammenhang mit der Aufgabenstellung aussagt. Die alphabetische Reihenfolge der Begriffe sagt nichts über die Wertigkeit aus.

Abgrenzung der Begriffe Verfahren, Methode und Modell

In der vorliegenden Arbeit soll ein ganzheitliches Modell zur Wissensgenerierung für die Steuerung der externen Wertschöpfungsnetzwerke als Grundlage der Lieferantenbewertung entwickelt werden. Ein Modell ist dabei allgemein eine „konkrete, fassliche und leicht realisierbare Darstellung unübersichtlicher Gegenstände und Phänomene“ [HEI14]. In der vorliegenden Arbeit bedeutet dies ein Abbild der Wirklichkeit, d. h. des Zusammenspiels der verschiedenen Prozesse, zu veranschaulichen. Dabei werden Methoden und Verfahren untersucht.

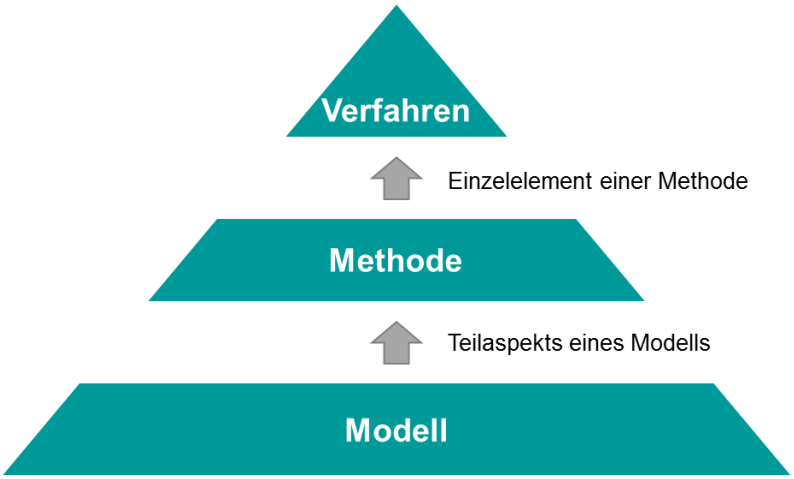


Bild 1-4: Abgrenzung der Begriffe Verfahren, Methode und Modell
Quelle: Eigene Darstellung in Anlehnung an [GEI01]

Eine Methode ist ein Teilaspekt eines Modells. Sie zeichnet sich durch ein planmäßiges Vorgehen (Verfahren) aus [GEI01], das zur Lösung theoretischer und praktischer Probleme führt [HEI14]. Der Begriff der Verfahren ist teilweise ein Synonym für den Begriff Technik [GEI01]. Ein Verfahren beschreibt eine „festgelegte Art und Weise, eine Tätigkeit oder einen Prozess auszuführen“ [DIN EN ISO9000].

Attribut

Merkmale eines Datensatzes werden im Data Mining als Attribut oder Item bezeichnet [NAK98, EST00, PIA10]. Merkmale repräsentieren Datensätze zu leistungsbeschreibenden und nicht leistungsbeschreibenden Datensätzen in Bezug auf Lieferanten. Im Zusammenhang mit einem vorliegenden Datensatz werden die zu untersuchenden Lieferanten als Objekte bezeichnet.

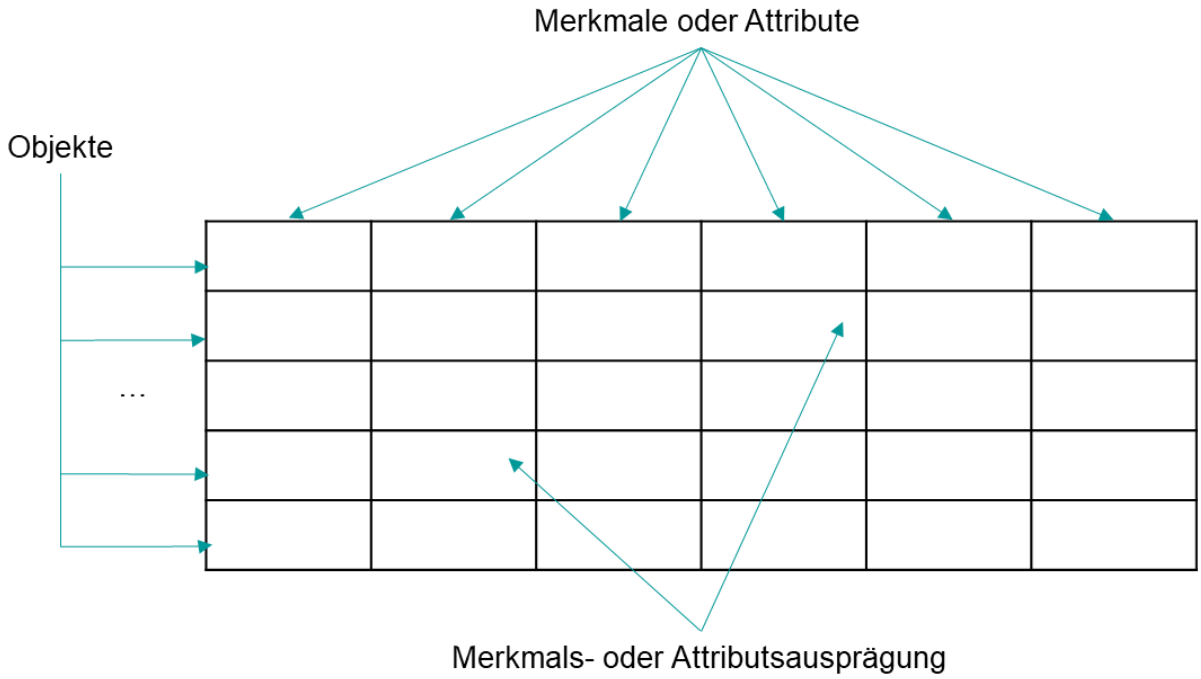


Bild 1-5: Datenbasis im Data Mining
Quelle: Eigene Darstellung in Anlehnung an [PIA10]

Zunächst wird in der vorliegenden Arbeit der Begriff des Merkmals und der Merkmalsausprägung für einen allgemeinen Datensatz verwendet. Wird dieser Datensatz einem Clustering unterzogen, verändern sich die Merkmale und werden nun als Attribute bezeichnet. Die Begriffe Attribut, Attributausprägung und Objekt werden in der vorliegenden Arbeit in Bezug auf einen vorliegenden Datensatz beim Data Mining zur Generierung quantitativer Assoziationsregeln verwendet.

Beschaffung

Der Begriff der Beschaffung wird in der Literatur vielfach verwendet. Für HAMMANN sind im Aufgabenbereich der Beschaffung die klassischen abwicklungsorientierten Prozesse zur „Ermittlung des Beschaffungsbedarfs, Spezifikation des Beschaffungsbedarfs, Suche nach potenziellen Lieferanten, Einholen von Angeboten, Bearbeitung der Angebote und Auswahl der Lieferanten, Objektrealisation und Überprüfung der Vertragserfüllung“ [HAM86] enthalten. KLEINAU [KLE95] spricht von inter- und intraorganisationalen Beziehungsmustern, welche das Transaktionsumfeld prägen. Des Weiteren sind verschiedene Betrachtungsweisen des Beschaffungsbegriffes bei BORGASCHEWSKY [BOG05], JANKER [JAN08] und IRLINGER [IRL12] publiziert.

Trotz der differierenden Begriffsdefinition schließt sich diese Arbeit der Definition von ARNOLD ET AL. [ARN08b] an. Die Autoren definieren den Begriff als „unternehmens- und/oder marktbezogene Tätigkeiten, die darauf gerichtet sind, einem Unternehmen die benötigten, aber nicht selbst hergestellten Objekte verfügbar zu machen“ [ARN08b].

Big Data

Große Datenmengen werden oft unter dem Begriff Big Data zusammengefasst [ELM17]. Für den Begriff Big Data gibt es keine einheitliche Definition [NAT17]. Bisweilen wird eine zu große Datenmenge für den Arbeitsspeicher als Big Data bezeichnet [MAY13]. LANEY [LAN01] definiert Big Data über die Ausprägung der drei Vs: Volume, Velocity und Variety. Einige Autoren bezeichnen diese Definition als unvollständig [WAR13]. NIST [NAT17] fügt zusätzlich Varibility hinzu. Dieses beschreibt die Veränderlichkeit innerhalb der Geschwindigkeit oder Struktur der Datenmenge. In einem Whitepaper postuliert ORACLE [ORA13] zu den drei Vs die Ausprägung der Aussagekraft der Daten. STEINBRECHER UND SCHUHMANN [STE15] fügen die Unbestimmtheit der Daten zu den drei Vs von LANEY [LAN01] hinzu. Weitere Sammlungen von Big Data Definitionen sind in DE MAURO ET AL. [MAU14] und in REINHARD [REI17] zu finden.

Auch wenn es keine einheitliche Definition des Begriffes gibt, ist das Ziel wichtig, welches mit den großen Datenmengen erreicht werden soll. Die vorliegende Arbeit folgt somit dem Gedanken von RIEDER UND SIMON [RIE17]: große Datenmengen erzeugen neue Arten von Kenntnissen. Wie dies innerhalb des zu erarbeitenden Modells mit Hilfe des Data Mining geschieht, wird in Kapitel 4 und 5 näher erläutert.

Daten

Daten können in unterschiedlichster Form auftreten. Allgemein werden Daten als eine „Zuordnung von Zeichen(folgen) zu Objekten und Sachverhalten der Wirklichkeit, die maschinell verarbeitbar sind und die zu Informationen werden können“ [HEI14] bezeichnet. In der vorliegenden Arbeit gibt es unterschiedlich große Mengen von Daten, die verarbeitet werden, was eine Begriffsdifferenzierung notwendig macht.

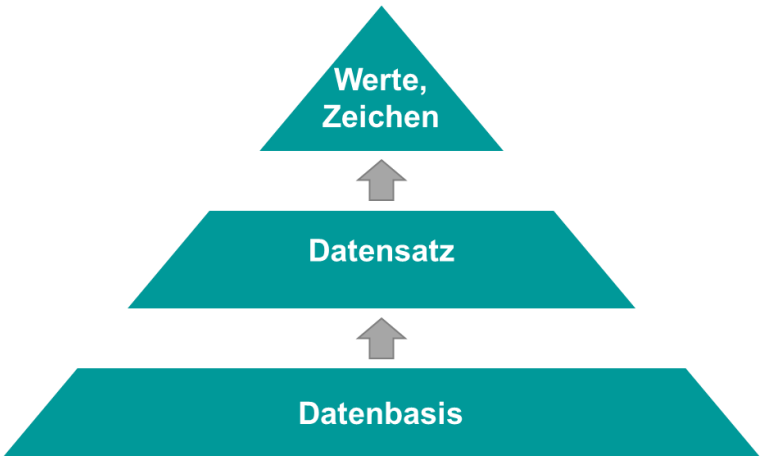


Bild 1-6: Abgrenzung der Begriffe Datenbasis, Datensatz sowie Werte und Zeichen
Quelle: Eigene Darstellung

Große Datenmengen setzen sich aus verschiedenen Datenquellen zusammen. Die Möglichkeiten, diese Datenmengen zu analysieren, sind vielseitig [FAS16]. Für die vorliegende Arbeit werden die Datenmengen, die zur Analyse bereitstehen, als Datenbasis bezeichnet. Die daraus extrahierten Datensätze bestehen aus relevanten Daten (Merkmalsausprägungen) bestimmter Merkmale (Kapitel 4.5.2) in Bezug auf ein Objekt, die letztlich für die durchzuführende Analyse genutzt werden. Diese relevanten Daten bestehen aus Werten oder Zeichen. Werte können einzelne Daten einer Kennzahl sein, wohingegen Zeichen einzelne syntaktische Elemente eines Datensatzes sind. Dies sind z. B. Wörter, wie die Adresse.

Supplier Risk Monitoring

Digitalisierung

Die Digitalisierung von Geschäftsprozessen wird auch als vierte Revolution bezeichnet und symbolisiert die Vernetzung der Wertschöpfungsnetzwerke durch Informations- und Kommunikationstechnologien (IKT) [HER17]. Die Digitalisierung trägt mit ihrem Mehrwert zur Wettbewerbsfähigkeit von Unternehmen bei. Prozess- und Geschäftsdaten können in Echtzeit erfasst und analysiert werden [CRE17]. Zusätzlich können auch neue Geschäftsmodelle auf Basis „einer höheren Durchdringung der Geschäftsprozesse mit Informationstechnologie, die […] optimal zugeschnittene Informationen und Services ermöglicht“ [FOT16] realisiert werden. Doch die „derzeit diskutierten Methoden und Lösungen basieren nahezu ausschließlich auf alten Geschäftsmodellen“ [SYS16]. Es muss ein Perspektivwechsel stattfinden, um die Unternehmen im Bereich der „Vernetzung des Digitalen“ [SYS16] zu unterstützen. Die Digitalisierung der Geschäftsprozesse in der Supply Chain ist in diesem Zusammenhang nicht als ein großes Projekt zu verstehen. Es ist „eine Vielzahl von Projekten“ [MAK16].

Relevanz und Relevanzprüfung

Die Relevanz eines Sinngebildes oder Faktes zu einem bestimmten Zeitpunkt ist im Wesentlichen durch die Vergangenheit des Faktes motiviert [STR15]. Das heißt, dass ein bestimmter Fakt in einem bestimmten Zusammenhang eine Bedeutung bzw. Aussagekraft hat. Das kann beispielsweise die Aussagekraft von quantitativen Assoziationsregeln oder auch nach der Generierung von Wissen die Bedeutung des Wissens für das weitere Vorgehen sein.

In der vorliegenden Arbeit besteht die Motivation der Relevanz in der hypothesenfreien Analyse von quantitativen Assoziationsregeln, um potenziell kritische Lieferanten zu identifizieren (Kapitel 4.3). Diese potenziell kritischen Lieferanten werden als relevantes Wissen über eine Relevanzprüfung gefiltert (Kapitel 4.3.4 und Kapitel 6). Für die Relevanzprüfung werden Daten aus der Vergangenheit genutzt. Von den identifizierten potenziell kritischen Lieferanten wird, je nach Priorität, nach der Relevanzprüfung eine Teilmenge der Lieferanten von einem Entscheidungsgremium als kritische Lieferanten eingestuft. Bei diesen Lieferanten ist es dann notwendig Maßnahmen zur Wiederherstellung der Leistungsfähigkeit zu initiieren.

Da die Literatur bislang nur Verfahren auf Grundlage von Hypothesen wiedergibt, wird in diesem Zusammenhang lediglich von kritischen Lieferanten gesprochen (Kapitel 2.3.4). Die Annahme, was einen Lieferanten als kritisch definiert, wird vor dem Start des jeweiligen Analyseverfahrens getroffen. Die in der vorliegenden Arbeit behandelte Assoziationsanalyse bietet erstmals die Möglichkeit die Lieferanten hypothesenfrei auf potenzielle Risiken (potenziell kritische Lieferanten) zu prüfen (Kapitel 4.3.3 und Kapitel 6).

Supply Chain und Value Chain

In der Literatur existiert keine einheitliche Definition des Begriffs Supply Chain [KOL13]. Die vorliegende Arbeit folgt jedoch der Definition von SODHI UND TANG. Die Autoren bezeichnen die Supply Chain als Kette von Organisationen, also Zulieferern, Logistikunternehmen, Händlern und Distributoren, die Produkte oder Dienstleistungen für den Endverbraucher bereitstellen [SOD12]. In der vorliegenden Arbeit wird zusätzlich von Wertschöpfungsketten bzw. -netzwerken und damit von einer Value Chain ausgegangen. Eine Value Chain betrachtet vor allem die in der Supply Chain enthaltene Wertschöpfung und damit eine Wertschöpfungskette [POR14].

Supplier Risk Monitoring

Supply Chain Management

KUHN UND HELLINGRATH sowie KURBEL definieren das Supply Chain Managements (SCM) als „integrierte prozessorientierte Gestaltung, Planung und Steuerung der Güter-, Informations- und Geldflüsse entlang der gesamten Wertschöpfungskette vom Kunden bis zum Rohstofflieferanten“ [KUH02, KUR16]. Diese Definition ist ähnlich ebenso in der Publikation von ARNOLD ET.AL. [ARN08b] enthalten. Auch wenn die verschiedenen Definitionen zum Supply Chain Management in der Literatur variieren [WER17], wird im Rahmen des SCM das gesamte Wertschöpfungsnetzwerk unter dem Gesichtspunkt der ganzheitlichen Prozessoptimierung betrachtet. Dabei gibt es verschiedene Möglichkeiten, die Beziehung zwischen Lieferant und Abnehmer zu gestalten [APP11].

Vernetzung

Eine Vernetzung, wie sie im Kontext der vorliegenden Arbeit verfolgt wird, kann mit dem Gedanken der Verknüpfung von Wissenselementen im Gehirn assoziiert werden. Dabei wird inhärent auch „das Wissen über die Beziehung zwischen Wissen“ [BOD03] als Vernetzung definiert. Als aktueller Megatrend wird in diesem Zusammenhang die Konnektivität, im Sinne einer „Vernetzung der Welt“ [ZUK16] durch die Verknüpfung von Daten und Informationen zu Wissen, bezeichnet. Beispiele von vernetztem Wissen im Rahmen von Netzwerken sind in BODENDORF [BOD03] enthalten.

Wissen

Wissen entsteht durch Vernetzung von Informationen [BOD03, PRO12]. Es ist die „Gesamtheit der Erkenntnisse und Fähigkeiten zur Lösung von Problemen“ [HEI14]. Die exakte Definition des Begriffs differiert jedoch in der Literatur [NIK17]. Wie und in welcher Form das Wissen und das Wissensmanagement mit der Steuerung der externen Wertschöpfungsnetzwerke zusammenhängen, wird im Kapitel 4 näher erläutert.

2 Stand der Wissenschaft im Lieferantenmanagement

Durch die immer schnellere industrielle Entwicklung stehen viele Unternehmen vor einer neuen und sich ständig verändernden Herausforderung: die Optimierung ihrer Wertschöpfung über die Unternehmensgrenzen hinaus [ARN08b]. Ziel ist es, eine möglichst hohe Effizienz zu erreichen. Der klassische Einkauf, mit rein operativen und dispositiven Tätigkeiten, kann dieser Aufgabe immer weniger gerecht werden [GAB08]. In der Fachliteratur wird in diesem Zusammenhang häufig eine Abgrenzung zwischen *Einkauf* und *Beschaffung* vorgenommen [HAH02, HEß08]. Vereinfacht werden dem Einkauf vorrangig reine Abwicklungs- bzw. Verwaltungsaufgaben zugesprochen [GAB08], während der Prozess der Beschaffung unternehmens- bzw. marktbezogene Tätigkeiten umfasst, um an das gewünschte Gut zu gelangen [HAH02, HEß08]. Das Lieferantenmanagement unterstützt hier den Prozess der Beschaffung an der Schnittstelle zum Lieferanten [IRL12].

Im Folgenden Kapitel wird der aktuelle Stand der Wissenschaft im Bereich Lieferantenmanagement beschrieben. Dafür wird zunächst die Eingliederung des Lieferantenmanagements in den Beschaffungsprozess dargestellt. Danach folgt die Betrachtung des Lieferantenmanagement-Prozesses mit dem Schwerpunkt der Lieferantenbewertung. Die Lieferantenbewertungsverfahren werden in den Kontext der Wissensgenerierung eingeordnet. Zum Schluss des Kapitels wird der aktuelle Stand der Wissenschaft in Bezug auf die Lieferantenbewertungsverfahren zur Konkretisierung des Forschungsbedarfs kritisch gewürdigt.

2.1 Das Lieferantenmanagement im Beschaffungsprozess

Die hohe Produktkomplexität setzt ein umfangreiches Know-how in vielen Bereichen voraus, das die meisten Unternehmen nicht vollständig bereitstellen können [[ARN08b] mit Verweis auf [STÖ03]]. Deshalb wird das Ziel verfolgt, sich ausschließlich auf die Kernkompetenzen zu konzentrieren. Zahlreiche Produktionsschritte werden in das Wertschöpfungsnetzwerk ausgelagert, sodass Kosten- und Qualitätsvorteile erreicht werden [HOF09, ARN10, IRL12, LIP13]. Die in den einzelnen Produktionsschritten entstehenden Produkte werden somit von Lieferanten beschafft.

In den 1970er und 1980er Jahren ist der Marketinggedanke in den Bereich des Einkaufs übertragen worden. Somit wird stärker zwischen abwicklungsorientierten und beschaffungspolitischen Aufgaben differenziert [LAR09]. Um dieser Komplexität gerecht zu werden, sind dem Einkauf weitere Kompetenzen im Sinne des Beschaffungsmanagements bzw. des Supply Chain Managements zugesprochen worden. Diese Aspekte werden nun näher betrachtet.

Ähnlich wie für ARNOLD ET AL. [ARN08b] erfüllt für LARGE die Beschaffung allgemein „die Funktion der Versorgung in der Unternehmung, indem sie andere Organisationseinheiten mit jenen Gütern versorgt, die diese zur Erfüllung ihrer Funktion benötigen“ [LAR09]. Somit müssen die anstehenden Beschaffungsmaßnahmen geplant und nach standardisierten Abläufen vorgenommen werden. Eine Beschaffung stellt sich demnach als Prozess dar. Im Fall eines Beschaffungsprozesses liegt der Zweckzusammenhang der Versorgung zugrunde [LAR09].

Kommen zur Beschaffung zusätzliche Aufgaben, wie das Materialgruppenmanagement und das Einkaufscontrolling hinzu, wird es als Beschaffungsmanagement deklariert [BME16]. Zu den allgemeinen Aufgaben des Beschaffungsmanagements zählt die Bereitstellung von Gütern und Dienstleistungen [LAR09] unter bestimmten Wert-, Human- und Umweltzielen

[PAL02]. Die Beschaffung und das Beschaffungsmanagement haben sich als Querschnittsaufgaben [PFE02] zu Prozessen mit hohem Einfluss auf die Wettbewerbsfähigkeit des Unternehmens entwickelt [HEß08].

Unter dem Begriff des Supply Chain Managements (SCM) wird die Betrachtung des Beschaffungsmanagements erweitert. Dabei bildet das SCM nach FROSCHMAYR UND GÖPFERT „eine qualitativ hohe Entwicklungsstufe im Lebenszyklus des Logistikmanagements“ [FRO10]. SIMCHI-LEVI ET AL. [SIM00] stellen in dem Zusammenhang einen direkten Bezug zur Logistik mit dem Verweis auf die 6 R der Logistik [JÜN89, MEL89] her. Da die Literatur im Definitionsverständnis des SCM differiert, bietet GÖPFERT [GÖP13] eine umfangreiche Auseinandersetzung zu diesem Thema. Dabei unterliegt der Gedanke des SCM einer Wandlung vom Management einer Wertschöpfungskette hin zum Management eines Wertschöpfungsnetzwerks [EßI13]. Mit dem Verständnis eines (Wertschöpfungs-)Netzwerkes heben SYDOW UND MÖLLERING [SYD15] unter anderem besonders das Risiko des Kompetenzverlustes sowie der Abhängigkeit hervor. Einseitige Abhängigkeiten stellen dabei „eine latente Existenzbedrohung für eine Produktion im Netzwerk dar“ [SYD15].

Mit Hilfe von strategischen und strukturierten Herangehensweisen unterstützt das SCM die Bewältigung der zukünftigen Herausforderungen [SYD99, HOF09] in der Gestaltung der Wertschöpfung. Dabei sind das Lieferanten-(Risiko-)management sowie der enthaltene Teilprozess der Lieferantenbewertung kennzeichnend für die Neuausrichtung des klassischen Einkaufs innerhalb einer strategischen Semantik [LEE89, LAR09, HAR10b, POL10, APP11]. In diesem Sinne verändert sich der Prozess des Einkaufs durch das Beschaffungsmanagement zum SCM mit dem Bereich des Lieferantenmanagements „vom Erfüllungsgehilfen zum Wertgestalter“ [HOF09] innerhalb von Netzwerken (siehe Bild 2-1).

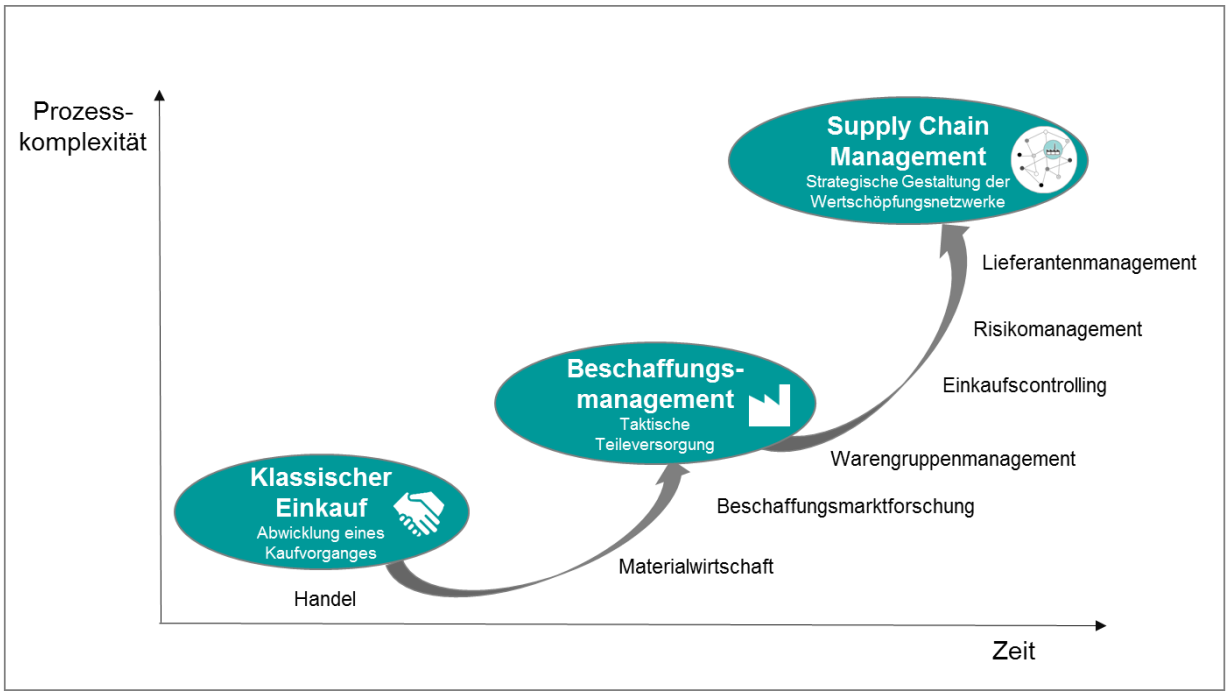


Bild 2-1: Anstieg des Anspruchs vom klassischen Einkauf zum Supply Chain Management
Quelle: Eigene Darstellung

Stellvertretend für die neue, komplexe Ausrichtung des klassischen Einkaufs hin zum SCM sind in Bild 2-1 einige klassische Unterstützungsprozesse dargestellt. Eine kurze Erläuterung der Unterstützungsprozesse ist im Glossar zu finden.

Als Prozesskomplexität stellt sich dabei „die Schwierigkeit der zu erbringenden Prozesse und [des] Servicegrad[s]“ [LIE16] dar. Die drei Komplexitätsformen aus Bild 2-1 können verschiedenen Vertretern aus der Literatur zugeordnet werden. Dazu gibt Tabelle 2-1 einen Überblick.

Tabelle 2-1: Typische Vertreter aus der Literatur in Bezug auf die Prozesskomplexität der Wertschöpfung
Quelle: Eigene Darstellung

Prozesskomplexität	Inhalt	Vertreter
Klassischer Einkauf	Operativ ausgerichtete Abwicklung eines Kaufvorganges	THEISSEN (1970) [THE70] WESTERMANN (1972) [WES72]
Beschaffungs-management	Taktische Aspekte der Beschaffung mit integrierter Materialwirtschaft	GROCHLA/SCHÖNBOHM (1980) [GRO80] MELZER-RIDINGER (1989) [MEL89] KOPPELMANN (1995) [KOP95] BOGASCHEWSKY (2005) [BOG05]
Supply Chain Management	Strategische Gestaltung und Steuerung der Wertschöpfungsnetzwerke mit einer intensiven Lieferanteneinbindung	STÖLZLE (1999) [STÖ99] SIMCHI-LEVI (2000) [SIM00] EßIG (2013) [EßI13]

Mit diesen Möglichkeiten zum Steuern, Leiten und Lenken der Wertschöpfungsnetzwerke gewinnt das SCM im Unternehmen an Bedeutung [LOC07, GÖP13]. Das Lieferantenmanagement, als Teil des SCM, findet dabei besondere Beachtung [WAG01]. Um die damit verbundenen Lieferanten-Abnehmer-Beziehungen im weiteren Verlauf dieser Arbeit näher zu betrachten, wird im Folgenden der Fokus auf den Bereich des Lieferantenmanagements, als Teil des SCM [JAN08], gelegt.

2.2 Das Lieferantenmanagement

Der Erfolg eines Unternehmens steht in direktem Zusammenhang mit der Leistungsfähigkeit der Lieferanten [LAR09, DÖL11]. Durch die enge Zusammenarbeit im Wertschöpfungsprozess entwickeln sich dabei Lieferanten zu strategischen Geschäftspartnern innerhalb der Wertschöpfungsnetzwerke [SCH14c]. Dieses Kapitel verdeutlicht die Zielsetzung sowie die Vorgehensweise und Ausprägungen zur Steuerung der Lieferanten-Abnehmer-Beziehungen im externen Wertschöpfungsnetzwerk nach dem aktuellen Stand von Wissenschaft und Forschung.

2.2.1 Definition des Lieferantenmanagements

Der Begriff des Lieferantenmanagements findet im Zuge der Umstrukturierung und Globalisierung der Beschaffung zunehmend Aufmerksamkeit. Der Einkauf spezialisiert sich im Rahmen des Lieferantenmanagements auf eine intensive Beschaffungsmarktforschung und steht der Einkaufsorganisation bei der Identifikation und Bewertung von Lieferanten zur Seite [ARN10]. Folglich wird das Lieferantenmanagement als Unterstützungsprozess verstanden.

Obwohl die Literatur bezüglich einer festen Definition des Lieferantenmanagements im Wortlaut differiert, gleichen sich die Kernaussagen der Autoren (Tabelle 2-2). Im Vordergrund des Lieferantenmanagements steht die Ausgestaltung der Beziehungen und Schnittstellen zwischen Lieferant und Abnehmer. Uneinigkeit besteht in der Literatur bezüglich der zugehörigen Prozesse. Tabelle 2-2 enthält einen Auszug über die in der Literatur zu findenden Aufgaben des Lieferantenmanagements. Einen weitreichenderen Überblick über die unterschiedlichen Aktivitäten des Lieferantenmanagements bietet JANKER [JAN08].

Tabelle 2-2: Literarischer Auszug der verschiedenen Aufgaben des Lieferantenmanagements
Quelle: Eigene Darstellung

Jahr	Autor	Definition
1994	GLANTSCHNIG	Unter dem Begriff Lieferantenmanagement sind die Phasen der Analyse, Bewertung, Auswahl und Kontrolle von Lieferanten zu vereinen [GLA94].
1994	HARTING	Die wesentlichen Elemente Auswahl, Bewertung, Kontrolle und Strategie subsumiert HARTING [HAR94] unter dem Lieferantenmanagement.
2002	WAGNER	WAGNER [WAG02] fasst unter dieser Thematik die Gestaltung, Lenkung und Entwicklung der Lieferantenbasis und -beziehungen zusammen. Er hebt dabei das Management der Lieferantenbasis, die Lieferantenentwicklung und -integration hervor.
2008	ARNOLD ET AL.	Das Lieferantenmanagement betrachtet „den gesamten Lebenszyklus der Kunde-Lieferant-Beziehungen […]. Dieses Element umfasst die aktive und systematische Analyse, Lenkung, Gestaltung und Entwicklung der Kunde-Lieferant-Beziehungen“ [ARN08b].

Es ist zu erkennen, dass die Definition des Lieferantenmanagements über die Zeit eine Entwicklung erfährt. Durch die steigende Komplexität der Wertschöpfungsnetzwerke und den damit verbundenen Lieferanten-Abnehmer-Beziehungen entwickeln sich auch die Managementaufgaben weiter [IRL12]. Trotz einiger Unterschiede in der Abgrenzung der Themengebiete wird in allen Werken dem Begriff des Lieferantenmanagements der in Bild 2-2 dargestellte Prozess zugeschrieben.

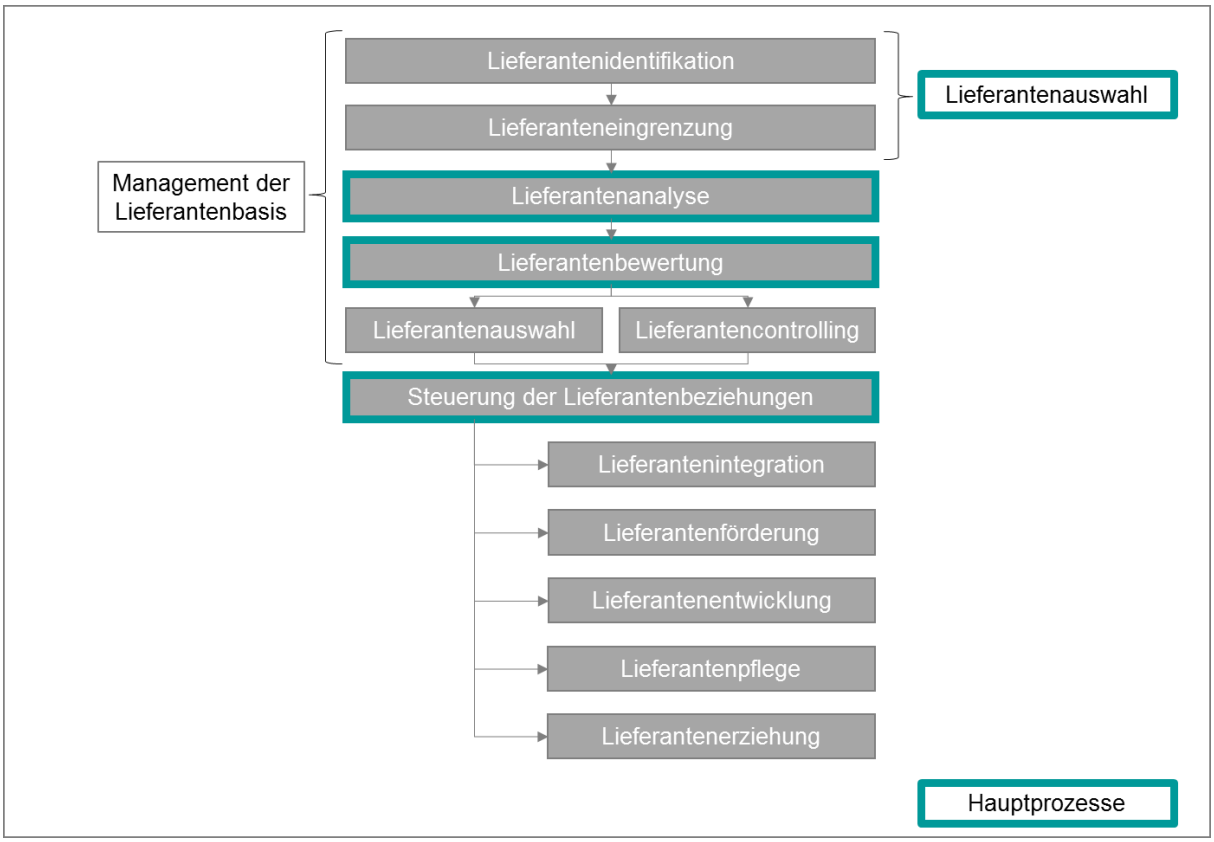


Bild 2-2: Prozess des Lieferantenmanagements
Quelle: Eigene Darstellung in Anlehnung an [ARN08b, JAN08, POL10]

Zusammenfassend beinhaltet der Ablauf des Lieferantenmanagements nach dem aktuellen Stand von Wissenschaft und Forschung folgende Prozesse [ARN08b, JAN08, POL10]:

- Lieferantenidentifikation: Identifizierung von Lieferanten, welche die benötigte Ware oder die benötigte Dienstleistung anbieten
- Lieferanteneingrenzung: Prüfung, ob die identifizierten Lieferanten als Geschäftspartner für das beschaffende Unternehmen in Frage kommen
- Lieferantenanalyse: Untersuchung der Leistungsfähigkeit der potenziellen Lieferanten mit Hilfe der Ergebnisse aus der Lieferantenauswahl
- Lieferantenbewertung: Beurteilung der Leistungsfähigkeit der potenziellen Lieferanten im Rahmen der Lieferantenauswahl oder einer bereits bestehenden Geschäftsbeziehung im Rahmen des Lieferantencontrollings

- Steuerung der Lieferantenbeziehungen: Stärkung der Zusammenarbeit mit den Lieferanten durch Einbeziehung in das beschaffende Unternehmen sowie Optimierung der Lieferantenbasis und der Lieferantenleistung durch die Lieferantenintegration, -förderung, -entwicklung, -pflege und -erziehung

Umfangreiche Erläuterungen zu den einzelnen Prozessschritten des Lieferantenmanagements sind unter anderem in den Abhandlungen von JANKER [JAN08], ARNOLD ET AL. [ARN08b] sowie POLITIS [POL10] enthalten. Bei dem in Bild 2-2 dargestellten Prozess entfällt die Lieferantenauswahl, wenn der Lieferant bereits bekannt oder vom Kunden im Lastenheft festgelegt worden ist [JAN08].

Die Lieferanten werden durch einen standardisierten Prozess gelenkt, gefördert und entwickelt [WAG08b]. Die Leistung einzelner Lieferanten soll dabei mit Hilfe einer transparenten und objektiven Darstellung vergangenheits-, gegenwarts- und zukunftsbezogener Informationen überwacht werden. Handlungsbedarf aufgrund schlechter Leistungsfähigkeit wird identifiziert, sodass Maßnahmen ergriffen werden können.

Das Lieferantenmanagement hat einen direkten Einfluss auf die Stärkung der Wettbewerbsposition des Unternehmens. Zusätzlicher Mehrwert ergibt sich aus einer Verbesserung der Innovationsposition durch die Nutzung des Know-hows des Lieferanten sowie einer Kostenoptimierung durch standardisierte Prozesse [HAR10b]. Bei der Umsetzung des Lieferantenmanagements gibt es verschiedene Ausprägungen. Diese werden im folgenden Kapitel betrachtet.

2.2.2 Ausprägungen des Lieferantenmanagements

Allgemein ergeben sich die Ziele des Lieferantenmanagements direkt aus den Zielen des Beschaffungsmanagements [ARN08b]. Im Bereich des Lieferantenmanagements wird in der Literatur eine Differenzierung zwischen dem normativen, strategischen und operativen Lieferantenmanagement vorgenommen [ARN08b, HOF09]. Diese Abgrenzung ist je nach Autor und Fokus der Arbeit unterschiedlich. Teilweise vermischen sich die Aufgaben und Ziele des Einkaufs, des Beschaffungsmanagements und der Produktion mit dem Lieferantenmanagement. WAGNER [WAG01] hat in seinen Ausführungen die verschiedenen Ausprägungen des Lieferantenmanagements in einem Konzept des integrierten Lieferantenmanagements visualisiert. Das Bild 2-3 gibt die wesentlichen Aktivitäten, Strukturen und das Verhalten in den jeweiligen Managementebenen wieder. Das normative Lieferantenmanagement definiert dabei die Ziele der Beschaffungs- und Lieferantenpolitik. Die strategische Ebene richtet die entsprechenden Strukturen und Aktivitäten auf die Ziele aus und die operative Ebene des Lieferantenmanagements setzt diese um.

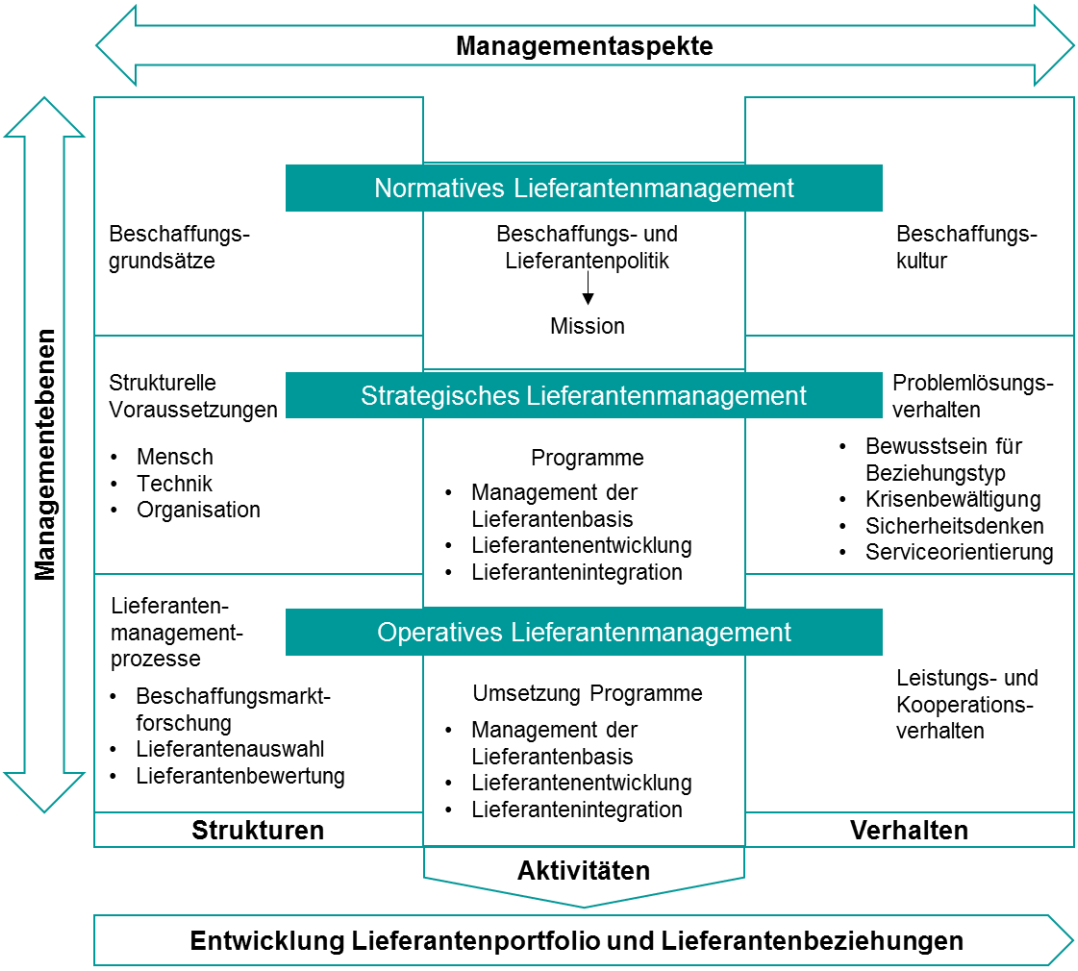


Bild 2-3: Konzept integriertes Lieferantenmanagement
Quelle: [WAG01]

Das *normative Lieferantenmanagement* wird durch generelle Ziele, Prinzipien sowie Normen und Strategien [DUR11] der Beschaffungs- und Lieferantenpolitik im Unternehmen beschrieben. Diese leiten sich aus Vorgaben des Beschaffungsmanagements ab, das wiederum eng mit der Unternehmensstrategie verbunden ist. Die Beschaffungsgrundsätze und die Beschaffungskultur übernehmen dabei den Rahmen zur Ausgestaltung des strategischen und operativen Lieferantenmanagements [WAG01]. Allgemein sichert das normative Management die Lebens- und Entwicklungsfähigkeit eines Unternehmens [BUL96].

Zu den Zielen des *strategischen Lieferantenmanagements* zählen unter anderem die mittel- bis langfristige Prozessoptimierung bei kritischen Lieferanten, um die Verfügbarkeit und Qualität der Ware sicherzustellen. Die Prozesse sollten dabei so gestaltet werden, dass die Leistungsfähigkeit der bestehenden Lieferanten steigt. HOFBAUER ET AL. [HOF09] werden in ihren Ausführungen konkreter. Für sie zählen unter anderem die Optimierung der Lieferantenbasis, die Risikominimierung, die Sicherung des Zugangs zu Innovationen sowie die Schaffung von Wettbewerb durch strukturiertes und strategisches Vorgehen bei der Kooperation und Integration zum Mehrwert. Für HEß ET AL. [HEß16] zählt die Lieferantenbewertung, neben der Klassifizierung der Lieferantenstrategie und der Lieferantenauswahl, zum strategischen Teil des Lieferantenmanagements. Das Optimierungspotenzial beschreiben die Autoren [HOF09, HEß16] unter anderem mit der systematischen Reduzierung von Lieferantenrisiken, einer vereinfach-

ten Zusammenarbeit oder auch einer transparenten Lieferantenleistung. Wie bereits beschrieben, sind die Ausführungen zur Abgrenzung zwischen dem strategischen und operativen Lieferantenmanagement je nach Autor nicht konsistent. In der Literatur finden sich nur selten konkrete Abgrenzungen.

Von einem *operativen Lieferantenmanagement* wird im Rahmen einer kurzfristigen Versorgungsabsicherung gesprochen. Die zugehörigen Aktivitäten sind in der Literatur je nach Autor different. So zählt WAGNER [WAG01], wie im Bild 2-3 beschrieben, die Umsetzung des Managements der Lieferantenbasis sowie die Lieferantenentwicklung und -integration zu den operativen Aufgaben. Nach ARNOLD ET AL. [ARN08b] umfassen die wichtigsten Steuerungsaktivitäten dabei die Elemente der Bestellabwicklung, die Überwachung der Liefertermine, das Mahnwesen, die Rechnungsprüfung bzw. die Lösung von Konfliktpotenzialen. Diese Aufgaben können, wie im Kapitel 2.1 beschrieben, auch dem klassischen Einkauf zugeordnet werden. HOFBAUER ET AL. [HOF09] weisen dem operativen Segment des Lieferantenmanagements zusätzlich zu den Aufgaben von WAGNER [WAG01] in Bild 2-3 die Aufgabe des Lieferantenscoutings zu. Das Lieferantenscouting kann dabei als Schnittmenge aus Lieferantenmanagement und Beschaffungsmarktforschung angesehen werden, „da der Suchprozess Bestandteil beider Beschaffungswerkzeuge ist“ [HOF09]. Es wird aktiv und systematisch nach neuen, unbekannten Lieferanten mit Leistungspotenzialen gesucht. Der Zulieferer soll dabei nicht nur einen wirtschaftlichen, technologischen oder ökologischen Mehrwert für den Abnehmer, sondern auch für den Endkunden haben. Um potenzielle Lieferanten aus dem Markt identifizieren zu können, werden Lieferantenprofile durch das systematische Erfassen und Auswerten von Daten erstellt. An dieser Stelle wird auf das Trichtermodell zur Lieferantenauswahl und -eingrenzung verwiesen [SCH89, JAN08]. Der Zusammenhang zwischen Beschaffungsmarktforschung, Lieferantenanalyse und Lieferantenscouting wird weitergehend in SCHUMACHER ET AL. [SCH08b] betrachtet. Für HOFBAUER ET AL. [HOF09] gehören weiterhin die Senkung der Änderungs- und Gewährleistungskosten sowie der Ausfallrate dazu. WAGNER [WAG01] zählt zu den operativen Prozessen des Lieferantenmanagements die Lieferantenauswahl sowie die Lieferantenbewertung. Die komplexen Prozesse erfordern dabei eine bereichsübergreifende und prozessorientierte Ausrichtung. Auch SIBBEL ET AL. [SIB05] schreiben den Prozess der Lieferantenbewertung den operativen Prozessen zu. Dabei heben sie besonders die Sicherstellung der Transparenz bei der Beurteilung der Lieferantenleistung hervor. Für DUST beschreibt das operative Lieferantenmanagement „alle Tätigkeiten eines Unternehmens zur Qualifizierung, Auswahl, Steuerung und Entwicklung von Lieferanten“ [DUS18]. Der Autor beschreibt in seiner Abhandlung die Differenzierung zwischen den Regelprozessen des operativen Lieferantenmanagements und dem Total Supplier Management (Kapitel 3). Dabei wird der Lebenszyklus eines Produktes (Materialgruppe, Normierung, Produktentstehung, Betrieb und After Sales) in den Vordergrund gestellt (Bild 2-4).

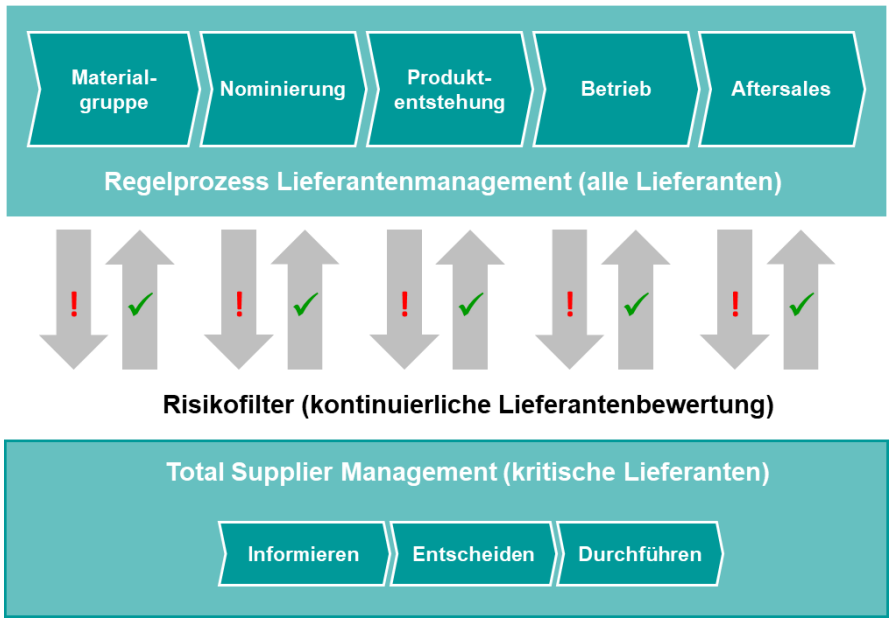


Bild 2-4: Regelprozesse und Risikofilter im Lieferantenmanagement
Quelle: Eigene Darstellung in Anlehnung an [DUS18].

Innerhalb des Lebenszyklus werden die Regelprozesse im operativen Lieferantenmanagement beschrieben. Sind entlang dieser Regelprozesse Leistungsdefizite beim Lieferanten zu erkennen, werden durch standardisierte Risikofilter zusätzliche Maßnahmen zur Wiederherstellung der Leistung bei den identifizierten Lieferanten durchgeführt [DUS18]. Auf Grundlage dieses ganzheitlichen Ansatzes „wird der operative Betrieb abgesichert“ [DUS18].

Zusammenfassend dient das normative, strategische und operative Lieferantenmanagement der Effizienz- und Effektivitätssteigerung zur Steuerung der externen Wertschöpfungsnetzwerke. Aufgrund der Komplexität der Netzwerke und der damit auftretenden Herausforderungen muss es um eine Betrachtung der Risiken erweitert werden.

2.3 Risikobetrachtung im Lieferantenmanagement

Moderne Lieferantenstrukturen werden zunehmend volatiler. So beschreiben WAGNER UND BODE [WAG08a] diese Veränderung als instabile Welt mit zunehmend sensibleren Wertschöpfungsnetzwerken. Eine Risikobetrachtung dieser Netzwerke dient als Ausgangspunkt für die Wahrnehmung der Notwendigkeit sowie die Quantifizierung und Einleitung von Verbesserungsmaßnahmen im Sinne eines kontinuierlichen Verbesserungsprozesses (Kapitel 3.4.4). Außerdem eignet sich die Betrachtung der Risiken für die Auswertung und Erfolgskontrolle der Zulieferer-Abnehmer-Beziehungen [PFE02]. Aufgrund der Lieferanteneinbindung in Produktentstehungsprozesse [HOF09] wird großer Wert auf die Entwicklungsleistung der Lieferanten gelegt. Die Abhängigkeit zwischen Lieferant und Abnehmer verstärkt sich somit zusätzlich [CHR04].

Laut DIN EN 31010:2010 bringen „alle Tätigkeiten einer Organisation […] Risiken mit sich, die beherrscht werden sollten“ [DINEN31010]. Ein „effect of uncertainty on objectives“ [ISO31000] wird dabei als Risiko bezeichnet. Weitere Diskussionen zum Risikobegriff sind in PERLITZ [PER04] enthalten. Forderungen einer Risikobetrachtung sind unter anderem in den Normen ISO 9001:2015 [DINENISO9001] und ISO 9004:2009 [DINENISO9004] sowie verschiedenen Richtlinien [VER11, VER16] verankert. Dies unterstreicht die zunehmende Beachtung, die einer Risikobetrachtung zukommt. Im Folgenden wird nun mit Hilfe der Literatur erörtert, warum und wie Risiken im Lieferantenmanagement mit Hilfe der Lieferantenbewertung betrachtet und beherrscht werden.

2.3.1 Ziele und Nutzen der Risikobetrachtung

Die Risikobetrachtung der Wertschöpfungsnetzwerke gewinnt aufgrund der beschriebenen Normen und Richtlinien verstärkt an Bedeutung [GLE16]. Eine Risikobetrachtung schließt dabei „alle Maßnahmen für eine frühe Identifikation, Bewertung und Steuerung von Risiken […], die eine Bedrohung der Unternehmensziele sein können“ [GAB10] ein. Weiterhin hat eine Studie des Fraunhofer IPA nachgewiesen, dass für 86 Prozent der befragten Industrieunternehmen die Risikobetrachtung der Wertschöpfungsnetzwerke eine wachsende Bedeutung hat [SCH10a]. Andere Studien belegen jedoch, dass die Umsetzung einer frühzeitigen Risikobetrachtung in der Praxis weiterhin Lücken aufweist [DRE00, JAN08, DUS16d].

Allgemein soll die Risikobetrachtung im Lieferantenmanagement zur Gewährleistung der Versorgungssicherheit und auch der Wettbewerbsfähigkeit beitragen [SIE15]. Diese Risikobetrachtung ist somit ein Teil des Lieferantenmanagements. Über diesen Prozess ist es Unternehmen bisher möglich, die externen Wertschöpfungsnetzwerke zu steuern und die entstehenden Risiken zu beherrschen. Im Folgenden werden die detaillierten Ziele in Anlehnung an JANKER [JAN08] und GLANTSCHNIG [GLA94] dargestellt (Tabelle 2-3). Die Gliederung der Tabelle erfolgt nach den Hauptprozessen beim Ablauf des Lieferantenmanagements (Bild 2-2) in Kapitel 2.2.1.

Tabelle 2-3: Ziele einer Risikobetrachtung im Lieferantenmanagement
Quelle: Eigene Darstellung

Prozess des Lieferanten-managements	Ziele einer Risikobetrachtung im Lieferantenmanage-ment
Lieferantenauswahl	• Objektivierung der Lieferantenauswahl • Optimierung der Lieferantenstruktur
Lieferantenanalyse	• Entwicklung geeigneter (Sourcing-)Strategien im Rahmen des Supply Chain Managements
Lieferantenbewertung	• Kompetenzaufbau zur Lieferantenentwicklung auf Basis von Erfahrungen • Förderung des beiderseitigen Problembewusstseins • Reduktion von Datensilos bei allen lieferantenbezogenen Beschaffungsprozessen • Aufbau eines bereichsübergreifenden Datenpools im Unternehmen, der eine objektive und transparente Aussage über die Leistungsfähigkeit der Lieferantenbasis enthält • Aufdecken von Schwachstellen beim Lieferanten
Steuerung der Lieferan-tenbeziehungen	• Steuerung und kontinuierliche Kontrolle der Lieferleistung des Lieferanten • Standardisierte Entwicklung von Maßnahmen zur Wiederherstellung der Lieferantenleistung • Regelmäßige Entwicklung und Pflege von strategischen Lieferanten • Steigerung und Halten der Lieferantenleistung • Absicherung der Wettbewerbsfähigkeit bei Lieferant und Abnehmer

Zusammenfassend lassen sich die Ziele einer Risikobetrachtung im Lieferantenmanagement aus der Literatur wie folgt darstellen [GLA94, HAR94, HOF09]:

- Objektivierung und Optimierung der Lieferantenauswahl
- Optimierung der Lieferantenbasis
- Kontinuierliche Verbesserung der Lieferantenqualität
- Transparenz und Kontrolle über die Lieferantenleistung durch Messung von Risiken
- Steuerung der externen Wertschöpfungsnetzwerke

Weitere Ziele sind durch JANKER [JAN08] in einer Studie mit 185 befragten Unternehmen ermittelt worden. Dabei zählen die Qualitätssicherung, zuverlässige Lieferanten und niedrige Preise zu den meist genannten Zielsetzungen.

Eine Risikobetrachtung im Lieferantenmanagement und damit innerhalb der Lieferanten-Abnehmer-Beziehung wird vor allem im Rahmen der Lieferantenbewertung vorgenommen [APP11]. Für diese Betrachtung kommen im Prozess der Lieferantenbewertung drei Zeitpunkte in Frage:

- im Rahmen der Warengruppenstrategie
- im Rahmen der Lieferantenauswahl
- im Rahmen der täglichen Zusammenarbeit

Einen Überblick über Inhalte der verschiedenen Zeitpunkte im Prozess der Lieferantenbewertung bietet Bild 2-5.



Bild 2-5: Zeitpunkte im Prozess der Lieferantenbewertung
Quelle: Eigene Darstellung in Anlehnung an [DUS18]

Die Literatur bietet bereits eine kritische Betrachtung der bisher publizierten und angewendeten Lieferantenbewertungsverfahren. Die Objektivierung bei den bisher angewendeten klassischen Lieferantenbewertungsverfahren zur Risikoüberwachung bewirken laut GLANTSCHNIG sowie HARTING [GLA94, HAR94] weder eine bessere Vergleichbarkeit der Leistungsfähigkeit der Lieferanten noch eine Reproduzierbarkeit der Bewertungsergebnisse, da für jeden Lieferanten die gleichen Bewertungskriterien betrachtet und einzelne Leistungen der Lieferanten miteinander verglichen werden. GABATH stellt dabei „[…] eine leistungsorientierte Lieferantenbewertung nach unternehmensweit einheitlichen und objektiven Kriterien“ [GAB08] in das Zentrum der wissenschaftlichen Abhandlung. Die fachbereichsübergreifende Lieferantenbewertung erfolgt in mehreren Dimensionen um „eine hinreichende Transparenz über die Leistungsfähigkeit der Lieferanten und somit die Grundlage für deren Förderung und Entwicklung zu schaffen“ [GAB08]. Über diesen Prozess ist es dem Unternehmen möglich, eine optimale Lieferantenbasis zu erhalten. Da die kontinuierliche Leistungserbringung der Lieferanten im

Fokus dieser Arbeit steht, entfällt im Weiteren die Betrachtung der Lieferantenbewertung im Sinne einer Lieferantenauswahl und der Warengruppenstrategie. Dabei muss eine Bewertung der kontinuierlichen Leistungserbringung verschiedene Anforderungen erfüllen.

2.3.2 Anforderungsprofil an eine Lieferantenbewertung

Das Ziel einer Lieferantenbewertung ist die Beurteilung der „Zuverlässigkeit der Produkte eines Lieferanten während eines definierten Zeitraums“ [HAR94]. Um aussagekräftige Resultate zu erhalten, ist es notwendig, ein Anforderungsprofil an das Bewertungssystem zu erstellen. Zu den *allgemeinen Anforderungen*, die keinen direkten Einfluss auf die Bewertungsmethode haben, zählen dabei Transparenz und Nachvollziehbarkeit der Bewertung [HOF09]. In der Literatur finden sich zahlreiche Aufzählungen weiterer Anforderungen, die in Tabelle 2-4 zusammengetragen worden sind. Die Erfüllung dieser Anforderungen bildet laut den Autoren [GLA94, PFE02, HOF09, POL10] die Voraussetzung für eine erfolgreiche Beurteilung der Leistungsfähigkeit der Lieferanten während der operativen Zusammenarbeit.

Tabelle 2-4: Anforderungen an eine Lieferantenbewertung
Quelle: Eigene Darstellung in Anlehnung an [GLA94, PFE02, ARN08b, GAB08, JAN08, THO08, HOF09, POL10, JUN14]

Anforderung	Konkretisierung
Strategie	• Beachtung unternehmens- und beschaffungsspezifischer Ziele
Crossfunktionalität	• Implementierung bereichsübergreifender Bewertungskriterien
Teamorientierung	• Arbeitsteilige Vorgehensweise bei der Erfassung qualitativer und quantitativer Bewertungskriterien zur Effizienzsteigerung
Kontinuität	• Regelmäßige Bewertung der Lieferanten
Vollständigkeit	• Strukturähnlichkeit von Realität und Modell • Erfassung weniger, aber relevanter Kriterien • Vorhandensein der lieferantenspezifischen Daten zu den relevanten Kriterien
Transparenz, Nachvollziehbarkeit, Objektivität und Akzeptanz	• Klare Formulierung • Überprüfbarkeit der Ergebnisse • Akzeptanz des Verfahrens • Neutralität der Bewertung
Zuverlässigkeit	• Zuverlässige Anwendung • Gleiches Verständnis des Ergebnisses

Tabelle 2-4: Anforderungen an eine Lieferantenbewertung (Fortsetzung)

Anforderung	Konkretisierung
Offenheit der Modellstruktur/ Flexibilität	• Anpassbarkeit an Anwendungssituationen (Ziele, Rahmenbedingungen, etc.) • Einfache Implementierung bei Veränderungen der Situation
Praktikabilität und Wirtschaftlichkeit	• Effizienz (Verhältnis Aufwand zu Ergebnis) • Automatisierbarkeit
Technik	• Anzahl der benötigten Parameter • Programmieraufwand • Berechnungsdauer (Auslastung der Technik)
Lösungen	• Konsistenz der Lösungen • Robustheit der Ergebnisse bei Parameteränderung
Bewertungskommunikation, Bewertungskonsequenzen	• Kommunikation der Bewertungsergebnisse • Maßnahmen zur Verbesserung ableiten

Zur Umsetzung einer Lieferantenbewertung wird ein entsprechendes Verfahren mit *allgemeinen Anforderungen* benötigt. Um die Nachvollziehbarkeit zu gewährleisten, sollte ein strukturiertes Verfahren zur Anwendung kommen [POL10]. Zusätzlich wird die Akzeptanz des Bewertungsverfahrens innerhalb des Fachpersonals durch die Einrichtung bereichsübergreifender Teams gesteigert und sichergestellt [HOF09]. Neben dem Bereich Einkauf nehmen auch die Logistik, die Qualität sowie die Forschung und Entwicklung Einfluss auf die Bewertung [HAR10b]. Um die Entwicklung ausgewählter Zulieferer regelmäßig zu kontrollieren, sollte die Beurteilung der Leistungsfähigkeit in einem festgelegten Turnus durchgeführt werden [JAN08]. Weiterhin ist ein einheitlicher Bewertungsmaßstab mit lieferantenunabhängigen Richtlinien für alle zu beurteilenden Zulieferer einzuhalten [GAB10]. Mit einer entsprechenden (teil-)automatisierten Softwareunterstützung kann eine Lieferantenbewertung ressourcenschonend und standardisiert gegenüber einer manuellen Bearbeitung durchgeführt werden [HAß16]. Mögliche Fehlerquellen werden zusätzlich reduziert [HOF09, POL10].

Spezifische Anforderungen, welche einen direkten Einfluss auf das Bewertungsverfahren haben, tragen nach POLITIS eine „weitaus größere und entscheidendere Rolle als die allgemeinen Anforderungen“ [POL10]. Demnach haben spezifische Anforderungen einen hohen Einfluss auf die Gewichtungsfaktoren des einzelnen Kriteriums in der Lieferantenbewertung. Unter anderem fließen Unternehmens- und Beschaffungsziele ein, welche als Grundlage für unterschiedliche Beschaffungsstrategien betrachtet werden können. In Abhängigkeit von der Beschaffungssituation ist eine detaillierte Gestaltung der Bewertungsstruktur vorzunehmen. Welche Risiken bewertet werden, hängt von der Unternehmensstrategie und -kultur ab. In der Literatur gibt es verschiedene Bewertungskriterien, die im Folgenden erörtert werden.

2.3.3 Bewertungskriterien

Der Umfang und die Auswahl der für die Lieferantenbeurteilung herangezogenen Bewertungskriterien und -verfahren sind abhängig von den zu betrachtenden unternehmensspezifischen Risiken sowie den Anforderungen, die an die Lieferanten gestellt werden. Ziel ist es, durch die Bewertung mögliche Risiken bei der Versorgung des beschaffenden Unternehmens zu minimieren. Im Folgenden werden dafür publizierte Bewertungskriterien betrachtet.

In der Literatur sind eine Vielzahl von möglichen Bewertungskriterien aufgeführt und erläutert [GLA94, DRE00, PFE02, WAG02, HOF09, POL10]. Die Forderung, möglichst viele dieser Indikatoren zur Risikobeurteilung zu berücksichtigen und zu gewichten, scheint zunächst sinnvoll, wird sich im Verlauf dieser Arbeit jedoch nicht als optimaler Weg zu einer effektiven und effizienten Risikobetrachtung erweisen (Kapitel 2.3.4 und Kapitel 3.4.1).

Eine theoretische Abgrenzungssystematik bei der Beurteilung einer kontinuierlichen Leistungserbringung von Lieferanten beinhaltet die Unterteilung in quantitative und qualitative Bewertungskriterien [KNA00, PFE02, JAN08]. *Quantitativ* heißt in diesem Zusammenhang, dass die Bewertung durch Messungen genau verifizierbar ist. *Qualitative* Bewertungskriterien hingegen sind nur durch eine Einschätzung der handelnden Person möglich und bedienen sich keiner messbaren Methode [ADA97]. In der Praxis werden qualitative Kriterien häufig als Softfacts benannt [POL10], wohingegen quantitative Kriterien unter dem Begriff Hardfacts verbreitet sind [APP11]. Softfacts sind nicht durch logistische Kennzahlen modellierbar, sollen sich jedoch durch die Operationalisierung einer subjektiven Beurteilung miteinander vergleichen lassen [APP11].

In der Literatur existieren verschiedene Gliederungsmöglichkeiten von Bewertungskriterien. HARTMANN ET AL. [HAR13] geben 13 Kategorien zur Strukturierung der Bewertungskriterien an. Darunter fallen beispielsweise Flexibilität, Termintreue, Preis, Gesamtkosten und Kommunikation. Im Gegensatz dazu beschränken sich DISSELKAMP und SCHÜLLER [DIS04] auf zehn Hauptkriterien zur Beurteilung der Zulieferer, wobei die Kategorien Bonität und Finanzkraft, der Standort sowie unternehmenspolitische Faktoren im Gegensatz zu HARTMANN ET AL. [HAR13] entfallen. Nach GLANTSCHNIG [GLA94] lassen sich die Bewertungskriterien in *objektbezogene* und *modalitätsbezogene* Leistungen differenzieren. Hierbei beziehen sich die objektbezogenen Leistungen direkt auf das Produkt. Die Unterkriterien dieser Leistungen beinhalten das Maß der Qualität des Produktes und die Mengenleistung des Lieferanten. Die Modalitätsleistungen bewerten hingegen die Leistungsfähigkeit, „die sich auf einzelne Komponenten von dessen Modalitäten richten“ [GLA94].

Die durch die Literatur beschriebenen Möglichkeiten einer Bewertungsstruktur sind vielfältig. Dennoch werden häufig folgende Kriterien zur Lieferantenbewertung genannt:

- Preis
- Qualität
- Logistik und Lieferzuverlässigkeit
- Service

Die generierten Kriterien aus der Literatur sind nicht vollständig auf einen bestimmten Einzelfall anwendbar. Somit müssen diese je nach Beschaffungsstrategie unternehmensspezifisch angepasst werden. Zusätzlich können durch den steigenden Informationsbedarf über die Lieferanten nicht alle in der Literatur aufgeführten Risikofaktoren erfasst und gemessen werden [HAR13]. Somit werden zunächst die entsprechenden Bewertungskriterien zur Risikobeurteilung der Lieferanten-Abnehmer-Beziehung selektiert, um anschließend das geeignete Bewertungsverfahren auszuwählen. Im Folgenden wird ein Überblick über die verschiedenen Komplexitätsstufen der Bewertungsverfahren mit dem Stand der theoretischen Forschung in diesem Bereich sowie einer kurzen Einschätzung gegeben.

2.3.4 Stufen der Lieferantenbewertung

In der Literatur sind verschiedene Einteilungen von Lieferantenbewertungsverfahren zu finden. Trotz der differenten Gliederung nehmen die Autoren eine Unterscheidung in qualitative und quantitative Bewertungsverfahren vor [GLA94, ARN08b, JAN08, HOF09, WOL09, POL10]. Ein Verfahren ist dabei eine „festgelegte Art und Weise, eine Tätigkeit oder einen Prozess auszuführen“ [DINENISO9000]. Es regelt die „Vorgehensweise zur Erreichung von bestimmten Gestaltungszielen bis auf die Ebene einzelner Arbeitsschritte“ [BOL07].

Bei *quantitativen Verfahren* kommen metrisch skalierte Daten, welche als Gleichungssystem miteinander verbunden werden, zum Einsatz. Q*ualitative Verfahren* sind hingegen von subjektiven Einschätzungen und Meinungen auf die Ziele geprägt, ohne das genaue Ausmaß auf den Zielerreichungsgrad darstellen zu können [ADA97].

FERRERAS [FER07] und MÜSSIGMANN [MÜS07] nehmen zusätzlich eine Einteilung in Mischverfahren vor. Diese Verfahren haben sowohl einen qualitativen als auch einen quantitativen Charakter. Dabei werden innerhalb eines Bewertungsprozesses numerische Werte verwendet, die Ergebnisse jedoch qualitativ dargestellt. Meist handelt es sich dabei um Notensysteme und Punktebewertungsverfahren [FER07, MÜS07]. ARNOLD ET AL. [ARN08b] weisen diesen Verfahren nur qualitative Merkmale zu. Die vorliegende Arbeit lehnt sich bei der Einteilung der Lieferantenbewertungsverfahren an die mehrfach publizierte Darstellungsform mit der Unterteilung in qualitative und quantitative Bewertungsverfahren an (Bild 2-6). Diese differenzierte Bezeichnung bezieht sich dabei auf die Zusammensetzung der Bewertungskriterien (Kapitel 2.3.3).

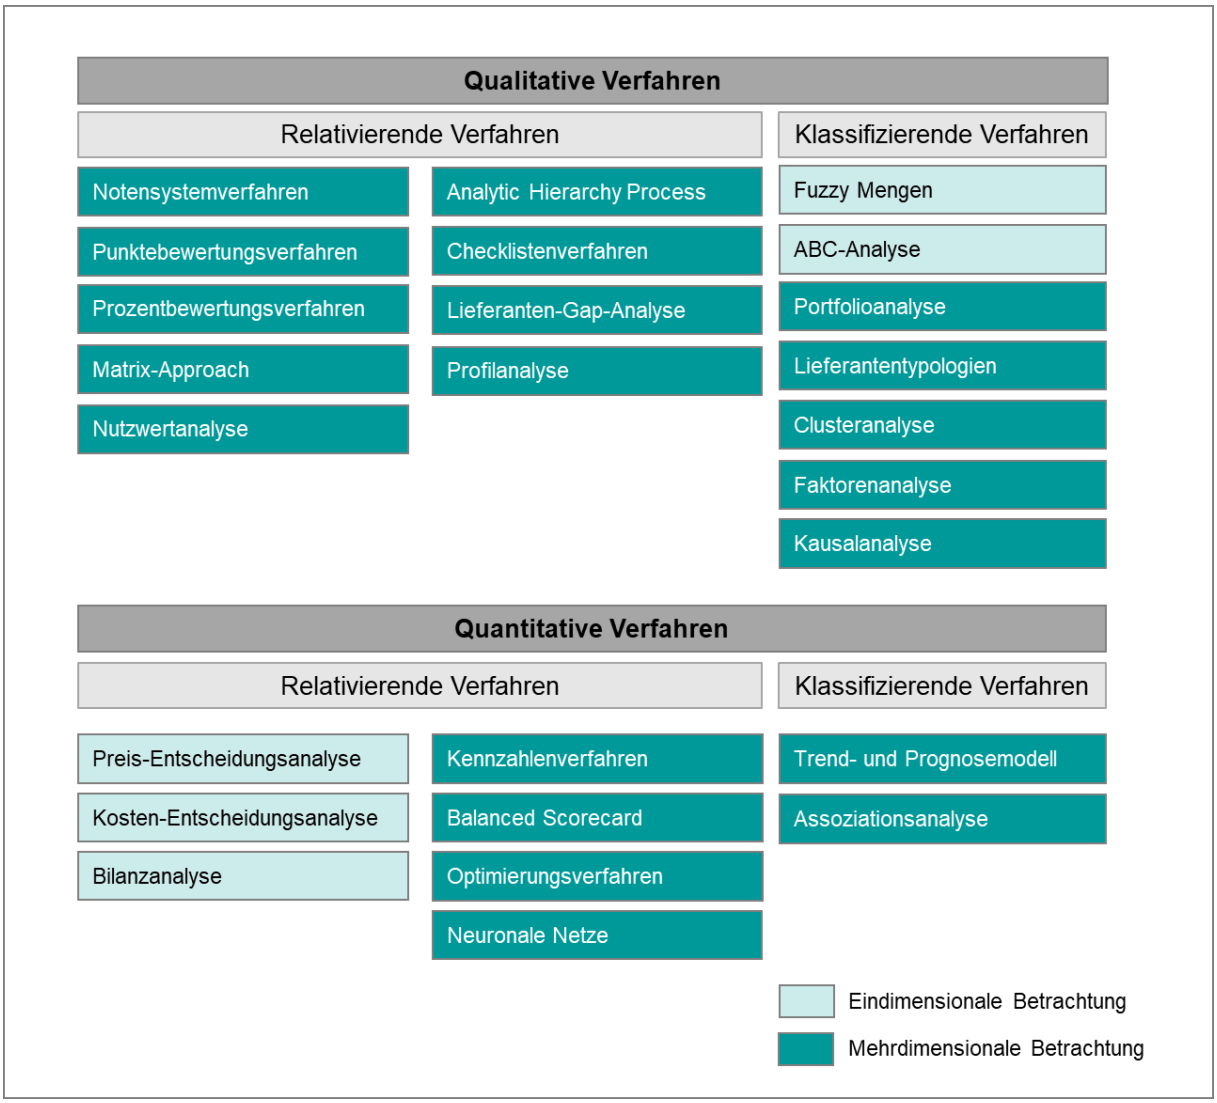


Bild 2-6: Einteilung Lieferantenbewertungsverfahren aus der Literatur
Quelle: Eigene Darstellung

Innerhalb der Lieferantenbewertungsverfahren werden eindimensionale oder mehrdimensionale Bewertungen im Rahmen des Zieldreiecks (Qualität, Kosten, Zeit) vorgenommen. Durch eindimensionale Betrachtungen wird ein Bewertungskriterium, wie beispielsweise der Preis oder die Kosten, beurteilt. Mehrdimensionale Betrachtungen beziehen mehr als ein Bewertungskriterium in die Beurteilung ein. Diese Verfahren werden zusätzlich in relativierende Verfahren zur Erzeugung einer Rangliste und klassifizierende Verfahren zur Beurteilung der Erbringung von Lieferanteneinzelleistungen untergliedert.

Die Lieferantenbewertungsverfahren folgen einer Evolution im Bereich der Komplexität zur Steuerung der externen Wertschöpfungsnetzwerke (Bild 2-7). Die geringste Komplexität weisen eindimensionale Verfahren auf. Durch diese Betrachtung einer Dimension, wie dem Preis bzw. den Kosten oder auch die Höhe des Bestellvolumens, das mit dem Lieferanten umgesetzt wird, ist nur eine Zielgröße im Fokus der Bewertung. Durch mehrdimensionale Bewertungsverfahren erhöht sich die Komplexität durch die höhere Anzahl der Bewertungskriterien. Es kann dabei jedoch aber auch zu konkurrierenden Zielvorgaben, beispielsweise zwischen dem zu erzielenden Preis und der benötigten Qualität eines Produktes, kommen.

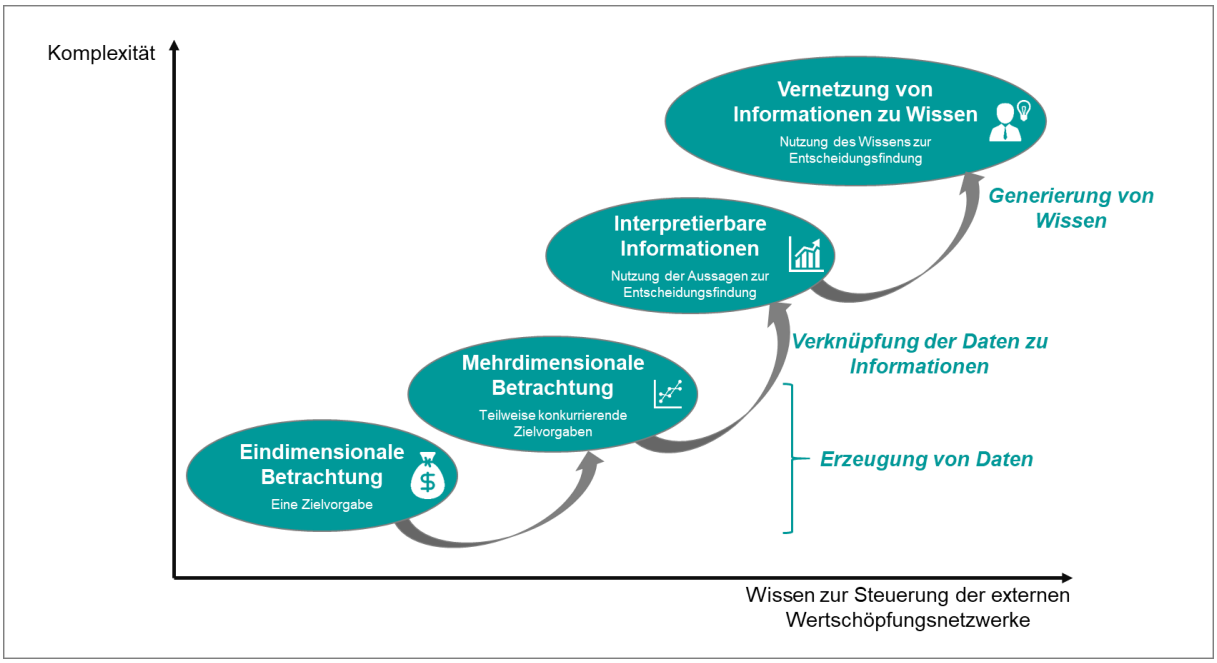


Bild 2-7: Evolution der Lieferantenbewertung
Quelle: Eigene Darstellung

Verfahren, die in diesem Rahmen eine mehrdimensionale Betrachtung sowie eine Verknüpfung von Daten, z.B. im Rahmen der Zeit haben, erzeugen interpretierbare Informationen für eine Entscheidungsfindung [DUS18]. Dies kann beispielsweise durch die Betrachtung von Trends- und Prognosen sowie die Möglichkeit von Kausalanalysen geschehen. Diese Aussagen können als erste Indikatoren für eine Entscheidungsfindung dienen (Kapitel 3.4.1). Durch die Vernetzung verschiedener Informationen zu Wissen erhöht sich die Komplexität der Lieferantenbewertung nochmals. Durch diese Vernetzung wird Wissen über die externen Wertschöpfungsnetzwerke erzeugt [REH96, BOD03], da zusätzlich die Stärken der unterschiedlichen Verfahren gebündelt werden können. Dieses Wissen stellt die Grundlage einer Lieferantenbewertung dar, welche die Basis für präventive Handlungsmaßnahmen bildet. Zusammengefasst ergeben sich innerhalb der möglichen Lieferantenbewertungsverfahren vier Stufen:

- Stufe 1: Verfahren mit der Betrachtung einer Dimension
- Stufe 2: Verfahren mit der Betrachtung verschiedener Dimensionen
- Stufe 3: Verknüpfung von Daten zu interpretierbaren Informationen
- Stufe 4: Vernetzung verschiedener Informationen zur Generierung von Wissen

Nachfolgend werden nun die verschiedenen Stufen mit den entsprechend zugeordneten Lieferantenbewertungsverfahren näher beschrieben. Dabei wird eine erste Einschätzung in Hinblick auf den Erfüllungsgrad der Anforderungen in Kapitel 2.3.2 gegeben.

2.3.4.1 Stufe 1: Betrachtung einer Dimension

„Im Einkauf liegt der Gewinn“ [MEL89]. Mit diesen Zitat weist bereits MELZER-RIDINGER [MEL89] auf die Bedeutung von Materialpreisen und Gesamtkosten für das beschaffende Unternehmen hin. Auch JANKER [JAN08] hebt durch die Ergebnisse seiner Befragung nach der Qualitätsleistung, die Wichtigkeit der Entgeltleistung des Lieferanten hervor. Diese Aussagen werden ebenfalls durch die Publikationen von METZ [MET15] und GUDEHUS [GUD15] bestätigt. Somit befassen sich Bewertungsverfahren der eindimensionalen Betrachtung beispielsweise mit dem Preis, den Kosten oder einer Klassifizierung der Lieferanten über den Umsatz. Ausnahme dabei ist die ABC-Analyse.

Ziel einer reinen Preisbetrachtung ist die Überprüfung der Angemessenheit des angebotenen Preises für eine Ware oder Dienstleistung [MUS98]. Des Weiteren lassen Vergleiche mit Branchendurchschnittswerten oder anderen Zulieferern Rückschlüsse über Chancen und Risiken für das beschaffende Unternehmen zu [GLA94, SYD10]. Z. B. kann die Kenntnis über die Entwicklung des (Einstands-) Preises oder der Bilanz des Zulieferers bei Verhandlungen mit dem Lieferanten von Vorteil sein [DIS04]. Geplante Preiserhöhungen können unter Umständen relativiert werden [GLA94]. Verfolgt ein Unternehmen beispielsweise eine Expansionsstrategie, sind leistungsstarke Partner erforderlich, die den unternehmensspezifischen Anforderungen genügen. Aus Kennzahlen, wie dem Cash Flow oder der Eigenkapitalquote, kann laut HARTING [HAR94] abgeleitet werden, ob ein Unternehmen in der Lage ist, ein beispielsweise im Business Plan verankertes Wachstum zu finanzieren. Diese Kennzahlen werden je nach Verfahren in Zusammenhang mit weiteren Indikatoren für die Preisbetrachtung zur Lieferantenbewertung eingesetzt. In der Literatur werden hierzu folgende Verfahren publiziert [JAN08, HOF09, POL10, IRL12]:

- Preis-Entscheidungsanalyse
- Kosten-Entscheidungsanalyse
- Bilanzanalyse

Um die Vorgehensweise einer Lieferantenbewertung auf Basis des Preises, der Kosten oder der Bilanz zu verdeutlichen, wird auf die Verfahren Preis- und Kostenentscheidungsanalyse eingegangen.

Zu einer *Preis-Entscheidungsanalyse* gehören die Preisbeobachtung, der Preisvergleich sowie die Preisstrukturanalyse. Die Entwicklung eines Preises für ein Produkt wird durch die Preisbeobachtung betrachtet. Dabei sollte nicht nur das Produkt selbst, sondern auch verschiedene Rohstoffpreise für das Gut betrachtet werden. Preisvergleiche finden bei der Differenzierung gleichwertiger Produkte unterschiedlicher Lieferanten Anwendung. Der Fokus innerhalb der Einkaufspraxis liegt auf der Preisbeobachtung und dem Preisvergleich. Das allgemeine Lieferantenverhalten sowie die Fähigkeiten in Bezug auf Qualität und Logistik werden nicht betrachtet [IRL12].

Innerhalb der *Kosten-Entscheidungsanalyse* werden die Kosten zur Herstellung eines Produktes oder Durchführung einer Dienstleistung beurteilt. Dabei finden in der Preis-Entscheidungsanalyse weitere Einflüsse, wie Qualität, Logistik und Service, Berücksichtigung [IRL12]. Die sich ergebenden „Kosten werden in diesem Zusammenhang als Strafe angesehen“ [[JAN08]

mit Verweis auf [TIM86]]. Der Lieferant mit dem geringsten (Einstands-)Preis sowie den geringsten Kosten wird ausgewählt, um eine Bestellung zu platzieren. Innerhalb der Kostenbetrachtung können dabei die Prozesskosten herangezogen werden. Als Prozesskosten werden Konformitäts- und Nonkonformitätskosten im Rahmen des Lieferantenmanagements betrachtet [DUS17].

Eine Lieferantenbewertung anhand von preis-, kosten-, oder bilanzspezifischen Merkmalen, wie z. B. Vertriebs-, Produktions- oder Personalkennzahlen (*Bilanzanalyse*), ohne Berücksichtigung quantitativer Daten ergibt somit keine umfassenden Informationen über die Leistungsfähigkeit eines Lieferanten. Eine Betrachtung der Leistungsfähigkeit ergibt sich erst, wenn beispielsweise auch die tatsächlich erbrachte Liefertreue oder die Qualität der gelieferten Ware beurteilt wird. Zusätzlich erschweren fehlende Daten innerhalb der Datenbasis, wie beispielsweise die Einsicht in Bilanzierungen oder Kalkulationen des Lieferanten, die Beurteilung aus Sicht des Abnehmers [ARN10]. SCHMITT hat dazu mit dem Verweis auf die 14 Managementregeln von DEMING folgendes formuliert: „Beende die Praxis, Geschäfte auf der Basis des niedrigsten Preises zu machen“ [SCH15b].

Neben der reinen preis-, (prozess-)kosten-, oder bilanzspezifischen Bewertung wird die *ABC-Analyse* publiziert. Die ACB-Analyse ist ebenfalls eine eindimensionale Lieferantenbewertung, dient aber der Klassifizierung von Lieferanten [FAL07]. Die Grundlage einer ABC-Analyse ist eine Pareto-Klassifizierung. Nach GUDEHUS stellt diese Einteilung „eine Anordnung einer Anzahl von Objekten nach abnehmender Größe einer messbaren Eigenschaft “ [GUD05] dar. Das vielfach übliche Verhältnis beträgt dabei 80:15:5 (ABC-Lieferanten) [GUD05]. Das Beschaffungsvolumen ist eine der gebräuchlichsten Einordnungsmöglichkeiten der Lieferanten [HOF09]. Somit erhalten die Unternehmen eine ausgewählte Anzahl von Lieferanten anhand des Beschaffungsvolumens, die später durch eine mehrdimensionale Lieferantenbewertung beurteilt werden.

Erhöht sich die Dimension der Bewertungskriterien, erhöht sich auch die Komplexität der Lieferantenbewertungsverfahren von Stufe 1 zu Stufe 2. Auf die Verfahren mit dem Ziel einer mehrdimensionalen Betrachtung wird im folgenden Kapitel eingegangen.

2.3.4.2 Stufe 2: Betrachtung verschiedener Dimensionen

Die Verfahren der Stufe 2 werden je nach Zielstellung in relativierende und klassifizierende Verfahren gegliedert. Diese beiden Gruppen werden nun näher erläutert.

Lieferanten mit einer kritischen Leistungserbringung werden von den Abnehmern auf eine Verbesserung oder Verschlechterung hin kontrolliert. Die Abnehmer haben jedoch nur begrenzte Kapazitäten, um mit Lieferanten zusammenzuarbeiten [ARN08b]. Um einen effizienten Ressourceneinsatz zu ermöglichen, werden Rangfolgen [ADA97] vom schlechtesten bis hin zum besten Lieferanten [JAN08] über *relativierende Verfahren* ermittelt und auch Einzelbetrachtungen der Leistungsfähigkeit bei den Zulieferern vorgenommen. Auf Grund der einfachen Verfahrensweise [GLA94], werden diese Bewertungsverfahren oft in der Praxis angewendet [VER94, HOF09, HAß16a]. In der Literatur werden hierzu verschiedene Verfahren postuliert [GLA94, ADA97, KAP97, PFE02, KAP04, JAN08, HOF09, HAR10b, POL10, IRL12, GÖP13, JUN14, BRU15].

Verfahren zur Erzeugung von Ranglisten vom schlechtesten bis zum besten Lieferanten anhand mehrdimensionaler Kriterien:

- Notensysteme (Drei- und Fünf-Notensystem, Qualifiziertes Notensystem, Indexsystem)
- Punktebewertungsverfahren (100-Punktebewertungsverfahren, Scoring Modell)
- Prozentbewertungsverfahren
- Matrix-Approach
- Nutzwertanalyse
- Analytic Hierarchy / Network Process
- Kennzahlenverfahren (Logistikkennzahlen, Zuverlässigkeitskennzahlen, Gesamtwertzahlverfahren)
- Balanced Scorecard

Verfahren zur Einzelbetrachtung von Lieferanten anhand mehrdimensionaler Kriterien:

- Checklistenverfahren
- Optimierungsverfahren
- Lieferanten-Gap-Analyse
- Profilanalyse

Während dem Kennzahlenverfahren, der Balanced Scorecard und den Optimierungsverfahren quantitative Daten zugrunde liegen, nutzen alle anderen Bewertungsverfahren qualitative Beurteilungen mit Hilfe einer Punkte- oder Prozentskala. Diese weist, je nach Verfahren, einer guten Leistung einen hohen und einer schlechten Leistung einen entsprechend niedrigen Wert zu.

Im Folgenden wird nun zunächst schematisch die Vorgehensweise der relativierenden Verfahren zur Erstellung einer Rangliste verdeutlicht (Bild 2-8). Diese Verfahren sind eine Teilmenge der aufgelisteten Verfahren der Stufe 2. Bild 2-8 visualisiert generisch über alle Verfahren den Ablauf zur Generierung der Ranglisten. Nach der Erörterung der Verfahren zur Erstellung einer Rangliste werden alle weiteren Verfahren zur Bewertung der Leistungsfähigkeit einzelner Lieferanten ebenfalls untersucht.

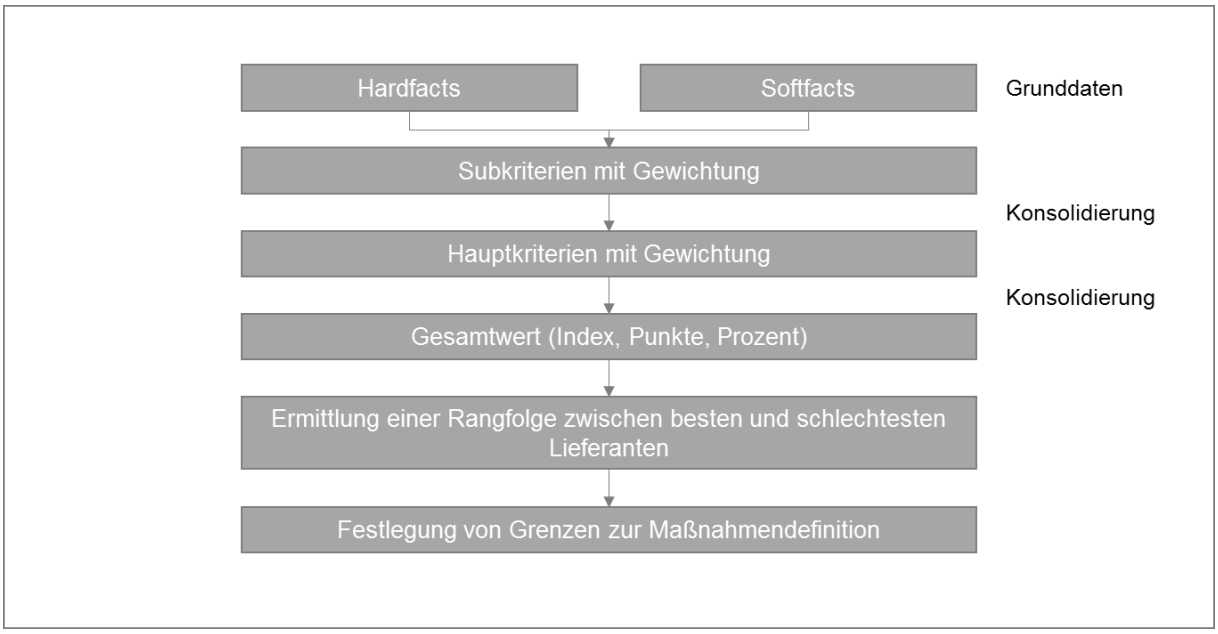


Bild 2-8: Vorgehensweise zur Ermittlung einer Rangfolge zwischen besten und schlechtesten Lieferanten
Quelle: Eigene Darstellung

Die Subkriterien (Hard- und Softfacts) werden nach ihrer Relevanz gewichtet. Dies sollte nach JANKER [JAN08] mit der Methode des singulären oder paarweisen Vergleichs geschehen. Durch den paarweisen Vergleich zeichnet sich beispielsweise der Analytic Hierarchy Process aus [BRU15]. Das Produkt aus der Gewichtung und dem Erfüllungsgrad der einzelnen Kriterien wird dann, je nach Verfahren, in Punkten, Prozent oder Indizes dargestellt und in Hauptkriterien konsolidiert. Oft wird zusätzlich ein Gesamtwert pro Lieferant aus der Summe oder dem Durchschnitt der Bewertungskriterien (meist Hauptkriterien) errechnet [JAN08, HOF09, WER17]. Somit ergibt sich eine Rangfolge zwischen den besten und schlechtesten Lieferanten [JAN08].

Problematisch ist hierbei die Differenzierbarkeit innerhalb des Bewertungsschemas. Die subjektive Einschätzung der Lieferantenleistung [GLA94, WER17] ist mit einer Skala, die einen Wortlaut wie „gut“ oder „sehr gut“ oder „Forderung nicht erfüllt“ bzw. „Forderung voll erfüllt“ [HOF09, WER17] in eine numerische Angabe überführt [THO08], für nachfolgende Bewertungen nicht transparent reproduzierbar. Zusätzlich bemängelt WERNER [WER17] die auftretenden Rundungen, Zahlenverdichtungen und Skalierungsbrüche.

Die Umrechnung der Zielerfüllung (Hardfacts) in Punkte oder eine Prozentangabe führt zu einer Intransparenz der tatsächlichen Werte der Lieferantenleistung. Durch die Verrechnung der unterschiedlichen Bewertungskriterien, d. h. der Subkriterien zu einem Hauptkriterium [JAN08, HOF09] sowie Verwendung von Hard- und Softfacts [HOF09], gehen zusätzlich Informationen über die Leistungserbringung der Lieferanten verloren. Werden diese Informationen zu einer Gesamtbewertung (Index, Punkte oder Prozent) zusammengefasst, ergibt dies eine „Scheingenauigkeit des Summenscores“ [GLA94]. Somit wird „eine nicht vorhandene quantitative Genauigkeit vorgetäuscht“ [KNA00], indem qualitative Merkmale durch Zahlen ausgedrückt werden. Dies kann zu Fehlentscheidungen führen [GLA94].

Hinzu kommt gegebenenfalls das Konsolidierungsproblem durch die Gewichtung der unterschiedlichen Bewertungskriterien [WAG01, HOF09]. Bewertungen werden miteinander verrechnet, sodass keine Möglichkeit eines Rückschlusses auf die Einzelbewertung eines Kriteriums gegeben ist. Somit bleiben zusätzlich Informationen über die Lieferanten verborgen.

Die Bewertungsverfahren zur Erstellung einer Rangliste sind mit einem manuellen [HOF09, HEL16, DUS18] und damit hohem Aufwand verbunden. Die Lieferantenbasis muss mit zahlreichen Bewertungskriterien regelmäßig beurteilt werden [HOF09]. Studien belegen, dass in diesem Zusammenhang nur ein Teil der Lieferanten bewertet wird [DUS13, DUS16d].

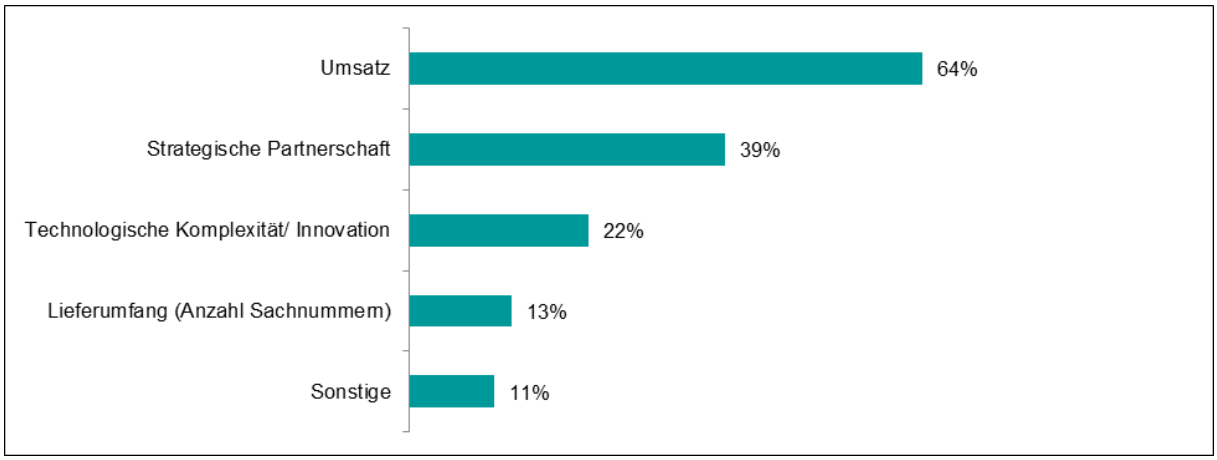


Bild 2-9: Verteilung der Kriterien zur Auswahl der Lieferanten, die regelmäßig bewertet werden
Quelle: [DUS16d]

Die Studie von DUST UND WILDE [DUS16d] zeigt, dass 66 Prozent der befragten Unternehmen nur ausgewählte Lieferanten nach deren Leistungsfähigkeit beurteilen. Mit 64 Prozent ist der Umsatz, vor der strategischen Partnerschaft (39 Prozent), das am häufigsten gewählte Kriterium zur Auswahl der für die Lieferantenbewertung zugelassenen Zulieferer. Dafür wird die Lieferantenbasis klassifiziert. Bei der Verfahrensweise einer eindimensionalen Klassifizierung wird in der Literatur weitestgehend auf die ABC-Analyse verwiesen [JAN08]. Dadurch wird lediglich ein geringer Teil der Lieferantenleistung in der Lieferantenbasis beurteilt (A-Lieferanten). Das Risiko, das von B- und C-Lieferanten ausgeht, die nicht im Bewertungsverfahren eingebunden sind, steigt, da ihre Leistungsfähigkeit nicht bekannt ist.

Nach der Betrachtung relativierender Verfahren zur Erzeugung einer Rangliste vom schlechtesten bis zum besten Lieferanten werden nun Verfahren untersucht, durch welche die Leistungsfähigkeit einzelner Lieferanten ebenfalls über eine mehrdimensionale Betrachtung beurteilt werden kann (klassifizierende Verfahren). Folgende Verfahren werden dazu in der Literatur publiziert [GLA94, JAN08, HOF09, POL10, IRL12]:

- Checklistenverfahren
- Optimierungsverfahren
- Lieferanten-Gap-Analyse
- Profilanalyse

JANKER [JAN08] und POLITIS [POL10] gliedern das *Checklistenverfahren* qualitativ zur Untergruppe der verbalen Verfahren. Die Kriterien der Checklisten werden mit „ja“ oder „nein“ beantwortet. Sie „können an die verschiedenen Entscheidungssituationen angepasst werden

und bieten die Möglichkeit, alle wichtigen Fragestellungen einzubeziehen und somit Schwächen und Stärken des Lieferanten zu erkennen“ [JAN08]. Zudem können Checklisten als Basis für eine Profilanalyse sowie das Punktbewertungsverfahren dienen. Nachteilig ist nach HARTING [HAR94] die Annahme der Gleichwertigkeit aller Merkmale, sodass differente Merkmalsausprägungen einzelner Lieferanten unbeachtet bleiben. Zusätzlich artet die Wahl der Skalierung „nicht selten in eine sinnlose Zahlenspielerei aus, mit der jede Entscheidung begründbar und letztlich nur Ausdruck der Hilflosigkeit gegenüber Problemen [ist]“ [HAR94].

Verfahren, die mit Hilfe einer Zielfunktion einen Parameter optimieren, werden bei JANKER [JAN08] in die lineare Optimierung und die Goal-Programming-Ansätze differenziert. Eine Bewertung der Lieferanten durch *lineare Optimierung* erfordert zunächst eine Modellierung der relevanten Kriterien. Diese Kriterien werden nach Prioritäten gewichtet. Das höchste Gewicht kann abhängig vom Abnehmer u. a. die geringste Wiederbeschaffungszeit, der niedrigste Preis oder auch andere Kriterien beinhalten, welche in eine Zielfunktion eingesetzt werden. „Verfahren der Preis- und Kosten-Entscheidungsanalyse können somit die Grundlage für Verfahren der linearen Optimierung bilden“ [JAN08]. Die übrigen Ziele sind Nebenbedingungen und stellen Minimal- und/oder Maximalforderungen dar, welche einzuhalten sind. Der Lieferant, welcher die Zielfunktion am besten erfüllt, wird ausgewählt. Doch die Begünstigung einzelner Beschaffungsziele ist kritisch, da die Nebenbedingungen konkurrierende Beschaffungsziele darstellen können. Die meisten Ansätze beschränken sich dabei auf das Ziel der Bestellkostenminimierung [REI02]. Eine Weiterentwicklung der linearen Optimierung bilden *Goal-Programming-Ansätze*. Unter dem Oberbegriff der Mathematical Programming Models ist eine Optimierung von Systemen in Bezug auf mehr als eine Zielsetzung zu verstehen. Dabei dient ein Utopia-Punkt als Zielerreichungsgrad, für dessen Nichterreichen ein Vergleichsmaß festgelegt wird. Das Maß des Nichterreichens sollte dabei in der Zielfunktion als Minimum betrachtet werden [KLE95]. Je komplexer sich ein modellierter Sachverhalt verhält, desto stärker erhöhen sich der Bearbeitungsaufwand und die analytischen Anforderungen an den oder die Bearbeiter(-innen). Vielfach wird das Optimierungsproblem auf ein Problem der Kostenminimierung beschränkt [KLE95]. Diese Verfahren sind durch ihren mathematischen Anspruch weniger verbreitet [MÜS07].

Die *Lieferanten-Gap-Analyse* prüft den Einfluss der Lieferanten auf die Wettbewerbsfähigkeit des Abnehmers [WAG02]. Die Herausforderung besteht darin, die relevanten objekt- und situationsbestimmten Bewertungskriterien (Merkmale) festzulegen sowie durch die „Gewichtung der festgelegten Merkmale Richtlinien für den nachfolgenden Schritt der Lieferantenverhandlung festzuschreiben“ [GLA94]. Eine strukturierte Ermittlung der Leistungserbringung „mehrerer Zulieferer ist bei einer Lieferanten-Gap-Analyse jedoch nicht möglich, zudem ist das vorgeschaltete Verfahren der merkmalsgestützten Auswahl zeitaufwändig und kompliziert“ [JAN08].

Zur Visualisierung der Leistungsfähigkeit der Lieferanten dient ebenfalls die *Profilanalyse*. Entscheidende Bewertungskriterien werden dabei qualitativ und quantitativ beurteilt. Durch den visuellen Vergleich der ausgewählten Merkmale zwischen Idealprofil eines Lieferanten und dem IST-Zustand wird der Anbieter ausgewählt, welcher die größtmögliche Übereinstimmung mit dem Idealprofil aufweist [GLA94]. Die grafische Darstellung kann durch ein *Polaritäten-* oder auch *Polarprofil (Sterndiagramm)* der Lieferanten erfolgen. Die Bezeichnung Sterndiagramm aus ARNOLD ET AL. [ARN08b] ist dabei analog zum Vorgehen bei dem Polarprofil in

JANKER [JAN08] zu sehen. Die fehlende Eindeutigkeit und Transparenz in Bezug auf eine Auswahl sowie die Unübersichtlichkeit beim Eintragen der Lieferanten und Auswerten deren Leistungsfähigkeit sind kritisch zu betrachten [GLA94]. Beide grafischen Verfahren sind in ihrer Einschätzung der Bewertungskriterien durch den Anwender subjektiv geprägt. Dies führt zu einer intransparenten Entscheidungsgrundlage. Zusätzlich leidet die Übersichtlichkeit bei der Darstellung vieler Lieferanten.

Bisher wurden im Bereich der mehrdimensionalen Beurteilung relativierende Verfahren betrachtet. Die Einteilung in *klassifizierende* Verfahren nehmen ARNOLD ET AL. [ARN08b] vor. Für diese Autoren gehören die Portfolioanalyse sowie die Lieferantentypologien dazu. Die Darstellung von Chancen und Risiken eines Beschaffungsobjektes innerhalb eines Beschaffungsmarktes ist das Ziel der *Portfolioanalyse*. Bei einer Weiterentwicklung zur dreidimensionalen Bewertung finden Portfoliotechniken dennoch ihre Grenzen. Die Definition der Klassifikationsmerkmale erfolgt subjektiv [JAN08]. Eine hinreichend objektive Entscheidungsgrundlage wird durch den hohen Abstraktionsgrad nicht geschaffen [HAR94]. Nachteilig ist ebenfalls, dass die Portfolioanalyse eine „Reduzierung der gesamten Einflussgrößen auf eine Kombination aus zwei Schlüsselfaktoren“ [JAN08] vornimmt. „Diese beiden Faktoren können eine vorliegende Beschaffungssituation meist nur unzureichend widerspiegeln“ [JAN08].

Ähnlich wie bei der Portfolioanalyse definieren *Lieferantentypologien* einheitliche, homogene Lieferantengruppen basierend auf einer Konsolidierung der relevanten Bewertungskriterien. Zu jeder Klasse ist es möglich, Handlungsempfehlungen für die Gestaltung der Lieferanten-Abnehmer-Beziehung, analog zu einer Portfolioanalyse, herzuleiten. Der manuelle Bewertungsaufwand ist jedoch sehr hoch.

Zusätzlich wird das Ergebnis der Klassifikation bei der Faktorenanalyse genutzt. Die *Faktorenanalyse* wird der Gruppe der multivariaten Verfahren zugeordnet. „Unter der Faktorenanalyse versteht man nicht ein bestimmtes statistisches Verfahren, sondern es handelt sich bei dieser Bezeichnung um einen Sammelbegriff für viele, zum Teil sehr unterschiedliche Techniken“ [FAH96]. Diese Techniken stellen „Verfahren zur Verfügung, die der Aufbereitung, der tabellarischen und graphischen Repräsentation und der Auswertung komplexer Datensituationen dienen“ [JAN08]. Das Motiv der Verfahren liegt in der Klassifikation der Vielzahl von Variablen nach ihrer korrelativen Beziehung. Faktorenanalysen streben demnach eine Reduktion der hohen Dimensionalität des Untersuchungsraumes an [HÜT00]. Eine weitere Zielstellung ist, dass viele Variablen, die in einer starken Wechselbeziehung stehen, durch wenige und unabhängige Faktoren, bei einem akzeptablen Informationsverlust, ersetzt werden [BAC16]. Die Faktorenanalyse ist ein Bestandteil der kausalanalytischen Betrachtungen. Der Vorteil dabei ist, dass bei diesen Verfahren Abhängigkeiten zwischen verschiedenen Merkmalen berücksichtigt werden können. Doch durch das subjektive Eingreifen des Anwenders in die Analyse wird die Interpretation der Ergebnisse einsatzabhängig [JAN08] und somit gegebenenfalls nicht reproduzierbar.

Durch die Analyseverfahren, durch die bisher ein- oder mehrdimensionale Betrachtungen vorgenommen worden sind, werden weitere Daten (Kennzahlen) zu den jeweiligen Lieferanten erzeugt. Was jedoch allen bisher erörterten Verfahren fehlt, ist eine Vernetzung verschiedener Daten zu Informationen. Durch diese Betrachtung erhöht sich die Komplexität der Bewertungsverfahren von Stufe 2 auf Stufe 3.

2.3.4.3 Stufe 3: Verknüpfung von Daten zu interpretierbaren Informationen

Zu den bisher vorgestellten qualitativen und quantitativen Verfahren werden in der Literatur weitere komplexe Lieferantenbewertungsverfahren publiziert. Die Verfahren aus Stufe 3 zeichnen sich durch Verknüpfung von verschiedenen Daten zu Informationen aus. Es fehlt jedoch im Vergleich zu Stufe 4 die Vernetzung von Informationen zu Wissen. Zur Gruppe der Verfahren aus Stufe 3 zählen somit Folgende:

- Kausalmodelle
- Neuronale Netze
- Fuzzy-Mengen

Die Literatur bezeichnet die Analyse von Strukturgleichungsmodellen mit latenten Variablen häufig als *Kausalmodell* oder Kausalanalyse [IRL12]. Durch eine Parameterschätzung werden Rückschlüsse auf Abhängigkeiten zwischen latenten (nicht direkt mess- oder beobachtbaren) Variablen gezogen [HOM08]. Die Abhängigkeiten werden in Korrelationen ausgedrückt. Korrelationen messen somit die Intensität des Zusammenhangs zwischen verschiedenen Risiken, welche als Variablen in das Modell aufgenommen werden [ROM04]. Als Grundlage für die Strukturgleichungsmodelle nennt IRLINGER [IRL12] neben der Regressionsanalyse die Pfadanalyse. Innerhalb von Strukturgleichungsmodellen werden die latenten Variablen sowie die Modellparameter für die Modellspezifikation geschätzt. Für die Lösung werden zunächst die hypothetischen Beziehungen innerhalb des Strukturmodells erfasst und beurteilt. Später werden die Beziehungen zwischen den Variablen innerhalb eines Messmodells formuliert und „aufgrund der empirischen Kovariation zwischen den manifesten Variablen untereinander geschätzt“ [IRL12]. Unter manifesten Variablen werden beobachtbare (messbare) Variablen verstanden. Die Antwort auf die Frage der eindeutigen Lösbarkeit des Modells liegt in der Identifikationsproblematik. Dabei ist zu überprüfen, ob das Modell eindeutig „die Gesamtheit der geschätzten Parameter bestimmt“ [HOM08] oder ob es weitere Formulierungsmöglichkeiten gibt. Indikatoren für nicht identifizierte Modelle sind unter anderem negative Fehlervarianzen sowie große Standardfehler. Bei einer negativen Beurteilung des Modells muss dieses wiederum angepasst werden. Die Ergebnisse können interpretiert werden, wenn die Bewertung des Modells positiv ausfällt. Die Erfassung komplexer Zusammenhänge mittels kausalanalytischer Betrachtungen finden im Bereich Marketing Anwendung [HOM08]. Dieser komplexe Ansatz ist jedoch auf Praktikabilität (Vollständigkeit des Modells sowie dessen Einflüsse) im Sinne der Wirtschaftlichkeit zu untersuchen. Die bekannten, wissenschaftlichen Abhandlungen [DUR11, IRL12] lassen darauf keine Rückschlüsse zu.

Neuronale Netze sind lernende Systeme, die komplexe und dynamische, real existierende Beziehungsmuster mit Hilfe von Daten nachbilden [WIE08]. Die Neuronen, welche eine Teilmenge des Systems darstellen, bilden dabei die Input-Output-Relationen ab. Zunächst wird dazu die Summe oder das Produkt aus allen gewichteten Inputs errechnet. Zur Errechnung des Outputs wird dann eine entsprechende Transformationsfunktion gewählt, über die sich alle Beziehungen abbilden lassen. Bei der Ausgestaltung eines neuronalen Netzes gibt es unterschiedliche Konzeptionen [WIE08]. Die Lernfähigkeit (Schätzverfahren) eines Netzwerkes liegt in der Gewichtsverlagerung der Inputs [HRU00]. Die Datenbasis für ein neuronales Netz muss hinreichend groß sein [WIE08], was in der Praxis nicht immer der Fall ist. Zusätzlich ist die

Modellierung eines neuronalen Netzwerkes zur Lieferantenbewertung komplex und aufwändig, sodass dieses Verfahren in der wissenschaftlichen Literatur zur Lieferantenbewertung zwar genannt wird, es aber keine konkreten Ausführungen gibt [BIE98, IRL12, MÖD19, WAL19]. Es existieren in der Literatur Hinweise zur Nutzung neuronaler Netze in Bezug auf wirkungsdefekte Zusammenhänge zwischen verschiedenen Einflussgrößen [COR98]. Konkretisiert wird das Vorgehen von CORSTEN UND MAY [COR98] nicht. Generell wird der Einsatz von neuronalen Netzen nur im Bereich der Lieferantenauswahl im Rahmen einer Fallstudie näher von GOLMOHAMMADI ET.AL. [GOL09] erläutert. Eine wirtschaftliche Betrachtung zur praxisnahen Einsetzbarkeit von neuronalen Netzen wird nicht diskutiert.

Unter *Fuzzy-Mengen* oder auch Fuzzy-Logik hat sich ein Entscheidungsverfahren entwickelt [MAC02, XU05], das sich mit Modellbildung unter Einbeziehung unscharfer oder nur vage bekannter Daten und Strukturen befasst [POL97]. Ein Entscheidungsverfahren ist „ein System von intersubjektiv nachvollziehbaren Regeln der Informationsbeschaffung und -verarbeitung […], das zur Bewältigung einer bestimmten Art von Entscheidungsproblemen eingesetzt werden kann“ [GRÜ17]. In der klassischen Mengenlehre ist ein Element entweder einer Menge zugehörig oder es liegt außerhalb dieser. Dieses zweiwertige Konzept wird in der Fuzzy-Logik erweitert, indem eine graduelle Zugehörigkeit zu einer Menge beschrieben wird [FER07]. So kann ein Element auch nur zu einem Teil in einer Menge enthalten sein [ROM94]. Die Fuzzy-Mengen können zusätzlich zur eindimensionalen Betrachtung für mehrdimensionale Entscheidungen mit der Nutzwertanalyse verbunden werden [ROM06]. HARTING [HAR94] kritisiert jedoch die Skalierung der unscharfen Mengen. Es stellt sich die Frage, ob eine unscharfe Menge, wie „gut“ oder „schlecht“ bei einer Lieferantenbewertung notwendig ist, da somit intransparente Informationen [FER07] erzeugt werden. Auch JANKER verweist darauf, „dass die Subjektivität zwar gemindert, jedoch nicht gänzlich ausgeschlossen […] wird“ [JAN08]. Durch die Komplexität des Verfahrens [JAN08] erhöht sich der Zeitaufwand, woraufhin die Wirtschaftlichkeit des Verfahrens in Frage gestellt wird [IRL12]. Das Verfahren liefert somit häufig nicht den gewünschten Mehrwert für eine Lieferantenbewertung [IRL12].

Durch die in Stufe 3 vorgestellten Analyseverfahren werden Informationen erzeugt. Diese Informationen sind kontext- bzw. fallgebunden und somit im Rahmen der Informationsgewinnung als subjektiv zu betrachten [BAL11, ETT13]. Als nächstes werden in der Stufe 4 Informationen zu Wissen vernetzt.

2.3.4.4 Stufe 4: Vernetzung verschiedener Informationen zu Wissen

Durch diese Vernetzung von Informationen wird Wissen über die Leistungserbringung der Lieferanten gewonnen. Die analytische Basis bieten, neben hypothesenfreien Verfahren, auch eine Vernetzung von verschiedenen Lieferantenbewertungsverfahren. Das Ergebnis ist eine Steigerung der Komplexität um eben diese Vernetzung der Verfahren zur Stufe 4. Dabei zeichnet die Verfahren der Stufe 4 besonders ihre Objektivität im Bereich der Wissensgenerierung [POR08] aus. Diese Eigenschaft der Objektivität wird drei Verfahren zugeschrieben, die im Folgenden näher betrachtet werden:

- Trend- und Prognosemodell
- Clusteranalyse
- Assoziationsanalyse

Das *Trend- und Prognosemodell* ist ein Teil des gestuften Bewertungsmodells von Lieferanten im Total Supplier Management (Kapitel 3.4.1). Diese Art der Lieferantenbewertung lässt sowohl objektive Aussagen über die vergangene Leistungserbringung der Lieferantenbasis als auch mit einer hohen Wahrscheinlichkeit über die zukünftige Leistungsfähigkeit ohne die Nutzung von subjektiven Gewichtungsfaktoren oder direkter Einbindung von Softfacts zu [DUS10c, RAM17]. Ziel ist es, Risiken frühzeitig objektiv über ein standardisiertes oder jederzeit reproduzierbares Verfahren zu erkennen, um mit den betroffenen Lieferanten präventiv und gezielt Maßnahmen zur Leistungssteigerung oder Absicherung der aktuellen Leistung zu ergreifen (Kapitel 3.4.2). Auf Grund des objektiven Charakters [RAM17] wird das Trend- und Prognosemodell entgegen der Literatur [DUS10c, WIL17, DUS18, WIL18a], in der das Trend- und Prognosemodell dem Prozessschritt des Informierens zugeordnet wird, in der vorliegenden Arbeit dem Bereich der Wissensgenerierung (Stufe 4) und nicht der Informationsgewinnung der Stufe 3 zugeordnet.

Allgemein gibt es verschiedene Prognosemodelle, die für den entsprechenden Anwendungsfall gezielt ausgewählt und kombiniert werden können [MER94]. Das grundsätzliche Vorgehen besteht aus der Analyse vergangener Ereignisse, um Gesetzmäßigkeiten zu finden, aus denen sich Erkenntnisse für zukünftige Ereignisse schließen lassen. Ziel ist es, mittels Prognosen Unsicherheiten einzugrenzen. Hierzu müssen Prognosen in regelmäßigen Abständen aktualisiert und überprüft werden.

Es gibt qualitative und quantitative Prognoseverfahren [WEB90]. Die qualitativen Prognoseverfahren beruhen ausschließlich auf subjektiven Bewertungen durch Experten und werden überwiegend für langfristige Prognosezeiträume eingesetzt [VOG15]. Dabei werden ausschließlich qualitative Aussagen getroffen. Eine Quantifizierung des Prognosewertes ist nicht möglich. Bei einer kontinuierlichen und operativen Lieferantenbewertung mit Trend und Prognosen liegt der Zeithorizont im kurz- bis mittelfristigen Bereich, sodass quantitative Prognoseverfahren, die sich auf mathematische Analysen stützen, verwendet werden [VOG15]. Quantitative Prognoseverfahren nutzen, je nach Prognoseziel, unterschiedliche Algorithmen, die einen quantitativen Prognosewert erzeugen [WEB90]. Des Weiteren werden diese Verfahren in zeitgestützte und kausale Prognosemethoden unterteilt. Diese Methoden zählen zu den mathematischen und statistischen Modellen und können bei Bedarf sinnvoll kombiniert werden [DUS10c].

Für das Lieferantenmanagement eignet sich die Kombination der linearen Regression und exponentiellen Glättung [DUS18]. Dabei bildet ein Teilmodell lineare Trends ab, während das exponentielle Modell Ausreißer und Punktewolken glättet [VOG15]. Diese ergeben gemeinsam das Trend- und Prognosemodell zur Vorhersage der Lieferantenleistung (z. B. bei der Kennzahl „Liefertreue“) für zukünftige Monate. Die beiden Teilmodelle werden für jeden Lieferanten individuell und abhängig vom bisherigen Verlauf der Lieferantenleistung gewichtet [DUS10c]. Die Trends des Datenverlaufs zeigen dabei die Entwicklung der Messwerte in einer Grundtendenz, wie steigend, fallend und konstant. Praxisprojekte zeigen, dass es auch Leistungsverläufe gibt, die von Ausreißern dominiert sind und eher Punktewolken gleichen. Dabei wird verstärkt die exponentielle Glättung genutzt [DUS10c].

Die Prognosen sagen Zustände und Ereignisse vorher und erreichen dabei durch die individuelle und umfangreiche Beobachtung der Daten eine hohe Validität [DUS10c]. Einerseits werden in dem Trend- und Prognosemodell die Prognosen selbst kritisch betrachtet, d. h. auch

das Nichteintreten des Ereignisses mit der höchsten Wahrscheinlichkeit wird berücksichtigt. Andererseits werden die Trends interpretiert und mit weiteren Daten verknüpft, sodass neue Informationen generiert werden.

Die Priorisierung des Handlungsbedarfs auf Basis des Trends ist aufgrund der in der Praxis nur begrenzt zur Verfügung stehenden Ressourcen ein wichtiger Aspekt. Ziel ist es, Maßnahmen in der Reihenfolge ihrer Dringlichkeit in einem Entscheidungsgremium zu beschließen und umzusetzen (Kapitel 3.4.2 und Kapitel 3.4.3).

Das Ziel einer *Clusteranalyse* ist die Erstellung von Ähnlichkeitsprofilen. Durch den schrittweisen Zusammenschluss der Cluster wird die Anzahl dieser immer weiter reduziert. „Die Variablenausprägung zwischen den Clustern soll dabei so unähnlich wie möglich ausfallen“ [JAN08]. Die Clusteranalyse kann dabei auch als Teil eines Verfahrens dienen, wie beispielsweise zur Erzeugung quantitativer Assoziationsregeln im Rahmen der nachfolgend beschriebenen Assoziationsanalyse [EST00, CLE16]. Somit kann die Vielzahl an Assoziationsregeln bereits bei der Erzeugung auf relevante und interessante Regeln eingegrenzt werden (Kapitel 6).

Die *Assoziationsanalyse* ist in der Lage große Mengen verschiedener Daten und Informationen zu verarbeiten. Aus der gesamten Datenbasis werden hypothesenfreie Assoziationsregeln erzeugt. Diese Assoziationsregeln werden dann auf Relevanz und Interessantheit auf Basis verschiedener Kriterien geprüft. Das Ziel der Assoziationsanalyse ist es, Datenmuster innerhalb der Datenbasis aller Lieferanten zu finden [EST00, HET01, KÜS01, BOD03, GAB09, CLE16]. Somit werden einzelne Informationen zu Wissen vernetzt. Dieses Wissen kann als frühzeitige Entscheidungsgrundlage zur präventiven Maßnahmenumsetzung dienen (Kapitel 3.4).

Bisher sind die theoretischen Anforderungen an eine Lieferantenbewertung, deren Ziele, Kriterien sowie die unterschiedlichen Möglichkeiten der Bewertungsverfahren betrachtet worden. Die Erkenntnisse aus dieser Betrachtung werden im Folgenden Kapitel zusammenfassend kritisch gewürdigt. Dabei wird insbesondere auf die Erfüllung der gestellten Anforderungen aus Kapitel 2.3.2 an die Bewertungsverfahren aus Stufe 1 bis Stufe 4 eingegangen.

2.4 Wissensgenerierung durch Lieferantenbewertungsverfahren

Zur Identifikation und Steuerung von Risiken im Wertschöpfungsnetzwerk werden in der Literatur eine Vielzahl von Bewertungskriterien sowie -verfahren postuliert (Kapitel 2.3.3 und Kapitel 2.3.4). In der Praxis finden qualitative und quantitative Bewertungsverfahren aus der Komplexitätsstufe 1 und 2 Anwendung [HOF09, HAß16a]. Insbesondere numerische Verfahren, wie das Scoring-Modell, das Prozent- und das Punktebewertungsverfahren werden in der Praxis eingesetzt [HAR94, PFE02, HOF09].

Um die in Kapitel 2.3.4 erörterten Bewertungsverfahren kritisch zu würdigen, wird in diesem Kapitel gezeigt, ob die Verfahren der einzelnen Komplexitätsstufen den definierten Anforderungen aus Kapitel 2.3.2 genügen. Dabei erfolgt eine konsolidierte Bewertung aller Verfahren einer Stufe je nach Anforderung. Das Verfahren, welches die entsprechende Anforderung aus Kapitel 2.3.2 am besten erfüllt, wird angegeben. Nach diesem Verfahren richtet sich auch der Erfüllungsgrad der entsprechenden Anforderung.

Die Erfüllungsgrade der Anforderungen differenzieren sich dabei ausgehend von „erfüllt“ (100 Prozent) in „teilweise erfüllt“ (50 Prozent) und „nicht erfüllt“ (0 Prozent). Dargestellt werden die Erfüllungsgrade durch

- ● Anforderung ist erfüllt,
- ◑ Anforderung ist teilweise erfüllt oder
- ○ Anforderung ist nicht erfüllt.

Zu jeder Anforderung erfolgt eine kurze spezifische Begründung in Bezug auf den Erfüllungsgrad. Die Verfahren jeder Stufe werden nun separat nach den Anforderungen betrachtet. Begonnen wird mit der Stufe der geringsten Komplexität, der Stufe 1.

Tabelle 2-5: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 1
Quelle: Eigene Darstellung

Anforderung	Erfüllungsgrad	Verfahren, das die Anforderung am besten erfüllt	Begründung
Strategie	●	• Kosten-Entscheidungsanalyse	Beschaffungsspezifische Ziele werden konkret berücksichtigt
Crossfunktionalität	○		Eindimensionale Betrachtung
Teamorientierung	○		Keine arbeitsteilige Vorgehensweise
Kontinuität	●	• Kosten-Entscheidungsanalyse	Regelmäßige Anwendung möglich
Vollständigkeit	○		Eindimensionale Betrachtung

Tabelle 2-5: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 1 (Fortsetzung)

Anforderung	Erfüllungs-grad	Verfahren, das die Anfor-derung am besten erfüllt	Begründung
Transparenz, Nach-vollziehbarkeit, Ob-jektivität und Akzep-tanz	◑	• Preis-Entscheidungs-analyse • Kosten-Entscheidungs-analyse	Eindimensionale Be-trachtung und somit keine bereichsübergrei-fende Akzeptanz
Zuverlässigkeit	●	• Preis-Entscheidungs-analyse • Kosten-Entscheidungs-analyse • ABC-Analyse	Ergebnis ist für alle Be-teiligten gleichermaßen verständlich
Offenheit der Mo-dellstruktur/ Flexibili-tät	●	• Preis-Entscheidungs-analyse • Kosten-Entscheidungs-analyse • ABC-Analyse	Anpassungen sind bei veränderten Situationen zügig und ohne großen Aufwand zu implemen-tieren
Praktikabilität und Wirtschaftlichkeit	◑	• Preis-Entscheidungs-analyse • Kosten-Entscheidungs-analyse • ABC-Analyse	Teilweise ineffiziente Verfahren, da die (Pro-zess-)Kosten oft nicht automatisiert vorhan-den sind
Technik	●	• Preis-Entscheidungs-analyse • Kosten-Entscheidungs-analyse • ABC-Analyse	Anzahl der benötigten Parameter sowie Pro-grammieraufwand und Berechnungsdauer sind gering
Lösungen	●	• Preis-Entscheidungs-analyse • Kosten-Entscheidungs-analyse • ABC-Analyse	Lösungen sind konsis-tent
Bewertungskommu-nikation Bewer-tungskonsequenzen	●	• Preis-Entscheidungs-analyse • Kosten-Entscheidungs-analyse	Ergebnisse können kommuniziert und Maß-nahmen abgeleitet wer-den

Vor allem durch die eindimensionale Betrachtung von Bewertungskriterien generieren die Verfahren der Stufe 1 keine bereichsübergreifende Entscheidungsgrundlage zur Beurteilung kritischer Lieferanten im Rahmen des Risikomanagements (Tabelle 2-5). Durch die reine Preis- und (Prozess-)Kostenbetrachtung sowie die Klassifikation durch eine ABC-Analyse werden Fragestellungen der aktuellen und zukünftigen Lieferantenleistung nicht beantwortet. Die Betrachtung der Lieferantenleistung ist jedoch im Rahmen einer Risikobetrachtung zwischen Lieferant und Abnehmer zwingend erforderlich.

Nach der Betrachtung und Beurteilung der Erfüllungsgrade von Verfahren der Stufe 1 werden nun die Erfüllungsgrade der Verfahren aus Stufe 2 beurteilt.

Tabelle 2-6: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 2
Quelle: Eigene Darstellung

Anforderung	Erfüllungsgrad	Verfahren, das die Anforderung am besten erfüllt	Begründung
Strategie	●	• Balanced Scorecard • Profilanalyse	Beschaffungsspezifische Ziele werden in mehreren Dimensionen berücksichtigt
Crossfunktionalität	●	• Balanced Scorecard • Profilanalyse	Bereichsübergreifende Bewertung
Teamorientierung	●	• Balanced Scorecard • Profilanalyse	Bereichsspezifische Bewertungskriterien werden getrennt erfasst und später konsolidiert
Kontinuität	●	• Balanced Scorecard	Regelmäßige Anwendung möglich
Vollständigkeit	●	• Balanced Scorecard	Erfassung aller relevanten Daten, sofern diese zur Verfügung stehen
Transparenz, Nachvollziehbarkeit, Objektivität und Akzeptanz	○		Die Akzeptanz für die Bewertungsverfahren ist zwar hoch, dennoch werden die Kennzahlen oft subjektiv vergeben
Zuverlässigkeit	●	• Balanced Scorecard	Ergebnis ist für alle Beteiligten gleichermaßen verständlich

Tabelle 2-6: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 2 (Fortsetzung)

Anforderung	Erfüllungs-grad	Verfahren, das die Anforderung am besten erfüllt	Begründung
Offenheit der Modellstruktur/ Flexibilität	●	• Balanced Scorecard • Profilanalyse	Anpassungen sind bei veränderten Situationen zügig und ohne großen Aufwand zu implementieren
Praktikabilität und Wirtschaftlichkeit	○		Ineffiziente Verfahren durch manuellen Bewertungsaufwand; teilweise keine IT-Unterstützung
Technik	◑	• Balanced Scorecard • Profilanalyse	Teilweise hoher Rechenaufwand
Lösungen	●	• Balanced Scorecard • Profilanalyse	Lösungen sind konsistent
Bewertungskommunikation Bewertungskonsequenzen	●	• Balanced Scorecard • Profilanalyse	Ergebnisse können kommuniziert und teilweise bereichsübergreifende Maßnahmen abgeleitet werden

In Tabelle 2-6 werden die Verfahren der Stufe 2 kritisch gewürdigt. „Die Definition geeigneter Bewertungskriterien bereitet teils große Schwierigkeiten“ [HEß08] bei relativierenden Lieferantenbewertungsverfahren. Somit kann eine bereichsübergreifende Bewertung nicht gewährleistet werden. Zusätzlich ist zu bedenken, dass die hohe Anzahl der Zulieferer es meist unmöglich macht, alle Lieferanten mit derselben Intensität von qualitativen oder quantitativen Verfahren zu überwachen [KNA00, DUS16d]. Der manuelle Aufwand ist durch die Einbindung von Softfacts, die in Bewertungsskalen ausgedrückt werden, zu hoch. Aus diesem Grund rät JANKER [JAN08] zu einer Lieferantenstrukturanalyse, die Aufschluss über den zu erbringenden Aufwand je Lieferant gibt. Dabei werden die Zulieferer in Hochleistungs-, Problem- und Mangellieferanten sowie unbrauchbare Lieferanten klassifiziert [LAR09]. Ziel ist es, einen Filter zu erhalten, der zeigt, welche Zulieferer verstärkten Kontrollen unterzogen werden sollten (Problem- und Mangellieferanten) und bei welchen eine Überprüfung seltener stattfinden kann (Hochleistungslieferanten). An dieser Stelle wird auf den in Kapitel 2.3.4.1 erläuterten Einsatz der ABC-Analyse verwiesen [JAN08]. Eine präventive Vorgehensweise durch eine frühzeitige und standardisierte Integration aller Lieferanten in die eigenen Unternehmensprozesse ist nicht möglich, da eine Vermeidung zukünftiger Leistungsdefizite bei einer teilweisen Betrachtung der Lieferantenbasis nicht stattfinden kann. HOFFMANN UND ROLAND postulieren sogar, dass „zumindest die quantitativen Verfahren größtenteils im Bereich des Supplier Risk Managements nicht anwendbar sind“ [HOF13]. Weiterhin kritisieren die Autoren den Aspekt der

Subjektivität bei qualitativen Verfahren. Somit kann keine valide Prognose in Bezug auf die Lieferantenleistung erstellt werden [HOF13].

Verfahren der Komplexitätsstufe 3 verknüpfen mehrdimensionale Daten zu interpretierbaren Informationen. Diese Informationen sind bislang durch Hypothesen und Subjektivität gebunden. Die Erfüllungsgrade der Verfahren aus Stufe 3 in Bezug auf die definierten Anforderungen werden nun in Tabelle 2-7 dargestellt.

Tabelle 2-7: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 3
Quelle: Eigene Darstellung

Anforderung	Erfüllungsgrad	Verfahren, das die Anforderung am besten erfüllt	Begründung
Strategie	●	• Kausalmodelle • Neuronale Netze	Beschaffungsspezifische Ziele sowie weitere Einflüsse werden in mehreren Dimensionen berücksichtigt
Crossfunktionalität	●	• Kausalmodelle • Neuronale Netze	Bereichsübergreifende Bewertung
Teamorientierung	●	• Kausalmodelle • Neuronale Netze	Verschiedene bereichsspezifische Bewertungskriterien in einem Modell
Kontinuität	●	• Kausalmodelle	Regelmäßige Anwendung möglich
Vollständigkeit	○		keine Möglichkeit zur Erfassung aller Umfeldfaktoren; nur Kennzahlen verwendbar (leistungsspezifische Merkmale)
Transparenz, Nachvollziehbarkeit, Objektivität und Akzeptanz	○		Subjektive Bewertung durch Gewichtungen oder Hypothesen innerhalb der Verfahren
Zuverlässigkeit	●	• Kausalmodelle • Neuronale Netze	Ergebnis für ausgewählte Beteiligte verständlich wobei die Komplexität sehr hoch ist

Tabelle 2-7: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 3 (Fortsetzung)

Anforderung	Erfüllungs-grad	Verfahren, das die Anfor-derung am besten erfüllt	Begründung
Offenheit der Mo-dellstruktur/ Flexibili-tät	●	• Kausalmodelle • Neuronale Netze	Anpassungen sind bei veränderten Situatio-nen mit teilweise ho-hem Aufwand imple-mentierbar
Praktikabilität und Wirtschaftlichkeit	○		Hoher Aufwand der subjektiven Bewertun-gen
Technik	●	• Kausalmodelle • Neuronale Netze	Softwareunterstützung möglich
Lösungen	●	• Kausalmodelle • Neuronale Netze	Lösungen sind konsis-tent
Bewertungskommu-nikation Bewer-tungskonsequenzen	●	• Kausalmodelle	Ergebnisse müssen ggf. vor der Kommuni-kation verständlich auf-bereitet werden

In großen Teilen erfüllt die Stufe 3 die Anforderung an eine Lieferantenbewertung. Dennoch gibt es hohe Mängel bei der Vollständigkeit, der Objektivität und Akzeptanz sowie der Praktikabilität und Wirtschaftlichkeit.

Kausalmodelle verwenden Hypothesen zur Beschreibung der Beziehungen zwischen den latenten und manifesten Variablen. Diese Hypothesen führen zu Einschränkungen des Modells hinsichtlich der Datenmenge. Dadurch ist es nicht möglich eine vollständige Datenbasis zu erhalten. Zusätzlich ist dieses Verfahren sehr aufwändig, wodurch es in der Praxis bisher keine bekannte Anwendung durch fehlende Akzeptanz findet.

Wie die Kausalmodelle verwenden auch die Fuzzy-Mengen und die Neuronalen Netze subjektive Hypothesen durch Gewichtungen und sind somit nicht objektiv. Die Verfahren werden auch als komplex beschrieben. Eine effiziente Steigerung des Mehrwehrtes für das Lieferantenmanagement ist bislang nicht nachgewiesen worden [JAN08, DUR11, IRL12].

Die höchste Komplexität innerhalb der Lieferantenbewertungsverfahren findet in Stufe 4 statt. Die Vernetzung von Informationen zu Wissen wird in der vorliegenden Arbeit als Wissensgenerierung bezeichnet. Zur Generierung von Wissen wird eine Kombination aus verschiedenen Verfahren der bisher erörterten Stufen genutzt. Diese Verfahren sind, wie in Kapitel 2.3.4.4 beschrieben, das Trend- und Prognosemodell, die Cluster- sowie die Assoziationsanalyse. Diese drei Verfahren werden nun in Bezug auf die definierten Anforderungen in Tabelle 2-8 dargestellt.

Tabelle 2-8: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 4
Quelle: Eigene Darstellung

Anforderung	Erfüllungs-grad	Verfahren, das die Anforderung am besten erfüllt	Begründung
Strategie	●	• Trend- und Prognosemodell • Assoziationsanalyse	Beschaffungsspezifische Ziele sowie weitere Einflüsse werden in mehreren Dimensionen berücksichtigt
Crossfunktionalität	●	• Trend- und Prognosemodell • Clusteranalyse • Assoziationsanalyse	Bereichsübergreifende Bewertung
Teamorientierung	●	• Trend- und Prognosemodell • Clusteranalyse • Assoziationsanalyse	Bereichsspezifische Bewertungskriterien werden zunächst themenspezifisch ausgewertet, um die Ergebnisse zu konsolidieren und in einem gemeinsamen Verfahren zu analysieren
Kontinuität	●	• Trend- und Prognosemodell • Clusteranalyse • Assoziationsanalyse	Regelmäßige Anwendung möglich
Vollständigkeit	●	• Assoziationsanalyse	Erfassung leistungsbeschreibender und nicht leistungsbeschreibender Merkmale
Transparenz, Nachvollziehbarkeit, Objektivität und Akzeptanz	●	• Assoziationsanalyse	Neutrale und transparente Bewertung durch Hypothesenfreiheit
Zuverlässigkeit	●	• Trend- und Prognosemodell • Clusteranalyse • Assoziationsanalyse	Ergebnis ist für alle Beteiligten gleichermaßen verständlich

Tabelle 2-8: Erfüllungsgrad der Lieferantenbewertungsverfahren aus Stufe 4 (Fortsetzung)

Anforderung	Erfüllungs-grad	Verfahren, das die Anforderung am besten erfüllt	Begründung
Offenheit der Modellstruktur/ Flexibilität	●	• Assoziationsanalyse	Anpassungen sind bei veränderten Situationen implementierbar
Praktikabilität und Wirtschaftlichkeit	●	• Trend- und Prognosemodell • Clusteranalyse • Assoziationsanalyse	Automatisierbarkeit ist gewährleistet
Technik	●	• Trend- und Prognosemodell • Clusteranalyse	Softwareunterstützung möglich
Lösungen	●	• Trend- und Prognosemodell • Clusteranalyse • Assoziationsanalyse	Lösungen sind konsistent
Bewertungskommunikation Bewertungskonsequenzen	●	• Trend- und Prognosemodell • Clusteranalyse • Assoziationsanalyse	Ergebnisse müssen auf Relevanz geprüft werden

Wie die Studie von DUST UND WILDE [DUS16d] nachweist, verwenden die befragten Unternehmen vorrangig Daten aus den vergangenen Zeitperioden für die Bewertung ihrer Lieferanten. Diesen Sachverhalt merkt auch WERNER [WER17] kritisch an. Für eine präventive Leistungsdatenerhebung müssen jedoch zusätzlich Daten aus der aktuellen Zeitperiode sowie zukunftsbezogene Daten aus Trendanalysen und Prognosen verwendet werden [DUS16a]. Es fehlen bislang Frühwarnsysteme für Unternehmensrisiken [GAB10]. Ein mögliches Frühwarnsystem ist das Trend- und Prognosemodell [DUS10c]. Das Trend- und Prognosemodell generiert durch seine Objektivität zwar Wissen, ist jedoch durch die Beschränkung auf Kennzahlen nicht vollständig. Eine ausführliche Beschreibung des Trend- und Prognosemodell ist in Kapitel 3.4.1 zu finden. Eine vollständige Risikobetrachtung bietet hingegen die Assoziationsanalyse. Diese integriert leistungsbeschreibende Merkmale, wie beispielsweise Kennzahlen, und auch nicht leistungsbeschreibende Merkmale, wie beispielsweise den Produktionsstandort eines Lieferanten (Kapitel 4.5.2).

Die Assoziationsanalyse erfüllt die Anforderungen aus Kapitel 2.3.2 auf Grund der Hypothesenfreiheit und Objektivität bis auf die technische Unterstützung. In diesem Zusammenhang ist im weiteren Verlauf der Arbeit zu prüfen, ob es Möglichkeiten der Verarbeitung großer Datenmengen auf Basis der Assoziationsanalyse im Rahmen der vorliegenden Arbeit mit IT-Systemen gibt (Kapitel 4.4.4). Zusätzlich kann die Komplexität der Assoziationsanalyse mit Hilfe der Clusteranalyse reduziert werden. ESTER UND SANDER [EST00] nutzen die Kombination der

Clusteranalyse sowie der Assoziationsanalyse, um quantitative Assoziationsregeln zu erstellen. Diese haben den Vorteil, dass sich der Rechenaufwand der Assoziationsanalyse auf Grund der geringeren Anzahl der Attribute reduziert [EST00].

Eine Kombination der Verfahren scheint somit sinnvoll. Diese Kombination wird im weiteren Verlauf der Arbeit untersucht (Kapitel 4.3). Um Synergien innerhalb der Stärken der drei Verfahren zur Wissensgenerierung hervorzuheben, werden die Lieferantenbewertungsverfahren der Stufe 4 wie folgt kombiniert:

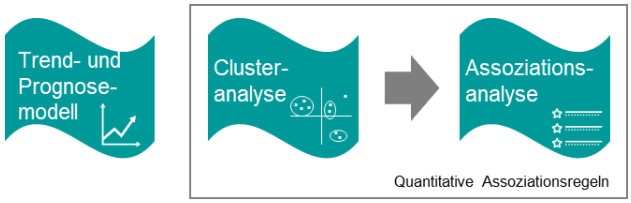


Bild 2-10: Kombination von Lieferantenbewertungsverfahren innerhalb der Komplexitätsstufe 4
Quelle: Eigene Darstellung

In welcher Form das Trend- und Prognosemodell Einfluss oder einen Mehrwert für die quantitativen Assoziationsregeln hat, ist im weiteren Verlauf der Arbeit zu prüfen (Kapitel 4.3). Als Abschluss des Kapitel 2 werden die Ergebnisse mit dem bisherigen Stand von Wissenschaft und Forschung zusammengefasst.

2.5 Zusammenfassung und Fazit

Der aktuelle Trend, dass sich der Einkauf vom Materialbeschaffer zum Gestalter von Wertschöpfungsnetzwerken entwickelt, setzt eine flexible Gestaltung des Lieferantenmanagements voraus. Doch bisher liegt der durchschnittliche Reifegrad des Lieferantenmanagements in produzierenden Unternehmen bei 40 Prozent, wie die Studie von DUST UND WILDE [DUS16d] belegt. In Summe haben die Unternehmen zwar den Nutzen eines ganzheitlichen Lieferantenmanagements erkannt, dieses aber noch nicht durgehend umgesetzt.

Um die Wertschöpfungsnetzwerke gestalten zu können, wird Wissen über diese benötigt. Bislang sind dazu verschiedene Lieferantenbewertungsverfahren genutzt worden. Zwar bewertet ein Großteil der Unternehmen die Lieferantenbasis regelmäßig, doch nur 34 Prozent der befragten, produzierenden Unternehmen beurteilen alle Lieferanten ihrer Lieferantenbasis [DUS16d]. Aussagen, in wie fern bei dieser Art der Lieferantenbewertung Wissen generiert wird, lässt die Studie nicht zu.

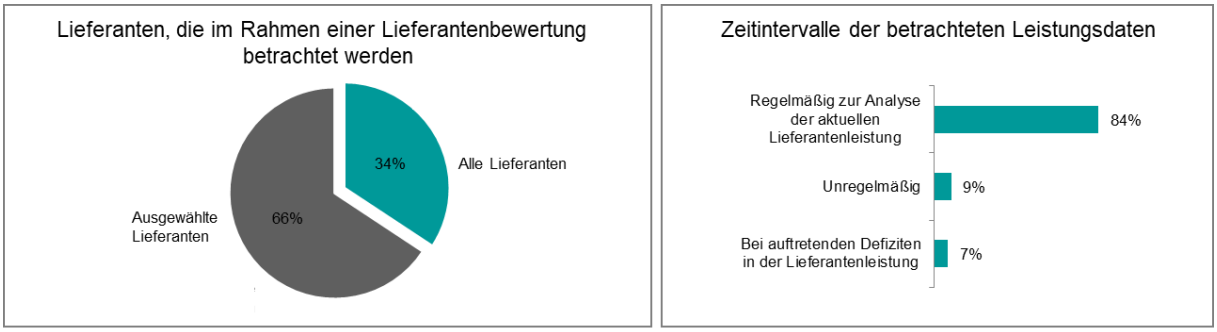


Bild 2-11: Umsetzung der Lieferantenbewertung im produzierenden Unternehmen
Quelle: [DUS16d]

Zusammenfassend nimmt die Komplexität der Lieferantenbewertung durch die Generierung von Wissen zu (Bild 2-7). Die Erörterung des Status Quo des Lieferantenmanagements zeigt, dass die in der Literatur postulierten und in der Praxis angewendeten Bewertungsverfahren zur Steuerung der externen Wertschöpfungsnetzwerke (Stufen 1 bis 3) für ein effizientes Wissensmanagement unter Beachtung der Anforderungen aus Kapitel 2.3.2 unzureichend sind. Um Wissen über die externen Wertschöpfungsnetzwerke zu generieren, wird eine Kombination verschiedener Verfahren im Rahmen der Wissensgenerierung (Stufe 4) benötigt. Zusammen bilden die Verfahren der Stufe 4 Synergieeffekte auf Basis ihrer Analysemöglichkeiten:

- *Trend- und Prognosemodell*: Betrachtung von Trends- und Prognosen
- *Clusteranalyse:* Betrachtung von Ähnlichkeiten
- *Assoziationsanalyse*: Betrachtung von Datenmustern über ein hypothesenfreies Verfahren auf Basis einer beliebig großen Datenmenge

Folglich besteht ein evidenter Forschungsbedarf zur Modellierung einer anforderungsgerechten Methode zur Wissensgenerierung über das externe Wertschöpfungsnetzwerk. Dieses Wissen muss in einem iterativen Prozess validiert werden. Somit wird ein Workflow definiert, der dieser Anforderung gerecht wird. Das Total Supplier Management bietet dabei die Möglichkeit das generierte Wissen in einem Managementworkflow zu überführen.

3 Total Supplier Management

Bei der Betrachtung des Lieferantenmanagements in Kapitel 2 sind einige Theorien zum Prozess des Lieferantenmanagements mit dem Schwerpunkt der Lieferantenbewertungsverfahren vorgestellt worden. Offene Forschungsfragen im Bereich des Wissensmanagements (Kapitel 1.1), wie sie bei JANKER [JAN08] formuliert sind, können dadurch jedoch nicht beantwortet werden. Auch die Frage nach neuen Managementansätzen zur Steuerung der externen Wertschöpfungsnetzwerke, welche nach SYDOW [SYD99] zukünftig besser zu strukturieren und weiterzuentwickeln sind, bleibt offen.

Aus diesen Gründen wird nun der Ansatz des Total Supplier Managements (TSM) näher betrachtet. Dieser beinhaltet folgende Schwerpunkte:

- Gestaltung eines Workflows zur Lieferantenbewertung
- Integration eines Frühwarnsystems mit Hilfe eines Trend- und Prognosemodells
- Kategorisierung von Risiken nach der Workfloworientierung

Zur Einordnung des TSM als Kommunikations-, Kooperations- und Koordinationsmodell wird zunächst der Mehrwert erläutert.

3.1 Ziele und Nutzen des Total Supplier Managements

Zur Erledigung der Aufgaben im Rahmen des Beschaffungsmanagements (Kapitel 2.1) arbeiten verschiedene Fachbereiche zusammen. Jeder dieser Fachbereiche besitzt Schnittstellen zum Lieferanten. Nach BELLMANN sind Schnittstellen dabei „die Konsequenz der Arbeitsteilung, d. h. sie entstehen infolge der Trennung eines ursprünglich ganzheitlichen Prozesses in Teilverrichtungen“ [BEL02]. Bei der Steuerung der externen Wertschöpfungsnetzwerke arbeiten vorrangig die Fachbereiche Einkauf, Logistik, Qualität und Technik (Entwicklung, Konstruktion und Produktion) mit dem Lieferanten zusammen. Es ergeben sich somit Zielkonflikte [GUD05, ARN08a, HEß08, SCH13], die zusammenfassend im Bild 3-1 visualisiert sind.

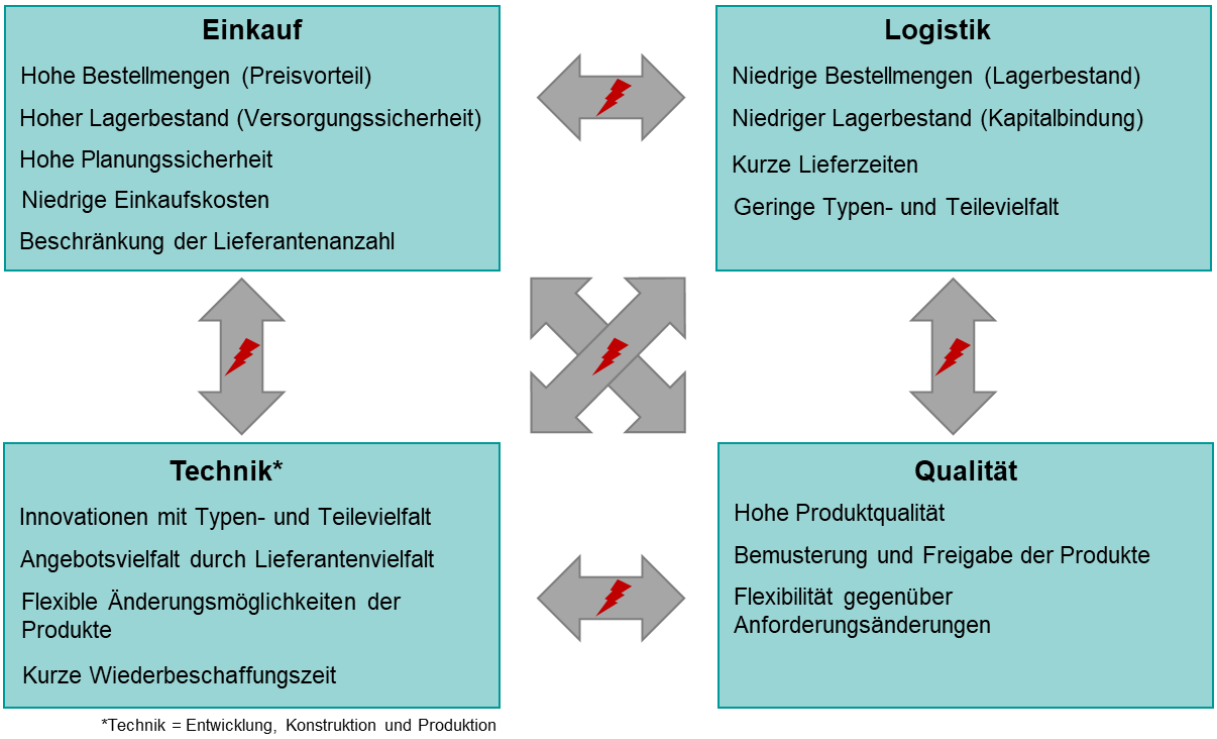


Bild 3-1: Zielkonflikte der Fachbereiche Einkauf, Logistik, Qualität und Technik
Quelle: Eigene Darstellung

Wie das bereits vorgestellte SCM unterstützt auch das TSM durch seine strategische und strukturierte Herangehensweise die Wertschöpfungsnetzwerke bei der Bewältigung der aktuellen Herausforderungen. Ziel eines ganzheitlichen Lieferantenmanagements ist es, Ineffizienzen, die durch die Zielkonflikte der verschiedenen Fachbereiche entstehen [ARN08b], zu beseitigen. Dazu ist ein hohes Maß an Kommunikation, Koordination und Kooperation notwendig. Weiterhin ist ein optimales Ergebnis der Leistungserbringung für das gesamte Unternehmen zu erzielen, um die Wettbewerbsfähigkeit im Wertschöpfungsnetzwerk sicherzustellen [DUS10b]. Somit ist es erforderlich, die Teilziele der Fachbereiche abzustimmen sowie die Unternehmensprozesse neu zu gestalten [ARN08b].

Die bisherigen Unternehmensstrukturen sowie internen und externen Zusammenarbeitsmodelle reichen für die gestiegene externe Leistungserbringung nicht mehr aus. Die Folge daraus ist unter anderem eine geringe Leistungserbringung der Zulieferer [DUS10b]. Mit Hilfe von durchgängigen Organisationsstrukturen, abgestimmten Prozessen sowie Methoden zur Steuerung der externen Leistungserbringung (Bild 3-2) wird die zukünftige Zusammenarbeit im TSM neu ausgerichtet [DUS10b].

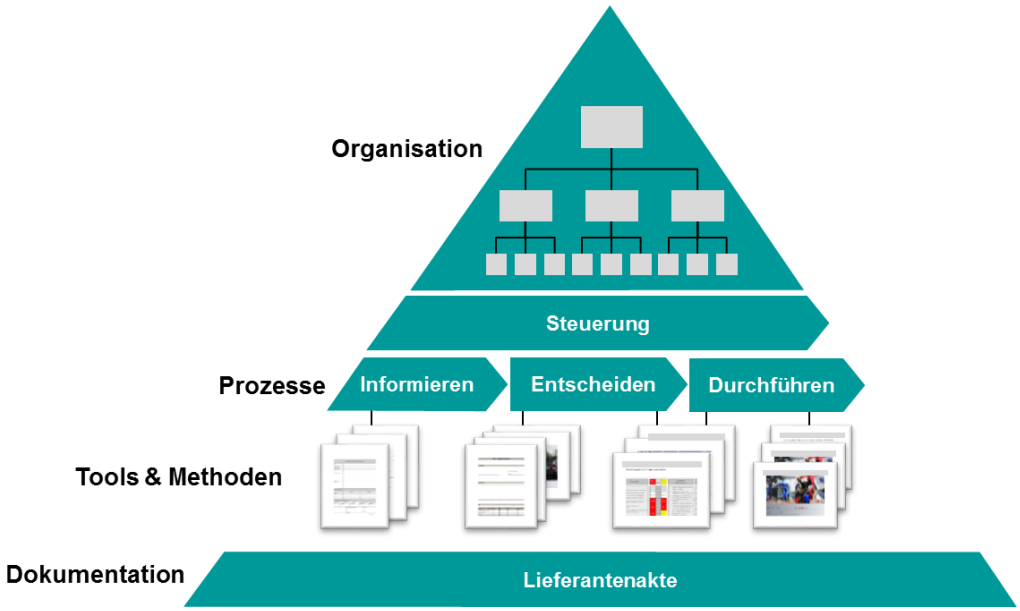


Bild 3-2: Abgrenzung von Organisationsstrukturen, Prozessen und Methoden im TSM
Quelle: [WIL17]

Das TSM-Modell sieht eine zentrale Organisationseinheit im Unternehmen vor. Diese dient der *Koordination* aller Aktivitäten gegenüber den Lieferanten. Maßnahmen, die aufgrund der differenten Zielsetzungen nicht zwischen den Fachbereichen abgestimmt werden, sind zu vermeiden [DUS10a]. Die Prozesse Informieren (Kapitel 3.4.1), Entscheiden (Kapitel 3.4.2) und Durchführen (Kapitel 3.4.3) folgen einem Workflow. Die Standardisierung dieses Workflows führt zu bereichsübergreifend koordinierten Abläufen. Unterstützt werden die Prozesse durch Methoden und IT-Tools zur Wissensgenerierung über die Lieferantenleistung. Zur Dokumentation dient eine bereichsübergreifende Datenbank. Das ganzheitliche Lieferantenmanagement im Sinne eines TSM koordiniert somit die Risiken bei Auswahl, Integration und Steuerung der Lieferanten in einem standardisierten Workflow zwischen den Fachbereichen.

Durch das Modell des TSM werden Informationen, welche die Schnittstelle zwischen dem beschaffenden Unternehmen und Lieferant betreffen, in einem bereichsübergreifenden Steuerkreis (Lieferantensteuerkreis, Kapitel 3.4.2) zwischen den Fachbereichen ausgetauscht. Diese bereichsübergreifende *Kommunikation* dient dem Verständnis über gemeinsame Ziele und damit der Konsensbildung bei Zielkonflikten der Fachbereiche. Das Ziel ist, nach der Maxime „One-face-to-the-supplier“ [DUS10b, SYD15], in der Außenwirkung zum Lieferanten abgestimmt aufzutreten. Die Kommunikation kann jedoch nur auf Grundlage valider und robuster Informationen (Kapitel 3.4.1) erfolgen. HEINRICH UND STELZER stellen dazu die These „ohne Information keine Kommunikation, und ohne Kommunikation keine Information“ [HEI09] auf.

Durch das abgestimmte Auftreten des beschaffenden Unternehmens findet eine interne *Kooperation* zwischen den Fachbereichen statt. Doch nicht nur die Fachbereiche arbeiten durch die gemeinsamen Zielvorstellungen zusammen. Auf der Grundlage des gestuften Eskalationsmodells (Kapitel 3.4.3) findet bei auftretenden Leistungsdefiziten zusätzlich eine gemeinsame und kooperative Lösungsfindung mit dem Lieferanten statt. Dabei können ebenso die internen Prozesse beim beschaffenden Unternehmen optimiert werden. Ein „Lernen vom Lieferanten“ [DUS10b] ist im Sinne eines KVP (Kapitel 3.4.4) wünschenswert.

Aufgrund der zentralen und koordinierenden Organisationseinheit, der bereichsübergreifenden Kommunikation sowie den miteinander kooperierenden Fachbereichen gilt das TSM als Koordinations-, Kommunikations- und Kooperationsmodell (Bild 3-3).

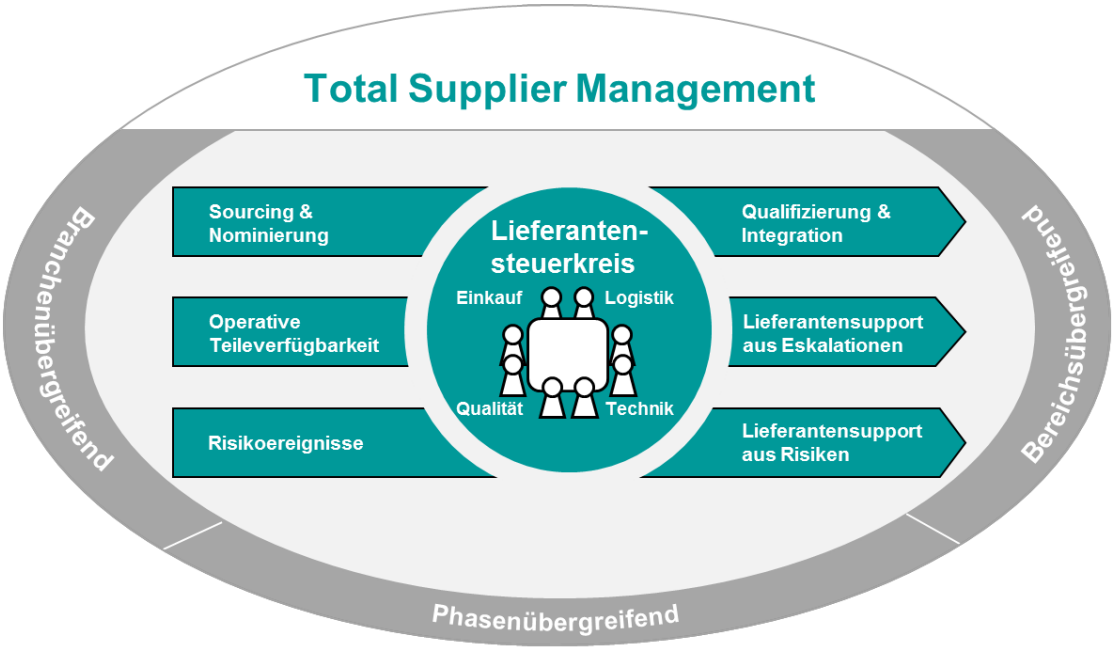


Bild 3-3: Total Supplier Management
Quelle: [DUS10b]

Das bereichs-, phasen-, und technologieübergreifende Modell wird über den gesamten Produktlebenszyklus branchenübergreifend angewendet. Innerhalb der standardisierten Abläufe des TSM-Modells werden die Lieferanten zu Beginn einer Zusammenarbeit systematisch eingebunden, qualifiziert und in die Unternehmensprozesse integriert (Sourcing und Nominierung). Arbeiten Lieferant und Abnehmer bereits zusammen, wird die Leistungserbringung der Lieferanten (operative Teileverfügbarkeit) regelmäßig sowie auftretende Risikoereignisse bei Bedarf überprüft. Ein bereichsübergreifendes Gremium (Lieferantensteuerkreis) beschließt bei sinkender Lieferantenleistung und auftretenden Risikoereignissen ggf. bereichsübergreifende Maßnahmen zur Unterstützung der Fachbereiche Einkauf, Qualität, Logistik und Technik [DUS10b]. Diese Unterstützung der Fachbereiche in ihren operativen Prozessen findet zeitlich begrenzt statt und ohne die Fachbereiche aus der operativen Verantwortung zu entlassen. Sie dient der Koordinierung an den unternehmensinternen und -externen Schnittstellen [WIL17].

Zusammenfassend vermeidet das TSM redundante Prozesse an der Schnittstelle zwischen Lieferant und Abnehmer und steigert somit die Effizienz durch die Optimierung des Ressourceneinsatzes [DUS10c]. Die Unternehmen, die das TSM-Modell implementieren, „zeichnen sich langfristig als wettbewerbsfähiges und auch in einem dynamischen Umfeld robustes Unternehmen aus“ [DUS16d].

3.2 Anforderungsprofil

Ein erfolgreiches, ganzheitliches Lieferantenmanagement im Sinne eines TSM besteht aus zehn Bausteinen (Bild 3-4), die einem standardisierten Workflow (Kapitel 3.4) folgen. Die Aufgaben der einzelnen Bausteine werden nun nach DUST UND WILDE [DUS16d] näher beschrieben.

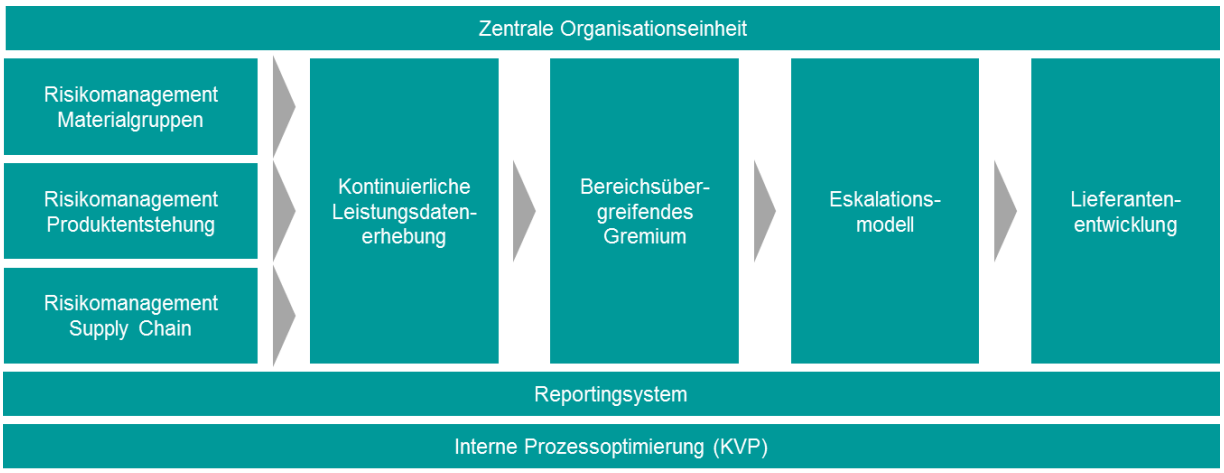


Bild 3-4: Die zehn Bausteine des Total Supplier Managements
Quelle: [DUS16d]

Die Bereitstellung der Standards zur Auswahl, Bewertung und Steuerung der Lieferanten obliegt der *zentralen Organisationseinheit*. Diese steuert auch den Workflow und standardisiert die entsprechenden Prozesse und Methoden im Rahmen des TSM. Zur Steuerung der Lieferantenbasis und den damit verbundenen Risiken ist das Risikomanagement zuständig. Dabei werden drei Gruppen differenziert:

1. das Risikomanagement der Materialgruppen,
2. innerhalb der Produktentstehung und
3. der Supply Chain.

Damit die notwendigen Lieferanten in der Lieferantenbasis vorhanden sind, steuert das *Risikomanagement Materialgruppen* die Lieferantenauswahl. Das *Risikomanagement Produktentstehung* identifiziert hingegen kritische Lieferanten innerhalb der Produktentstehungsphase. Die Überwachung kritischer Risikoereignisse und die Überwachung der Lieferantenleistung während der kontinuierlichen Zusammenarbeit zwischen Lieferant und Abnehmer übernimmt das *Risikomanagement Supply Chain* (Kapitel 3.3.5). Dafür ist eine *kontinuierliche Leistungsdatenerhebung* (Kapitel 3.4.1) auf Basis eines Sensorikmodells zur Bewertung der Lieferantenleistung mit Hilfe einer Trend- und Prognosebetrachtung erforderlich. Liegen die Ergebnisse aus der Lieferantenbewertung vor, beurteilt und interpretiert diese ein *bereichsübergreifendes Gremium* (Kapitel 3.4.2). Das Gremium beschließt dann Maßnahmen zur Sicherstellung bzw. Wiederherstellung der vereinbarten Leistungserbringung und koordiniert die durchzuführenden Aktivitäten bei den Lieferanten. Bei der Maßnahmendefinition unterstützt ein *Eskalationsmodell* (Kapitel 3.4.3). Dieses standardisierte Vorgehen verweist auf geeignete Methoden und IT-Tools für die einzelnen Verbesserungsprojekte bei den Lieferanten. Die standardisierten IT-Tools und Methoden, die im Eskalationsmodell vorgesehen sind, werden inner-

halb der *Lieferantenentwicklungsprojekte* umgesetzt. Ein *Reportingsystem* verfolgt konsequent die Maßnahmenumsetzung. Eine konsolidierte Erfassung aller mangelhaften Prozesse im Unternehmen sowie der zugehörigen Maßnahmendefinition zur Prozessverbesserung findet schließlich durch die *interne Prozessoptimierung* (Kapitel 3.4.4) statt.

Die Wirksamkeit und das Zusammenspiel der Bausteine werden durch die Erfüllung der sechs Qualitätsmerkmale im Lieferantenmanagement des TSM beschrieben (Bild 3-5). Zusammenfassend bestehen dieses aus den folgenden Merkmalen:

- partnerschaftlich,
- bereichsübergreifend,
- präventiv,
- langfristig wirksam,
- standardisiert und
- prozessoptimierend.

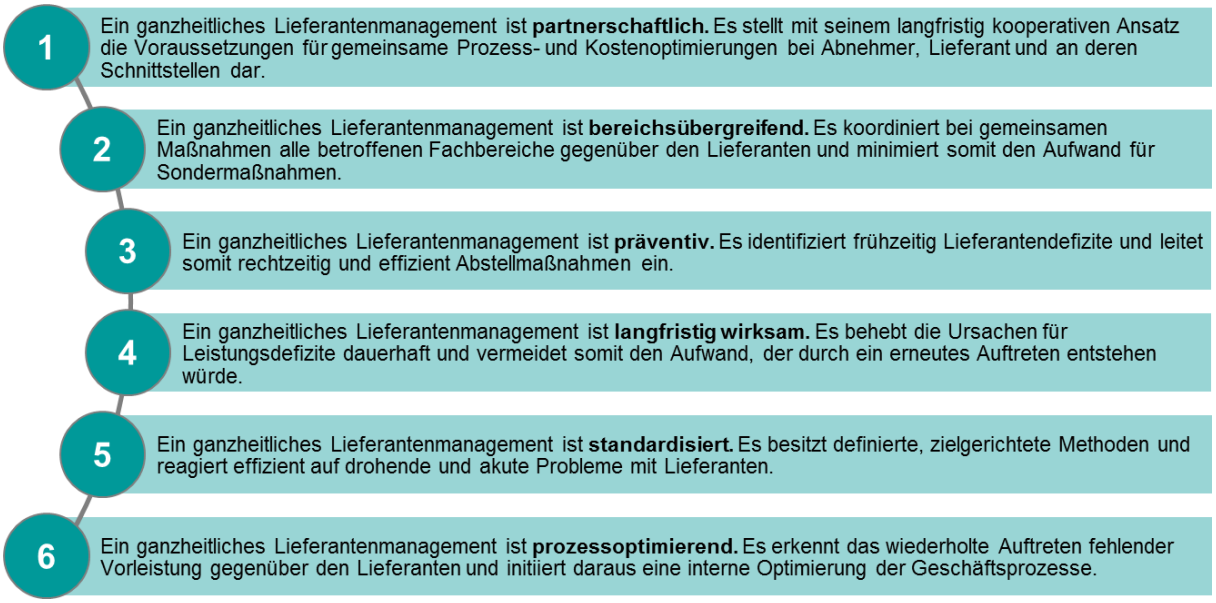


Bild 3-5: Die sechs Qualitätsmerkmale des ganzheitlichen Lieferantenmanagements im TSM
Quelle: [DUS16d]

Die durchgängige Implementierung aller Bausteine mit dem Grundsatz der sechs Qualitätsmerkmale ermöglicht ein effizientes und effektives Lieferantenmanagement [DUS16c]. Die Studie von DUST UND WILDE [DUS16d] zeigt den aktuellen Reifegrad des Lieferantenmanagements anhand der zehn Bausteine in der unternehmerischen Praxis. Der Reifegrad dient der Strukturierung und Bewertung von Prozessen sowie der Identifikation von Verbesserungspotenzialen [HEß15] anhand der zehn Bausteine und der sechs Qualitätsmerkmale.

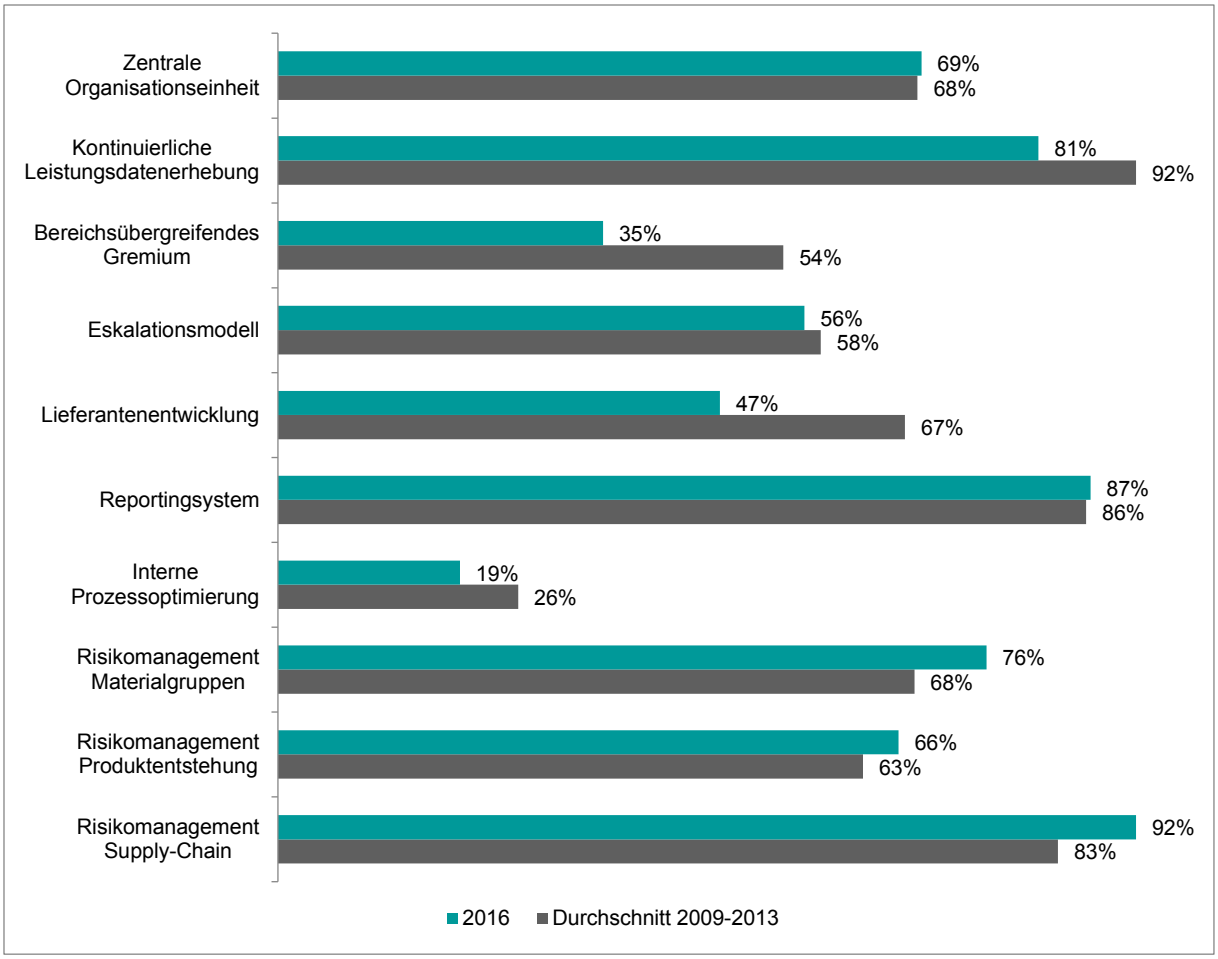


Bild 3-6: Umsetzungsgrad der einzelnen Bausteine im TSM
Quelle: [DUS16d]

Die durchschnittliche Umsetzung aller Bausteine des ganzheitlichen Lieferantenmanagements ist in den Jahren 2009 bis 2016 von 67 Prozent auf 63 Prozent gesunken. Nach Angaben der Studienteilnehmer haben 19 Prozent die Umsetzung der Bausteine abgeschlossen. Der überwiegende Teil der Befragten befindet sich mit 45 Prozent in der Umsetzungsphase [DUS16d]. Der Umsetzungsgrad der für die Bausteine als Basis geltenden Qualitätsmerkmale Prozessoptimierung, Standardisierung sowie der Partnerschaftlichkeit stagnieren laut Studie in ihren Werten [DUS16a]. Doch die Umsetzung der Qualitätsmerkmale einer präventiven, bereichsübergreifenden und langfristig wirksamen Vorgehensweise hat im durchschnittlichen Vergleich zu den vergangenen Jahren abgenommen [DUS16a]. Das lässt die Schlussfolgerung zu, dass einigen der befragten Unternehmen der Mehrwert eines ganzheitlichen Lieferantenmanagements nicht bekannt ist. Auch WAGNER weist in seinen Erkenntnissen darauf hin, dass „Unternehmen häufig weder heute noch in Zukunft in der Lage [sind], dieses Potenzial [des Lieferantenmanagements] zu nutzen“ [WAG01]. Ein Hindernis bei der Umsetzung liegt in den unzureichenden Daten bzw. Informationen für eine Analyse der Lieferantenbasis [WAG01]. Die Daten bzw. Informationen für die Analyse der Lieferantenbasis sind das Ergebnis einer vorgeschalteten differenzierten Risikobetrachtung des externen Wertschöpfungsnetzwerkes.

3.3 Differenzierte Risikokategorisierung

Die wachsende Komplexität der Supply Chain [SYD15] birgt ein hohes Risiko auf vielen Ebenen. Die Globalisierung und steigende Produktvielfalt werden als Haupttreiber der Risiken im externen Wertschöpfungsnetzwerk betrachtet [THU11]. Diese Risiken gilt es in der Lieferantenbewertung mit Hilfe von Kennzahlen zu bewerten. Es stellt sich jedoch die Frage, welche Risiken es überhaupt innerhalb der Supply Chain gibt und wie diese zu beherrschen sind. Um die Unterschiede zwischen den Risiken und den Aufwand für die Beherrschung zu verdeutlichen, wird eine Kategorisierung vorgenommen [SOD12]. Diese Kategorien unterstützen durch die strukturierte Erfassung der Risiken den weiteren Schritt der Lieferantenbewertung [ROM04].

Die Differenzierung von Risikoarten nimmt Bezug auf den Entstehungsort einer Risikoursache [THO08]. Dabei wird allgemein zwischen innerbetrieblichen (endogenen) und außerbetrieblichen (exogenen) Risiken unterschieden [GÖT15]. Die verschiedenen Kategorien sind logisch begrenzte Einheiten, die alle in sich gleiche Eigenschaften aufweisen [ROS75]. Eine Kategorisierung wird in diesem Zusammenhang als Prozess bezeichnet, der durch kognitive Fähigkeiten Ähnlichkeiten in Gruppen zusammenfasst [MED99]. In der Literatur [SPE07, MOD08, SOD12] werden die Begriffe der Risikokategorisierung und -klassifizierung häufig synonym verwendet.

Einen Literaturüberblick über die verschiedenen Ansätze zur Kategorisierung von Risiken bieten MODER [MOD08] sowie JÜTTNER UND MAKLAN [JÜT11]. Im Folgenden wird zunächst auf mögliche Risikokategorisierungsformen, gegliedert nach den Schwerpunkten SCOR, Supply Chain sowie fachlicher und thematischer Betrachtung, eingegangen. Diese Kategorisierungsformen werden dann in einer kritischen Würdigung gegenübergestellt. Da die differenzierte Risikobetrachtung des TSM-Modells die Risikokategorien nicht nach der Entstehungsursache, sondern nach der Weiterverarbeitung im Workflow gliedert, wird diese in Kapitel 3.3.5 gesondert erörtert.

3.3.1 Kategorisierung von Risiken nach SCOR

Das SCOR-Modell dient zur standardisierten Erfassung und Beschreibung von Geschäftsprozessen vom n-tier-Lieferanten bis zum Endkunden [SUP08]. SCOR repräsentiert ein Geschäftsprozess-Referenzmodell, das eine idealtypische Supply Chain darstellt. Die zugehörigen Anforderungen an ein Referenzmodell werden detailliert in den Ausführungen von HERTEL [HER11] beschrieben.

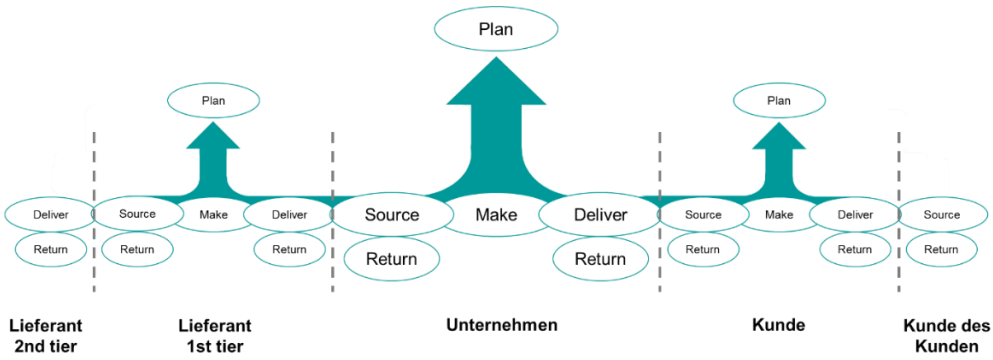


Bild 3-7: SCOR-Modell
Quelle: Eigene Darstellung in Anlehnung an [SUP08]

Das Ziel des SCOR-Modells ist es, die externe Wertschöpfung zu analysieren, um die Schwachstellen im Prozess zu identifizieren. Zur Gewährleistung der Leistungssteigerung oder -absicherung werden Maßnahmen definiert. Somit werden Aspekte der Geschäftsprozess-Optimierung und des Leistungskennzahlenvergleichs in ein Bezugssystem integriert [BOL07].

Auf der obersten hierarchischen Prozessebene werden die einzelnen Prozessschritte, wie Planen, Beschaffen, Herstellen, Liefern und Entsorgen, gegliedert [POL07]. Die Prozessschritte helfen dabei, die identifizierten Risiken zu kategorisieren und zu gruppieren. Die Prozessebenen der Konfiguration, Gestaltung und Implementierung dienen der weiteren Differenzierung einzelner Prozesselemente. Eine umfangreiche Darstellung der Prozessebenen sind in EßIG ET AL. [EßI13] zu finden. Das modellierte Wertschöpfungsnetzwerk erstreckt sich vom 2nd-tier hin zum Endkunden.

Als zentraler Mehrwert des SCOR-Modells gilt laut EßIG ET AL. „die direkte Nähe zu den Bezugspunkten des SCM (Beschaffung, Produktion und Distribution) sowie die Praxisorientierung“ [EßI13]. Ein Abgleich der Unternehmensstrategie, der Material- und Informationsflüsse sowie der Arbeitsabläufe ist innerhalb des Modells gewährleistet [BOL07]. WERNER [WER17] kritisiert jedoch, dass das Modell einen hohen Abstraktionsgrad aufgrund der generischen und branchenübergreifenden Betrachtung hat.

Das SCOR-Modell ist mit einer kurzfristigen Perspektive eher taktisch ausgerichtet [BOL07]. Die Kategorisierung des SCOR-Modells deckt die klassischen Supply-Chain Risiken des Risikoportfolios innerhalb einer Wertschöpfungskette, jedoch nicht innerhalb eines Wertschöpfungsnetzwerks ab. Da sich das Modell auf eine reine Deskription der Supply Chain-Prozesse beschränkt, wird auf entscheidungsunterstützende Aussagen verzichtet [EßI13].

Plötzlich eintretende Risikoereignisse, die nicht die Ursache im Wertschöpfungsnetzwerk haben, finden in diesem Modell keine Beachtung. Demnach werden beispielsweise Naturkatastrophen, politische Unruhen oder Terroranschläge nicht berücksichtigt. Diese Risiken sind nicht beeinflussbar. Eine Betrachtung im Vorfeld kann vorteilhaft sein und sollte angestrebt werden, um ggf. durch standardisierte Abläufe die Reaktionszeit zu reduzieren [LIE16].

Das SCOR-Modell befindet sich laut POLUHA [POL07] in einem evolutionären Zustand. Dies birgt ein hohes Maß an Planungsunsicherheit, da heutige Elemente in der Zukunft ihre Gültigkeit verlieren könnten. Die Treiber dafür sind neue Geschäftsmodelle oder auch die zunehmende Digitalisierung der Geschäftsprozesse. Somit muss sich die Wertschöpfungskette im SCOR-Modell zu einem Wertschöpfungsnetzwerk weiter entwickeln.

3.3.2 Kategorisierung nach Risiken entlang der Supply Chain

Wie beim SCOR-Modell grenzen auch SODHI UND TANG [SOD12] ihr Risikokategorisierungsmodell im Prozess der Supply Chain ab. Somit können die Beschaffungs-, Prozess-, und Bedarfsrisiken dem jeweiligen Prozess, der am besten auf die Risiken präventiv oder beherrschend einwirken kann, in der Supply Chain zugeordnet werden. Zusätzlich werden gesellschaftliche Risiken, wie politische Entscheidungen oder Währungsschwankungen, betrachtet. Davon ausgehend sind vier Hauptrisikoklassen definiert: Gesellschaftsrisiken, Beschaffungsrisiken, Prozessrisiken und Bedarfsrisiken.

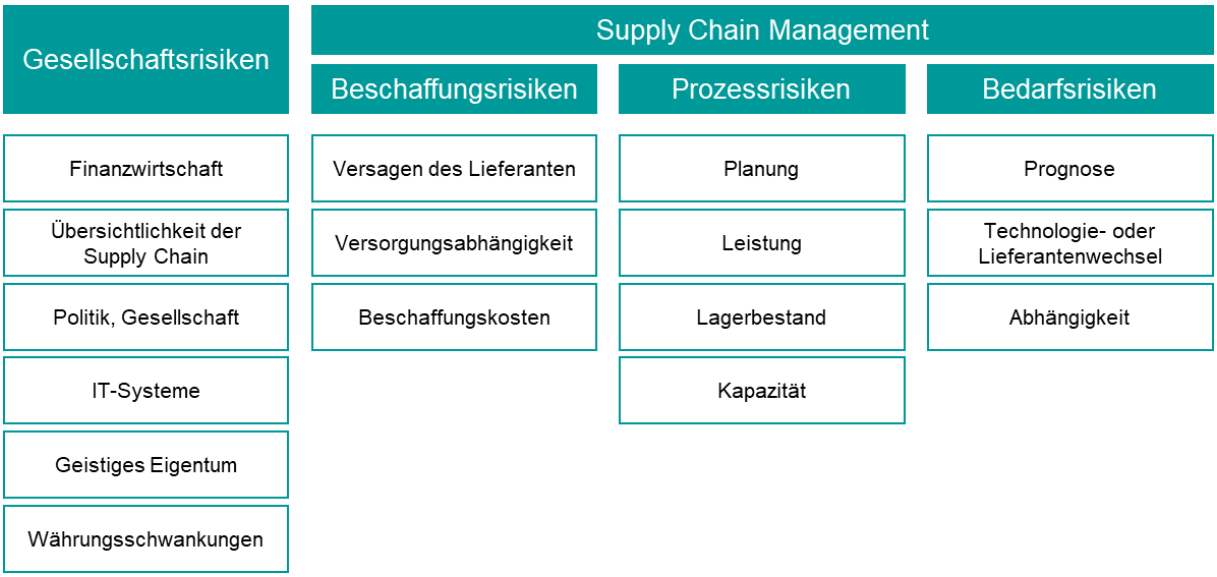


Bild 3-8: Risikokategorisierung in der Supply Chain nach SODHI UND TANG
Quelle: Eigene Darstellung in Anlehnung an [SOD12]

Gesellschaftsrisiken betreffen die gesamte SC und somit jedes Unternehmen. Im Hinblick auf diese Risiken müssen die Unternehmen ihre Aktivitäten zentralisiert koordinieren, um diese zu steuern [SOD12]. *Beschaffungsrisiken* beziehen sich auf die Verfügbarkeit und die Qualität des jeweils zu beschaffenden Gutes, welches ein Unternehmen für seine weitere Wertschöpfung oder Leistungserbringung benötigt [SUC16b]. Im Gegensatz zu SODHI UND TANG [SOD12] (Bild 3-8) differenziert SUCKY [SUC16a] die Beschaffungsrisiken in fünf Subrisikokategorien:

- Qualitätsrisiko: Abweichung zwischen der gelieferten Qualität und den vereinbarten Anforderungen.
- Mengenrisiko: Abweichung zwischen benötigter Menge und gelieferter Menge des zu beschaffenden Gutes
- Terminrisiko: Abweichung vom tatsächlichen Liefertermin zum geplanten Liefertermin
- Preisrisiko: Abweichung zwischen tatsächlichem Preis und erwartetem Preis für das zu beschaffende Gut
- Transportrisiko: Zerstörung oder Beschädigung des zu beschaffenden Gutes beim Transport

Die *Prozessrisiken* richten sich nach den Abläufen und Prozessen innerhalb der Organisation in Bezug auf Entwicklung, Fertigung und Vertrieb [SOD12]. *Bedarfsrisiken* bilden den höchsten Unsicherheitsfaktor in der Supply Chain. Der Bedarf des Kunden und der Absatz eines Unternehmens sollten ausgewogen sein. Um Absatzschwankungen zu verringern, sollten Unternehmen ihre Produkte auf verschiedenen Märkten und Ländern verkaufen [SOD12].

Bei der Zuordnung der Risiken entlang der Supply Chain entstehen folglich Haupt- und Subkategorien. Eine Hauptkategorie zeichnet sich durch eine Zuordnung von Einzelrisiken aus [ROM09]. Zu jeder dieser Hauptkategorien können sich Notwendigkeiten eines Handelns im Falle des Eintretens eines Risikos ergeben [SAR19]. Subkategorien sind in diesem Zusammenhang weitere Unterteilungen einer Hauptkategorie, wie beispielsweise in Bild 3-8 die *Beschaffungskosten* als Subkategorie der Hauptkategorie *Beschaffungsrisiken* zugeordnet wird.

Ähnlich wie das Modell von SODHI UND TANG [SOD12] kategorisiert das Modell nach CHRISTOPHER UND PECK [CHR04] die identifizierten Risiken in vier Hauptkategorien.

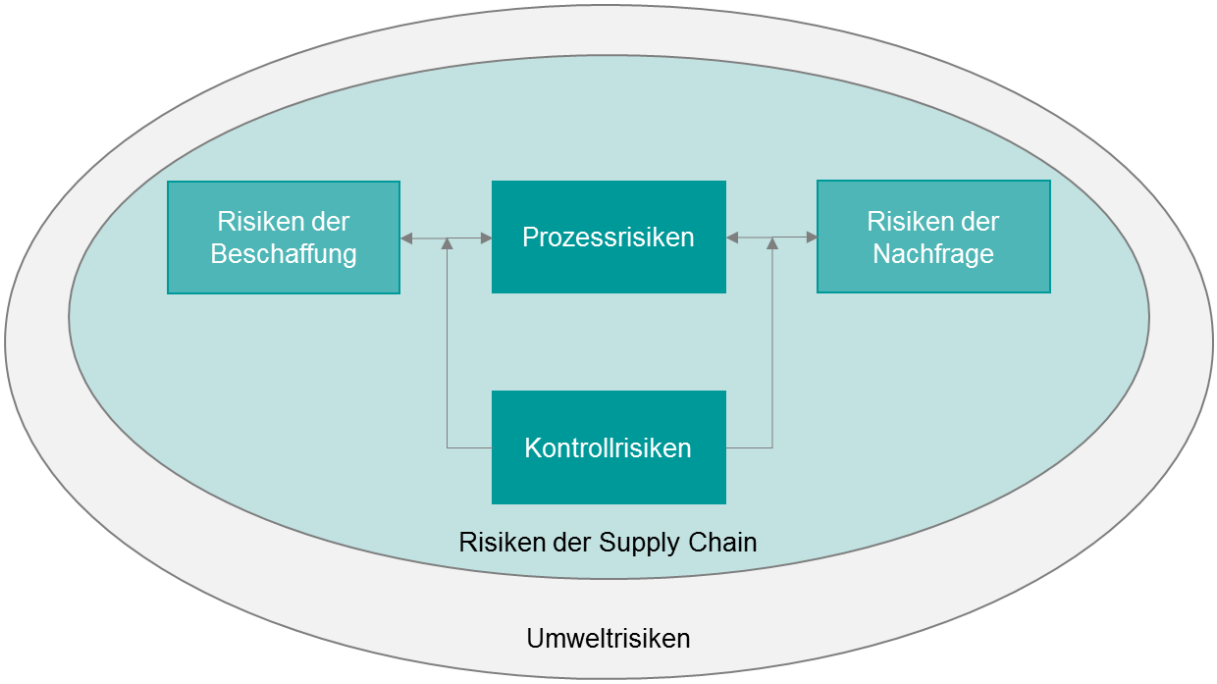


Bild 3-9: Risikokategorisierung in der Supply Chain nach CHRISTOPHER UND PECK
Quelle: Eigene Darstellung in Anlehnung an [CHR04, SUC16b]

Prozess- und Kontrollrisiken werden den *internen Risiken einer Organisation* zugeschrieben. Die Prozessrisiken richten sich, wie bei SODHI UND TANG [SOD12], nach den Abläufen und Prozessen innerhalb der Organisation. CHRISTOPHER UND PECK [CHR04] stellen jedoch in ihrem Modell die Kommunikation mit den involvierten Fachbereichen und Lieferanten in den Vordergrund. Die Kontrollrisiken sind auf der Ebene der Unternehmensstrategie und Führung einer Organisation. Sie beinhalten Richtlinien, Vorgaben, Personaleinsatz und gesetzliche Rahmenbedingungen. *Externe Risiken in Bezug auf die Organisation*, die aber dennoch als interne Risiken für die Supply Chain gelten, definieren die Autoren [CHR04] als Risiken der Beschaffung und der Nachfrage. Die Beschaffungsrisiken beinhalten Risiken entlang der Beschaffung und Bereitstellung des vom Lieferanten hergestellten Gutes. Unter den Nachfragerisiken werden generelle Probleme durch den Absatz, beispielsweise Imageprobleme, oder auch Transport- und Lagerrisiken [STE09] verstanden. Als Überbegriff fungieren die Umweltrisiken. Diese sind in Bezug zur Supply Chain *externe Risiken*. Sie sind nicht vorhersehbar und müssen akzeptiert werden. Zu Umweltrisiken werden beispielsweise Naturkatastrophen, Terroranschläge oder politische Veränderungen gezählt [CHR04]. Die Cluster des Modells sind eindeutig beschrieben und erlauben eine exakte Zuordnung der Risiken. Demnach sind alle z.B. Umwelt- und SC-Risiken durch die Cluster Beschaffung, Prozess und Nachfrage abgedeckt [GÜR13]. Diese Kategorisierung ist in der Literatur am häufigsten vertreten [STE09].

TANG UND TOMLIN [TAN08] setzen sich mit einer reduzierten Einordnung in Beschaffungs-, Prozess- und Nachfragerisiken auseinander. Für ihre Betrachtung der Beschaffungsrisiken gliedern die Autoren diese in Kosten-, Qualitäts- und Kommitment-Subrisiken. Risiken des Prozesses werden mit Qualität, Zeit und Kapazitätsengpässen verbunden. Auf Unsicherheiten bei der Nachfrage gehen die Autoren nicht ein.

Im Modell von ROMEIKE UND HAGER [ROM09] werden die Risiken durch endogene (z. B. Prozessrisiken) sowie exogene (z. B. Umfeldrisiken) Ereignisse verschuldet. Sie sind somit Auslöser einer Störung auf Organisationsebene. Die Umfeldrisiken von ROMEIKE UND HAGER [ROM09] sind analog zu den Umweltrisiken von CHRISTOPHER UND PECK [CHR04] zu verstehen. Auch die Prozess- und Steuerungsrisiken (Kontrollrisiken bei CHRISTOPHER UND PECK [CHR04]) haben die gleichen Eigenschaften. Somit ist die Klassifizierung der Risiken in der Supply Chain nach ROMEIKE UND HAGER [ROM09] (Bild 3-10) ähnlich der von CHRISTOPHER UND PECK [CHR04] (Bild 3-9).

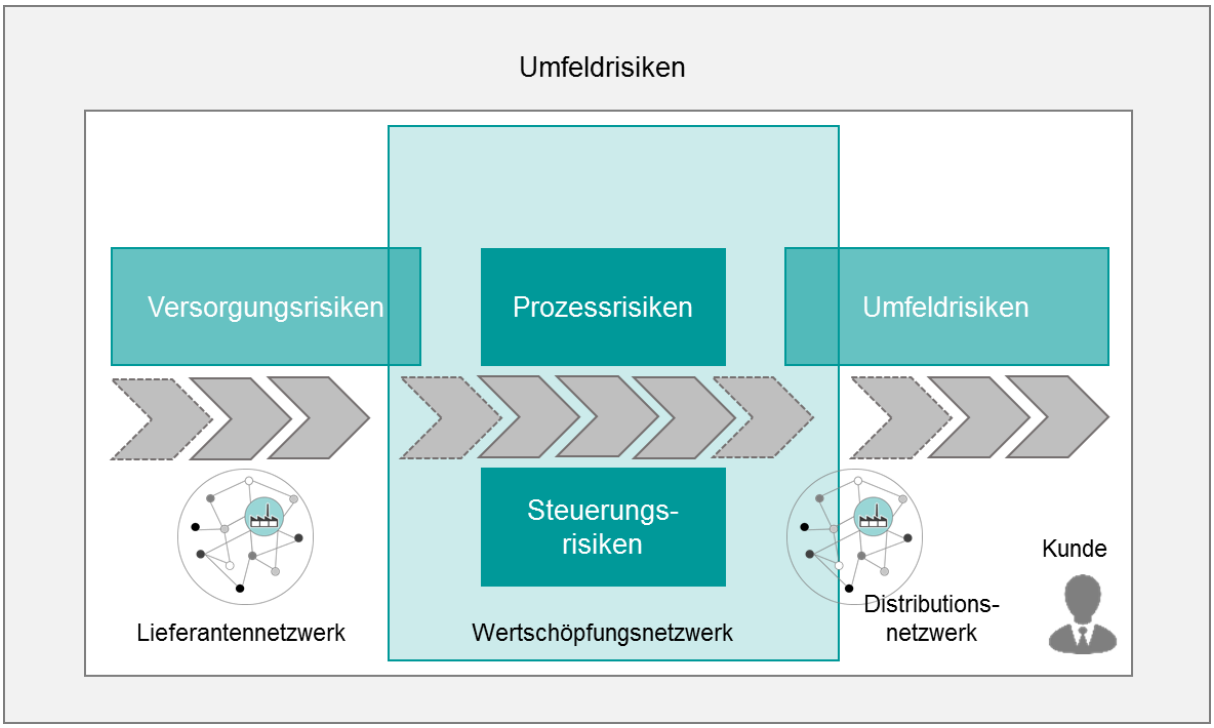


Bild 3-10: Risikokategorisierung in der Supply Chain nach ROMEIKE UND HAGER
Quelle: Eigene Darstellung in Anlehnung an [ROM09]

Zusammenfassend ähneln sich alle in Kapitel 3.3.2 beschriebenen Modelle. Lediglich in der Wortwahl sowie in der Zuordnung der Risiken zu den jeweiligen Haupt- und Subkategorien gibt es leichte Unterschiede.

3.3.3 Kategorisierung nach der fachlichen und thematischen Orientierung

SPECHT ET AL. [SPE07] gehen in ihrem Risikomanagementansatz in technologieorientierten Beschaffungsnetzwerken von den typischen Risiken in der Beschaffung aus. Sie weisen dabei beispielsweise auf das Bedarfsdeckungsrisiko, das Lieferrisiko, das Transportrisiko und das Lagerrisiko hin. Um jedoch eine systematische Erfassung der wesentlichen Risiken zu gewährleisten, beziehen sie sich auf das Risikoprofil von MATZENBACHER ET AL. [MAT99] (Bild 3-11). Dieses Risikoprofil beinhaltet Risikokategorien, denen Risikofelder zugeordnet werden. Dadurch wird eine systematische Aufschlüsselung der identifizierten Risiken gewährleistet. Ein weiterer Punkt ist die Betrachtung von Netzwerkrisiken innerhalb der Supply Chain. Dabei werden die Lieferantennetzwerke analysiert und die Risiken anhand des Lieferantenwettbewerbs untereinander verglichen. Ein möglicher Know-how-Verlust durch Outsourcing muss dabei berücksichtigt werden [GÖP16].

Externe Risiken	Finanzwirtschaftliche Risiken	Leistungswirtschaftliche Risiken	Risiken aus Management und Organisation
Gesetzliche Bedingungen	Währung	Beschaffungsmarkt	Qualität des Personals
Politische Vorgaben	Liquidität	Technik	Kommunikation

Bild 3-11: Risikokategorisierung in der Supply Chain nach MATZENBACHER ET AL.
Quelle: Eigene Darstellung in Anlehnung an [SPE07] mit Verweis auf [MAT99]

Ein zusätzlicher Bestandteil des Modells ist die *finanzwirtschaftliche Kategorisierung*. Ebenso wie ROMEIKE [ROM05] betrachten auch MATZENBACHER ET AL. [MAT99] finanzielle Risiken für das beschaffende Unternehmen.

HOFFMANN UND ROLAND [HOF13] haben eine Zusammenfassung aus verschiedenen Best-Practice Studien zum Thema Haupt- und Subkategorien zur Risikobetrachtung erstellt. Dabei sind die am Häufigsten genannten Risiken in der Supply Chain untersucht worden. Als Ergebnis der Analyse ergeben sich folgende Kategorien: Umweltrisiken, Finanzielle Risiken, Operative Risiken sowie Strategische Risiken.

Supply Risk			
Umweltrisiken	Verhaltensrisiken		
	Finanzielle Risiken	Operative Risiken	Strategische Risiken
Allgemeines Problem	Liquiditätsproblem	Kompetenzproblem	Präferenzproblem
Naturkatastrophen	Insolvenz	Qualitätsmängel	Opportunistisches Verhalten
Streik	Zahlungsschwierigkeiten	Zeitliche Verzögerung	Fehlende Präferenz
Preiserhöhung (Rohstoffe)	Sinkende Auftragslage	Lieferausfall	Abhängigkeit
Zugriff auf Rohstoffe	Einseitige Unternehmensstruktur	Kommunikation	Mitarbeiterwechsel
Allgemeine Preiserhöhung	Veränderung von Rating	Beschaffungslogistik des Lieferanten	Produktionskapazität
Währungsschwankungen	Kreditwürdigkeit	Fertigungskompetenz	
	M&A beim Lieferant		

M&A = Mergers & Acquisitions

Bild 3-12: Risikokategorisierung in der Supply Chain nach HOFFMANN UND ROLAND
Quelle: Eigene Darstellung in Anlehnung an [HOF13]

Das *Verhalten* in der Lieferanten-Abnehmer-Beziehung wird durch die Klassen der finanziellen, operativen und strategischen Risiken charakterisiert. Das Eintreten bzw. die Ursachen dieser Risiken sind durch den Abnehmer bzw. den Lieferanten direkt beeinflussbar. *Umweltrisiken* sind hingegen nicht beinflussbar. Die Bedeutung der einzelnen Risikoklassen hängt von der jeweiligen Eintrittswahrscheinlichkeit ab [HOF13]. Die Abhandlung lässt jedoch keine Rückschlüsse darauf zu, wie die Bedeutung ausgedrückt wird.

3.3.4 Zwischenfazit zu den diskutierten Kategorisierungsmodellen

Die bisher behandelten, wissenschaftlich publizierten Risikomodelle werden zur Übersicht in einem Zwischenfazit kritisch gewürdigt. Im Kontext der unternehmerischen Risiken sowie der Supply Chain widmen sich die Kategorisierungsmodelle der Einordnung von Risiken auf Basis der Risikoursache [ROM04, SCH15b].

Die Literatur ist in ihren Ausführungen zur Risikokategorisierung teilweise different (Kapitel 3.3.1 bis Kapitel 3.3.3). „Die Abgrenzung zwischen den einzelnen Risikokategorien ist aufgrund der Vielschichtigkeit und Komplexität häufig nicht unproblematisch“ [ROM05]. Die Unterteilung der Haupt- in Subkategorien macht die Modelle beliebig komplex. Abhandlungen oder Ausführungen über die Herkunft der zu betrachtenden Risiken sind in der Literatur nicht enthalten.

„Doch um Risiken zu beherrschen, muss man sie kennen“ [EBE13] betont EBERT. Mit dem Erkennen eines Risikos verbindet der Autor die Identifizierung eines möglichen Schadensfalls. Nicht jedes Unternehmen ist den gleichen Risiken ausgesetzt. Die Anwendung der Kategorien kann individuell variieren [SOD12, SCH15b]. Somit ist es notwendig, dass auch die Risikokategorien nicht wahllos, sondern strukturiert betrachtet und ausgewählt werden [SOD12]. Es ist möglich, Risiken aus der Vergangenheit auf Relevanz für die aktuelle und zukünftige Gestaltung der Wertschöpfungsnetzwerke zu analysieren. Diese identifizierten Risiken werden als historisch hergeleitete Risiken bezeichnet. Sinnvoll ist somit eine Identifizierung der zu betrachtenden Risiken aus 80 Prozent historisch hergeleiteter, unternehmensspezifischer Ereignisse [DUS14] und zu 20 Prozent eine Identifizierung zukünftiger, hypothetischer Risikoszenarien (Bild 3-13).

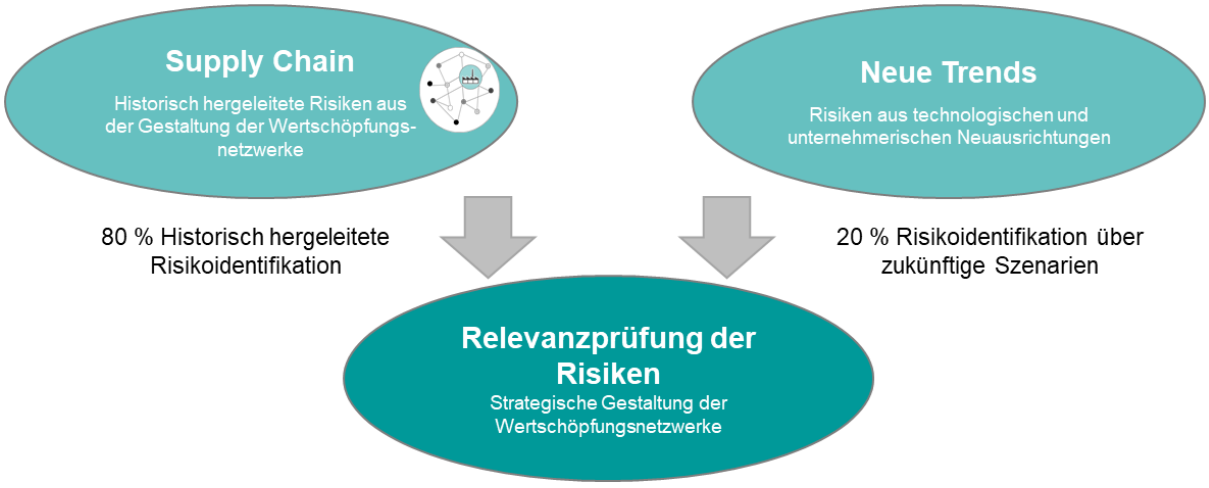


Bild 3-13: Risikoidentifizierung
Quelle: Eigene Darstellung

Werden Aussagen zur weiteren Handhabung der Modelle benötigt, verweisen die Autoren ROMEIKE [ROM05] sowie SPECHT UND MIEKE [SPE07] auf den nächsten Schritt der Risikobewertung mit Hilfe klassischer (Lieferanten-)Bewertungsverfahren bzw. dem Risikomanagementprozess [SCH15b]. Die Kategorisierung und die Bewertung der Risiken scheinen jedoch keinen verbindenden Workflow aufzuweisen. Auch im Risikomanagementprozess der ISO 31000 [ISO31000] ist keine Verbindung zur Risikokategorisierung enthalten. Somit stehen konkrete Aussagen zur Weiterverarbeitung der Risikokategorien innerhalb eines Prozesses noch aus [SOD12].

3.3.5 Kategorisierung von Risiken nach der Workfloworientierung im TSM

Im TSM ist die differenzierte Risikobetrachtung nach dem Umgang mit den identifizierten Risiken ein wichtiger Bestandteil. Diese systematische Art der Einteilung der Risiken erlaubt nach der Weiterverarbeitung im Sinne eines Workflows ein ganzheitliches und effizienteres Vorgehen.

Zunächst werden die Risiken, wie in Bild 3-13 beschrieben, identifiziert. Zur Einteilung werden alle Risiken in drei Haupt- und zwei Nebenkategorien entlang der Supply Chain und des Produktlebenszyklus eingeordnet [DUS14] (Bild 3-14). Die Hauptkategorisierung der Risiken erfolgt in statische, operative und dynamische Risiken.

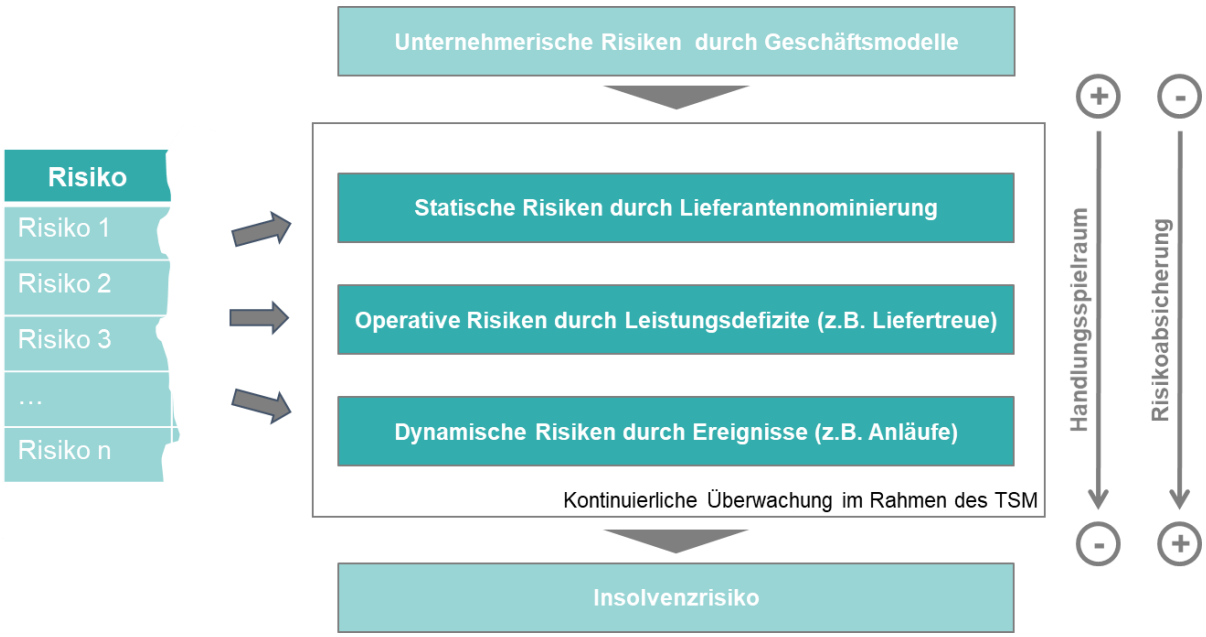


Bild 3-14: Risikokategorisierung im Total Supplier Management
Quelle: Eigene Darstellung in Anlehnung an [WIL17]

Statische Risiken werden bereits bei der Lieferantennominierung und -auswahl berücksichtigt [DUS14]. Zu einem statischen Risiko zählt beispielsweise der Produktionsstandort des Lieferanten. So ist das Risiko insbesondere bei Standorten in Erdbebengebieten hoch. Das beschaffende Unternehmen muss vor Beginn einer Geschäftsbeziehung entscheiden, ob es das Risiko eingeht oder das Risiko nicht akzeptiert. Beim Eintritt des Risikos sollte ein standardisiertes Vorgehen vorhanden sein, um den Schaden so gering wie möglich zu halten. Ein statisches Risiko bedarf keiner kontinuierlichen Überprüfung [DUS14].

Als *operative Risiken* werden tägliche Unsicherheiten verstanden, die eine kurzfristige Beherrschung benötigen [EBE13]. Diese haben unter anderem Einfluss auf Termine, Kosten sowie Qualität des Produktes oder der Dienstleistung. Die Zulieferer werden einer kontinuierlichen Leistungskontrolle durch eine gestufte Lieferantenbewertung (Kapitel 3.4.1) unterzogen [DUS14].

Geplante (z. B. Anläufe), absehbare (z. B. Engpässe oder Streiks) und unerwartete Ereignisse (z. B. Brand) werden zu *dynamischen Risiken* oder auch Risikoereignissen gezählt [DUS14]. Unter Risikoereignissen werden allgemein ungeplante und unvorhergesehene Vorfälle verstanden [SVE00, GÜR13]. Diese können die Wertschöpfung empfindlich stören oder sogar zeitweise beenden [GÜR13]. Für jede dieser drei Subkategorien werden bei Eintritt des Risikos

verschiedene Strategien angewendet. Geplante Ereignisse werden mit Hilfe eines standardisierten Risikokatalogs nach Wahrscheinlichkeit des Eintretens und der Bedeutung des Risikos für das Unternehmen beurteilt. Bei absehbaren Ereignissen werden aussagefähige Indikatoren zur Beurteilung der Risiken ausgewählt. Eine Risikobeherrschung mit Hilfe von Kapazitäten und Expertise wird durch standardisierte Abläufe bei unerwarteten Ereignissen angestrebt [LIE16].

Sind die Risiken den drei Kategorien zugeordnet, werden sie in den weiteren Workflow des TSM-Modells integriert (Bild 3-15). Je nach Risikoart werden die Informationen zusammengetragen, sodass der bereichsübergreifende Lieferantensteuerkreis entsprechende Maßnahmen zur Umsetzung beschließen kann.

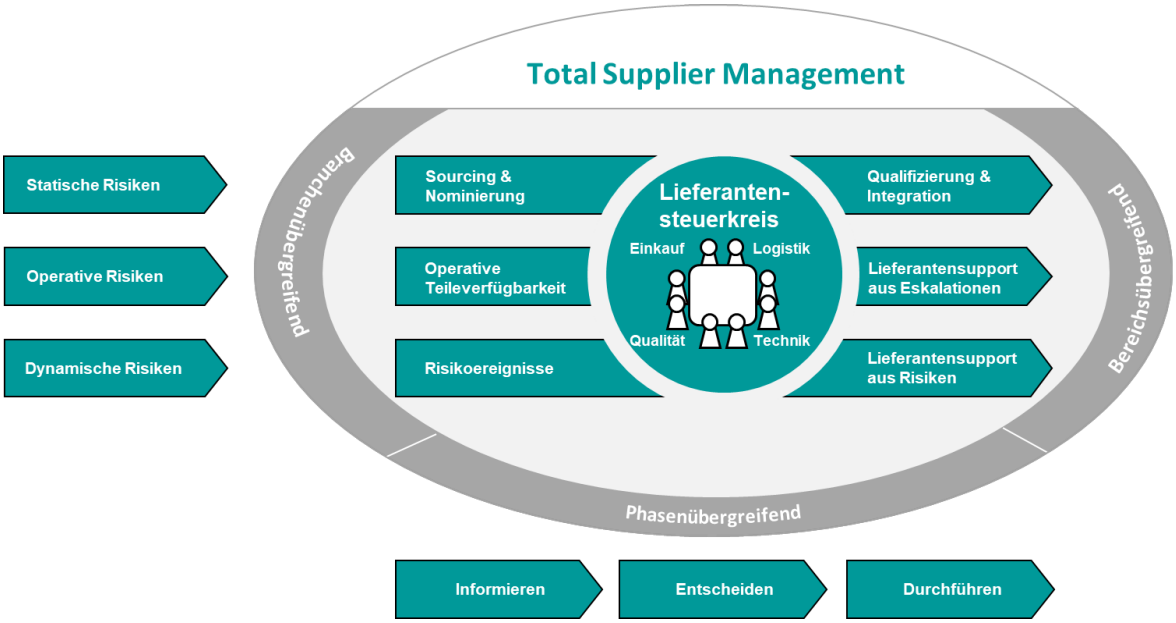


Bild 3-15: Integration der differenzierten Risiken im TSM-Modell
Quelle: [DUS10b]

Durch die Einbindung der Risikokategorisierung in den Workflow des TSM-Modells können die Risiken nun direkt im Prozess weiter betrachtet werden. Somit erlaubt erst eine differenzierte Betrachtung des Umgangs mit den jeweiligen Risiken „eine vollständige Erfassung, transparente Bewertung und effiziente Steuerung der relevanten Risiken der Supply Chain“ [DUS14] und trägt damit zur Steuerung und Leistungsverbesserung der gesamten Lieferantenbasis bei.

3.4 Workflow im Total Supplier Management

Die Prozesse im TSM folgen einem standardisierten Workflow. Allgemein wird unter einem Workflow die Trennung zwischen Steuerung und Durchführung von Aufgaben innerhalb eines Aufgabenlösungsverfahrens verstanden [ARN08b]. Beginnend mit der Informationsbeschaffung, übergehend zur Handlungsentscheidung und hin zur Durchführung der festgelegten Maßnahmen [DUS16d] sichert dieses standardisierte Vorgehen im TSM die Leistungserbringung der externen Wertschöpfung durch die Lieferanten ab. Für eine nachhaltige Unternehmensentwicklung wird der Workflow des TSM mit dem Lessons Learned-Prozess im Sinne eines kontinuierlichen Verbesserungsprozesses verbunden.



Bild 3-16: Workflow des Total Supplier Management
Quelle: Eigene Darstellung

Im weiteren Verlauf des Kapitels wird nun auf die einzelnen Schritte

- Informieren,
- Entscheiden,
- Durchführen und
- Lessons Learned eingegangen.

Diese entsprechen dem TSM-Workflow nach DUST UND SCHNEIDER [DUS10b]. Sofern nicht anders ausgewiesen, wird sich in diesem Kapitel zusammenfassend auf die Publikationen von DUST und seinen Co-Autoren [DUS10b, DUS10c, DUS10a, DUS11, DUS13, DUS14, DUS16a, DUS16c, DUS16d, DUS16e, DUS16f, DUS18] bezogen.

3.4.1 Informieren

Zunächst beginnt der arbeitsteilige Prozess mit einer präventiven Risikoerkennung innerhalb der gesamten Lieferantenbasis. Das Ziel ist es, möglichst frühzeitig viele Informationen zur Identifikation von kritischen Lieferanten zu erhalten. Werden die Leistungsdefizite frühzeitig erkannt, ist der Aufwand für die Wiederherstellung der Lieferantenleistung geringer. Um diese Informationen zu erhalten, werden an das präventive Risikomanagement vier Anforderungen definiert, die im Folgenden näher betrachtet werden:

1. Bewertung aller Lieferanten (Gestuftes Vorgehen zur Effizienzsteigerung)
2. Prävention (Nutzung des Trend- und Prognosemodells)
3. Vollständigkeit (Einbindung von Hard- und Softfacts)
4. Prozessorientierung (Bewertung der Leistungsfähigkeit aller Lieferanten)

Der Ansatz eines *gestuften Vorgehens* innerhalb der Lieferantenbewertung (Bild 3-17) basiert auf Einzelbewertungen der Fachbereiche, welche über ein gestuftes Bewertungsmodell zu bereichsübergreifenden Aussagen konsolidiert werden. Der Einsatz von Kennzahlen, Prognosen und Softfacts ermöglicht eine effiziente Anwendung durch die systematische Filterung der kritischen Lieferanten (siehe hierzu „Risikofilter im Lieferantenmanagement“ in Kapitel 2.2.2) in drei aufeinander aufbauenden Stufen. „In allen Stufen werden lieferantenspezifische, anforderungsgerechte und entscheidungsrelevante Informationen zur Verfügung gestellt“ [DUS18].

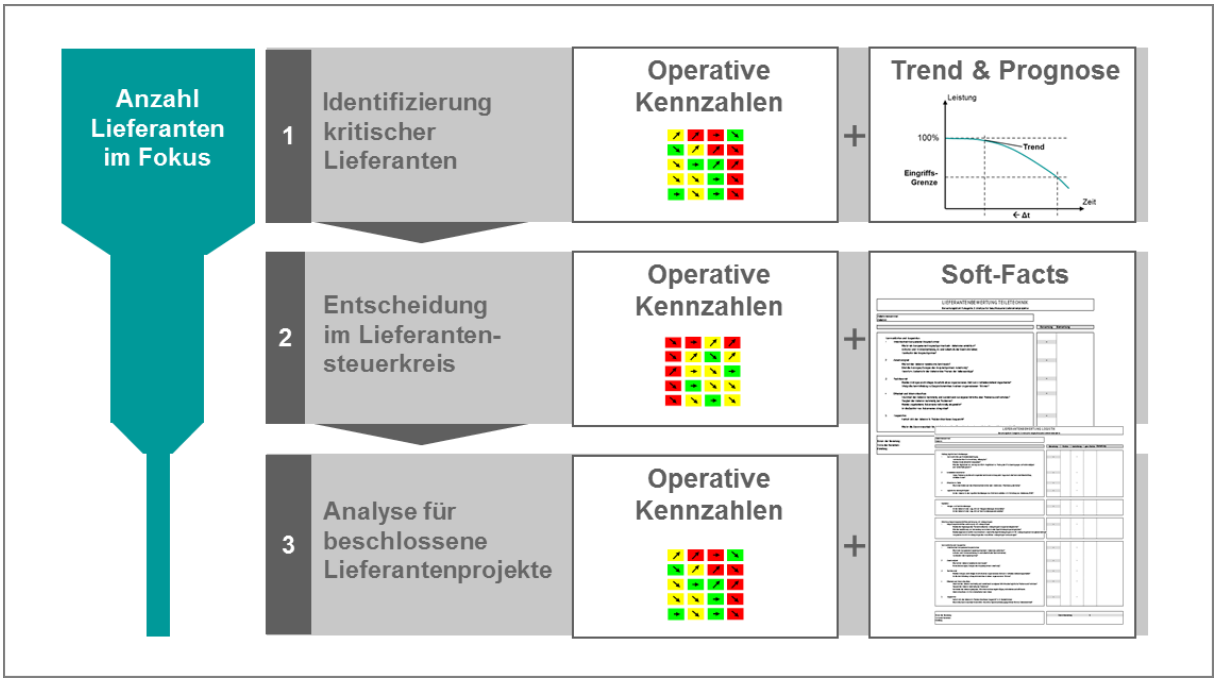


Bild 3-17: Gestufte Lieferantenbewertung
Quelle: [DUS15]

Alle Lieferanten durchlaufen ein dreistufiges Bewertungs- und Kennzahlenmodell. Dabei wird die Anzahl der zu betrachtenden Lieferanten, von Stufe zu Stufe, reduziert. Während in der ersten Stufe noch alle aktiven Zulieferer der Lieferantenbasis eines Unternehmens durch wenige, aber aussagefähige Kennzahlen analysiert werden, reduziert sich die Anzahl der Zulieferer und somit der Analyseaufwand in der zweiten und dritten Stufe [DUS15].

1. Stufe:

- Identifikation auffälliger und somit möglicher kritischer Lieferanten mithilfe des *Trend- und Prognosemodells* (Kapitel 2.3.4.4), in dem wenige, aber aussagekräftige Risikoindikatoren für die kommende Periode (z.B. den kommenden Monat) betrachtet werden
- Übernahme der identifizierten Lieferanten in die 2. Stufe

2. Stufe:

- *Nutzung von weiteren Kennzahlen und Softfacts* (z. B. die Flexibilität bei kurzfristigen Änderungen oder die Zusammenarbeit mit dem Lieferanten) als erweitertes Kennzahlenset, um eine Entscheidungsgrundlage im Lieferantensteuerkreis zu generieren

- Initiierung von Entscheidungen und Einleitung von Verbesserungsmaßnahmen bei als kritisch definierten Lieferanten nach entsprechender Priorisierung, z.B. nach Aufwand und Ressourcen
- Übernahme der Lieferanten, bei denen Verbesserungsmaßnahmen zur Verbesserung der Leistungserbringung entschieden worden sind, in Stufe 3

3. Stufe:

- Hinzunahme aller Kennzahlen, Informationen und Softfacts in Bezug auf Lieferanten, die in Stufe 2 als kritisch priorisiert worden sind, um konkrete Verbesserungsmaßnahmen zu definieren
- Z.B. Einleitung einer Problemanalyse beim Lieferanten vor Ort

Die Kennzahlen für das in Stufe 1 genutzte Trend- und Prognoseverfahren ergeben sich aus der differenzierten Risikobetrachtung (Kapitel 3.3.5). Jedem Risiko, das kontinuierlich betrachtet wird, ist eine Kennzahl als Risikoindikator zugeordnet. Für die prozessorientierte Bewertung der Lieferanten werden nur wenige, jedoch stark aussagefähige Kennzahlen genutzt.

Bereits vor dem Erreichen von unterschiedlichen Leistungsklassen (Eingriffsgrenzen) der Lieferanten [SCH14c] identifiziert das Trend- und Prognosemodell (Kapitel 4.3.1) die möglichen kritischen Lieferanten auf Basis des Trends (Bild 3-18). Die türkise Linie stellt exemplarisch den Kennzahlenverlauf über die Zeit dar. Dieser fällt ab dem Zeitpunkt t ab. Die Eingriffsgrenze (schwarze Linie) markiert den Zeitpunkt t+1, wenn der Lieferant mit der Kennzahl eine schlechtere Leistungsklasse erreicht. In diesem Fall müssen Maßnahmen zur Wiederherstellung der Leistung definiert werden. Das Trend- und Prognosemodell ermittelt anhand von Kennzahldaten aus der Vergangenheit den weiteren, möglichen Verlauf des Kennzahlenwertes auf Basis der Statistik. Anhand dieser Information kann beurteilt werden, ob ein Lieferant zukünftig und hypothetisch zum Zeitpunkt t+1 kritisch wird (wie im Bild 3-18) oder nicht. Die Errechnung der Prognose dient dabei ausschließlich der Validierung des Modells und nicht der Wissensgenerierung. Die Prognose hat somit keinen Einfluss auf die Entscheidungen des Lieferantensteuerkreis bzw. beschlossene Eskalationsmaßnahmen [DUS10c, HEL16, RAM17].

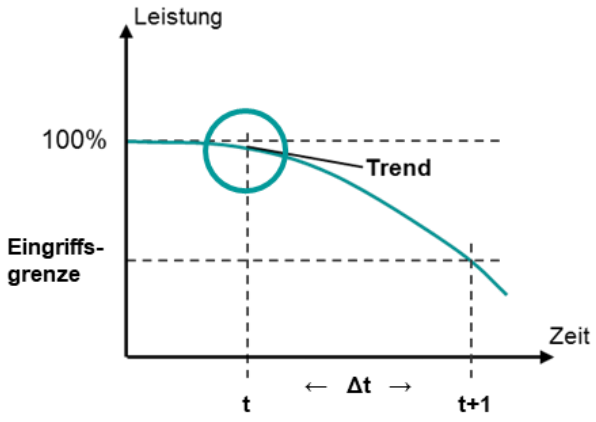


Bild 3-18: Identifikation möglicher kritischer Lieferanten mit Hilfe des Trend- und Prognosemodells
Quelle: Eigene Darstellung in Anlehnung an [DUS18]

Durch dieses Vorgehen wird eine effiziente Methode gewählt, die es ermöglicht, die relevanten Informationen für eine Entscheidungsgrundlage zur Verfügung zu stellen, wobei der Analyseaufwand reduziert wird [DUS18]. Der Grundsatz des Modells kann folgendermaßen zusammengefasst werden: „Bewertung aller Lieferanten mit relevanten… [Kennzahlen und Softfacts] innerhalb einer Stufe, statt der Bewertung ausschließlich wichtiger Lieferanten mit allen… [Kennzahlen und Softfacts]“ [DUS15]. Damit bezieht sich der Autor auf die erste Stufe des gestuften Bewertungsmodells. Das Ziel ist, immer alle Lieferanten der Lieferantenbasis zu bewerten.

Die Informationen, die durch die Analysen in den Stufen 1 bis 3 des gestuften Bewertungsmodells generiert werden, müssen jederzeit für alle Mitarbeiter im Unternehmen mit Schnittstellen zum Lieferanten zugänglich sein. Dafür wird eine bereichsübergreifende Datenbank angelegt. Auch weitere Informationen, beispielsweise über die Materialgruppenstrategie im Zuge der Lieferantenauswahl, das Reifegradmanagement oder die Auditberichte werden darin dokumentiert. Somit ist eine transparente und einheitliche Sicht auf den Lieferanten gewährleistet. Statistische Auswertungen pro Lieferant (z. B. über die Leistungserbringung) oder auch lieferantenübergreifend pro Risiko (z. B. bei einer kritischen Materialgruppe) sind durch diese konsolidierten Informationen möglich [DUS16f].

Doch allein die bereichsübergreifenden Informationen zu sammeln reicht nicht für die Steuerung der externen Wertschöpfungsnetzwerke aus. Ein „Mehrwert entsteht [erst], wenn Risikoinformationen zu besseres Entscheidungen führen“ [GLE16]. Für diese Entscheidungen wird ein bereichsübergreifendes Gremium benötigt.

3.4.2 Entscheiden

Die Informationen aus der Analyse werden im nächsten Schritt des Workflows von den Teilnehmern des bereichsübergreifenden Steuerkreises genutzt. Dieses Gremium dient als operatives Instrument des Lieferantenmanagements [DUS16d]. Innerhalb dieses Gremiums tauschen sich die verschiedenen Fachbereiche, z. B. Einkauf, Logistik, Technik (Entwicklung/Konstruktion) und Qualität regelmäßig über die Risiken in der Supply Chain aus, um anschließend standardisiert Maßnahmen zu beschließen.



Bild 3-19: Bereichsübergreifender Lieferantensteuerkreis im Total Supplier Management
Quelle: [DUS10b]

Zusammenfassend hat der Lieferantensteuerkreis folgende Eigenschaften:

- Workfloworientiert durch die Einbindung in das ganzheitliche Lieferantenmanagement des TSM
- Bereichsübergreifend durch den gemeinsamen Austausch der Fachbereiche mit Schnittstellen zum Lieferanten
- Präventiv durch den regelmäßigen Austausch der tagenden Fachbereiche
- Mandatiert durch Einbindung in die Hierarchieebenen
- Priorisierend durch die effiziente Verteilung der Ressourcen
- Nachhaltig durch die regelmäßige Kontrolle der beschlossenen Maßnahmen

Die Punkte der Workfloworientierung (Kapitel 3.4), des bereichsübergreifenden, präventiven und regelmäßigen Austausches (Kapitel 3.1) sowie das Trend- und Prognosemodell (Kapitel 4.3.1) sind bereits in weiteren Zusammenhängen erläutert worden. Im Folgenden wird auf die Eigenschaften mandatiert, priorisierend und nachhaltig eingegangen.

Der Steuerkreis erhält von der Geschäftsleitung des beschaffenden Unternehmens das *Mandat* zur Entscheidungsbefugnis. Die Geschäftsleitung wird durch das Berichtswesen wiederum über die Aktivitäten des Steuerkreises informiert. Somit findet ein regelmäßiger Informationsaustausch mit Hilfe eines durchgängigen Berichtswesens zwischen den Hierarchieebenen statt.

Zur Steuerung der Lieferantenbasis stehen dem beschaffenden Unternehmen nicht unendlich viele Ressourcen (Mitarbeiterinnen und Mitarbeiter, finanzielle Mittel etc.) zur Verfügung. Somit unterliegen sowohl die einzelnen Eskalationsschritte, als auch die Zusammenarbeitsmodelle mit den Lieferanten einer *Priorisierung* nach Zeit, Aktivitäten sowie Ressourcen. Dafür werden über den Workflow-Schritt Informieren (Kapitel 3.4.1) alle Informationen für die Entscheidung, wie mit den jeweiligen Lieferanten verfahren wird und damit für die Verteilung der Ressourcen, zusammengetragen.

Durch die regelmäßige Kontrolle der Wirkung von eingeleiteten Maßnahmen stärkt der Steuerkreis die *Nachhaltigkeit* der Aktivitäten an der Schnittstelle zum Lieferanten. Somit kann die Lieferantenleistung nachhaltig wiederhergestellt werden.

Um die verschiedenen Ziele der Fachbereiche mit Schnittstellen zum Lieferanten (Kapitel 3.1) zu berücksichtigen, ist ein bereichsübergreifend abgestimmtes Vorgehen notwendig. Der bereichsübergreifende Steuerkreis, der zur Koordination dieses Vorgehens dient, tagt regelmäßig. Laut der Studie von DUST UND WILDE [DUS16d] besitzen aktuell 22 Prozent der befragten Unternehmen einen bereichsübergreifenden Steuerkreis aus mindestens zwei oder mehr Fachbereichen. Bei 52 Prozent der Studienteilnehmer tagt dieser regelmäßig im wöchentlichen oder monatlichen Rhythmus [DUS16d].

3.4.3 Durchführen

Mit Hilfe situationsgerechter und effizienter Eskalationsmodelle beschließt der Steuerkreis Maßnahmen, um die Lieferantenleistung nachhaltig abzusichern oder wieder herzustellen [MUS98, DUS16d]. Die beschlossenen Maßnahmen werden von den verantwortlichen Fachbereichen in einem Eskalationsmodell umgesetzt (Bild 3-20).

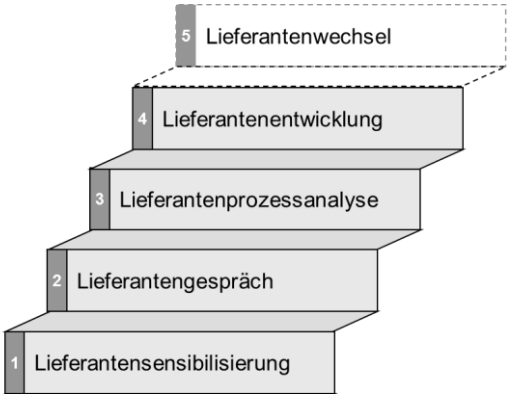


Bild 3-20: Eskalationsmodell
Quelle: [WIL17]

Die Stufen des Eskalationsmodells müssen nicht nacheinander umgesetzt werden. Der Steuerkreis kann bei auftretenden Defiziten sofort entsprechende Maßnahmen einleiten. Annähernd 56 Prozent der durch die Studie von DUST UND WILDE [DUS16d] befragten Unternehmen stützen ihre Maßnahmen durch ein solches Eskalationsmodell. Für die Untersuchung des Einsatzes von weiteren Sanktionen in Abhängigkeit von der Lieferantenleistung wird auf JANKER [JAN08] verwiesen. Im Folgenden werden die Stufen des Eskalationsmodells erläutert.

1. Stufe:

Die Kontaktaufnahme vom Abnehmer zum Lieferanten aufgrund von auftretenden Leistungsdefiziten ist im Rahmen der Sensibilisierung definiert. Der Kontakt kann über einen Brief oder auch ein Telefonat mit dem entsprechenden Ansprechpartner hergestellt werden. Dabei wird der Lieferant auf die Defizite sowie möglichen Auswirkungen hingewiesen und zu Maßnahmen aufgefordert.

2. Stufe:

Bei auftretenden Leistungsdefiziten werden die Ergebnisse aus der Lieferantenbewertung vor dem Lieferantengespräch an den Gesprächspartner gesendet. Somit haben alle Beteiligten eine gemeinsame Informationsgrundlage. Die Ergebnisse aus der Lieferantenbewertung werden dann mit dem Lieferanten erörtert [HEß08]. Die notwendigen Maßnahmen zur Wiederherstellung der Leistung werden gemeinsam identifiziert und dokumentiert. Die Maßnahmenumsetzung obliegt dem Lieferanten [HEß08]. Vom Abnehmer wird die Umsetzung der Maßnahmen regelmäßig kontrolliert.

3. und 4. Stufe:

Die einzelnen Maßnahmen der Lieferantenprozessanalyse und der Lieferantenentwicklung basieren auf Lieferantenprojekten mit einer standardisierten Vorgehensweise. Diese ist in vier Aspekte gegliedert: Vorbereitung, Analyse vor Ort, gemeinsame Maßnahmendefinition mit dem Lieferanten und nachhaltige Problemlösung.

Bei der standardisierten *Vorbereitung* der Lieferantenprojekte gilt es, eine klare Beauftragungssituation zwischen allen Beteiligten mit gemeinsamen Zielen herzustellen. Dies geschieht durch eine koordinierte interne Voranalyse. Danach wird die *Analyse vor Ort* beim Lieferanten durchgeführt. Mit Hilfe standardisierter Methoden und einer lösungsorientierten Prozessanalyse werden Defizite ermittelt. Eine *gemeinsame Maßnahmendefinition* soll das Problembewusstsein schärfen. Für die Durchführung werden Verantwortlichkeiten im Rahmen des Projektes festgelegt. Regelmäßige Überprüfungen mit Statusberichten schaffen Verbindlichkeiten für eine *nachhaltige Problemlösung*. Die Projekte werden abschließend in einem Bericht dokumentiert.

Diese Tätigkeiten übernimmt der Lieferantenmanager. Das Anforderungsprofil des Lieferantenmanagers wird nach HELMHOLD UND TERRY [HEL16] folgendermaßen definiert

- Management von Risiken
- Modellierung von Liefernetzwerken
- Interkulturelle Erfahrungen
- Schnittstelle zwischen den Fachbereichen
- Einleitung präventiver Maßnahmen bei Versorgungsrisiken
- Nachhaltige und langfristige Maßnahmeneinleitung

Der Lieferantenmanager arbeitet zusammen mit dem Lieferanten sowie weiteren beteiligten Fachbereichen an der Absicherung und Wiederherstellung der Lieferantenleistung.

5. Stufe:

Für einen Lieferantenwechsel gibt es mehrere Gründe. Zusammenfassend [JAN08, APP11, DÖL11, SCH14c] können dies

- erhebliche Leistungsdefizite trotz Einsatz von Maßnahmen und Sanktionen,
- eine Insolvenz des Lieferanten,
- volatile Kosten bzw. Preise des zu beschaffenden Gutes,
- eine vorgesehene Volumenbündelung bei einem anderen Lieferanten oder
- die Änderung der Beschaffungsstrategie sein.

Die Eliminierung eines Lieferanten aus der Lieferantenbasis ist mit einem Wechsel zu einem anderen Lieferanten verbunden. Aufgrund des Aufwands der Eliminierung des bestehenden Lieferanten und der Auswahl des neuen Lieferanten [SCH14c] gilt dieser Schritt als letztes Mittel [JAN08].

In der Studie von DUST UND WILDE [DUS16D] wird die Verankerung eines gestuften Eskalationsmodells in der Unternehmensorganisation erörtert. Dabei stellen die Autoren fest, dass 44 Prozent der befragten Unternehmen kein gestuftes Eskalationsmodell und 44 Prozent ein Eskalationsmodell ohne Verbindung zu einem koordinierenden Steuerkreis haben. Dieses Vorgehen ähnelt einer „Feuerwehrkultur“ [EBE13] und führt zu nicht abgestimmten sowie ineffizienten Vorgehensweisen.

3.4.4 Lessons Learned

Der Lessons Learned-Prozess im Lieferantenmanagement resultiert aus den aufgedeckten Leistungsdefiziten an der Schnittstelle zum Lieferanten. Werden die entsprechenden Stufen des Eskalationsmodells durchgeführt, fallen weitere Informationen an. Diese werden wieder in den Workflow des TSM eingegliedert (Bild 3-21).

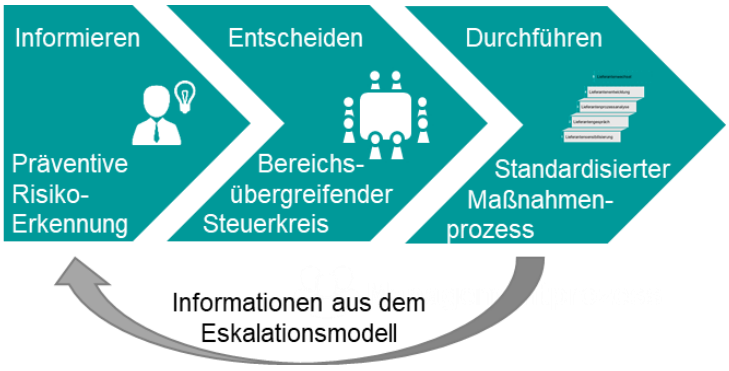


Bild 3-21: Informationen aus dem Eskalationsmodell im Kontext zum TSM-Workflow
Quelle: Eigene Darstellung

Doch nicht immer können die Defizite über Lieferantenprojekte verbessert werden. Mehr als ein Drittel der Leistungsdefizite beim Lieferanten entsteht aufgrund fehlender Vorleistungen des Abnehmers [DUS16d]. Diese Defizite an der Schnittstelle zwischen Lieferant und Abnehmer können nur mit einer Prozessverbesserung im beschaffenden Unternehmen nachhaltig reduziert werden. Abgeleitet von PENEDER [PEN13] werden die Ziele des Lessons Learned wie folgt zusammengefasst:

- Sicherung des erworbenen Wissens aus den Eskalationsmaßnahmen (Wissensbewahrung)
- Transparenz und Sichtbarmachen des erworbenen Wissens (Wissensverteilung)
- Schaffung neuer Erkenntnisse (Wissenserwerb)

Die Maßnahmen des Lessons Learned werden durch einen kontinuierlichen Verbesserungsprozess (KVP) überprüft und angepasst. Der Kreislauf einer kontinuierlichen Verbesserung lehnt sich dabei an den durch DEMING [DEM98] bekannt gewordenen PDCA-Zyklus (Bild 3-22) an [SCH15b].

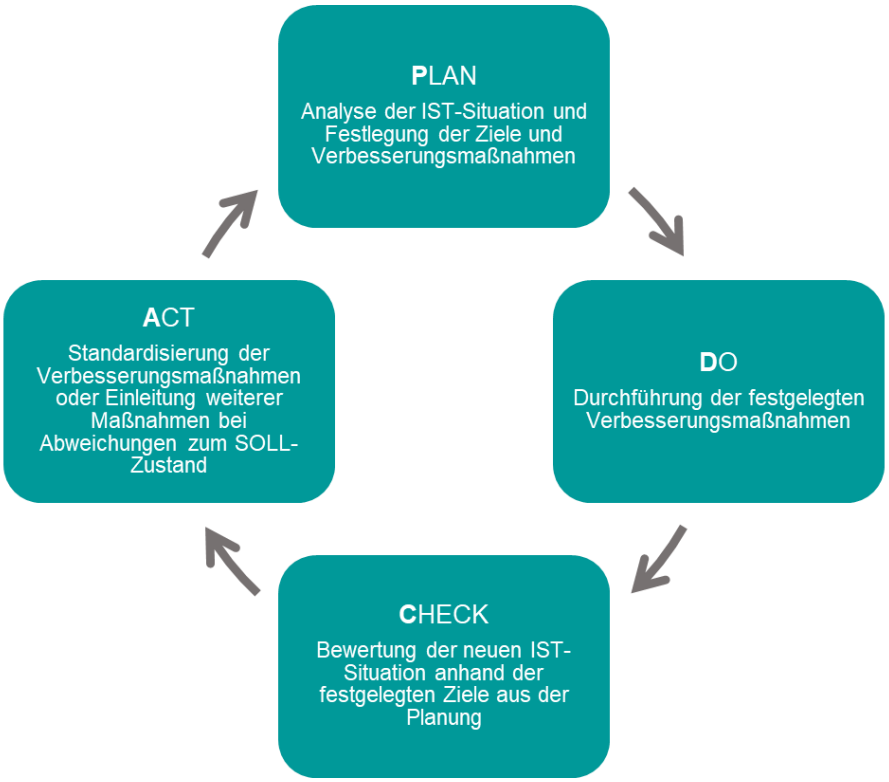


Bild 3-22: PDCA-Zyklus
Quelle: Eigene Darstellung in Anlehnung an [SCH15b]

Der PDCA-Zyklus ist ebenfalls in der ISO 31000:2009 [ISO31000] im Rahmen des Risikomanagementprozesses enthalten. Dieser Problemlösungsprozess hat das Ziel der ständigen Verbesserung von Produkten und Dienstleistungen. Somit hat der Prozess einen direkten Einfluss auf die Qualität des Lieferantenmanagements.

Die Zusammenarbeit mit den Lieferanten hat das Ziel, Transparenz über die Leistungsfähigkeit und Sicherheit bei der Versorgung über das externe Wertschöpfungsnetzwerkes zu gewährleisten. Durch die Möglichkeit im TSM über präventives Handeln nachhaltige Verbesserungen in der Lieferantenleistung zu erreichen und diese Leistungsfähigkeit auch regelmäßig zu überprüfen, kann die wirtschaftliche Stabilität des beschaffenden Unternehmens abgesichert werden.

3.5 Zusammenfassung und Fazit

Das TSM beschreibt ein bereichsübergreifendes Koordinations-, Kommunikations- und Kooperationsmodell, das die Auswahl, Integration, Steuerung und Entwicklung der Lieferanten standardisiert. Dies wird zum unternehmerischen Erfolgsfaktor, da das gesamte Wertschöpfungsnetzwerk effizient und kostenoptimal gesteuert wird. Eine kooperative Zusammenarbeit zwischen Lieferant und Abnehmer verhindert ineffektive und ineffiziente Prozesse an den Schnittstellen [DUS16e] und ermöglicht die Nutzung gemeinsamer Prozesskostenpotenziale. Die Steuerung der externen Wertschöpfung setzt durchgängige Organisationsstrukturen, Prozesse und Methoden voraus. Dies Voraussetzungen bietet ein ganzheitliches Lieferantenmanagement mit seinen Bausteinen und Qualitätsmerkmalen. Der präventive Ansatz vermeidet zusätzlich Leistungsdefizite beim Lieferanten. Bei kritischen Zulieferern wird die Leistungserbringung verbessert, womit die Aufwände für Steuerungen und Korrekturmaßnahmen minimiert werden.

Durch die enge Zusammenarbeit der Fachbereiche an der Schnittstelle zum Lieferanten werden Synergien erzeugt. Zusammenfassend liegt der Mehrwert des standardisierten Vorgehens in den folgenden Punkten [HEß08, DUS10b]:

- *Verbesserung der Prozessqualität*: Aufgrund des standardisierten Workflows mit einem integrierten KVP werden die Prozesse abgesichert.
- *Effizienzsteigerung an der Schnittstelle zum Lieferanten*: Das abgestimmte Vorgehen im Lieferantensteuerkreis vereinfacht den Aufwand zur Steuerung der externen Wertschöpfungsnetzwerke.
- *Reduzierung der Prozesskosten***:** Eine strukturierte Vorgehensweise reduziert den Abstimmungsbedarf durch eine reaktive Task Force sowie die Anzahl der Lieferantengespräche und somit die Reibungsverluste an der Schnittstelle zum Lieferanten sowie die lieferantenverursachten Fehlerkosten erheblich.

Die Anforderungen an eine ganzheitliche Risikobetrachtung aus Kapitel 2.3.2 erweitern sich nach der Betrachtung der zehn Bausteine mit den sechs Qualitätsmerkmalen des ganzheitlichen Lieferantenmanagements um folgende Punkte:

- Kontinuierliche Leistungsdatenerhebung mit Trend- und Prognosemodellen
- Durchgängiger Workflow bei der Lieferantenbewertung und im gesamten TSM-Modell
- Gestuftes Vorgehen, um alle Lieferanten effizient zu bewerten

Der Anteil der befragten Unternehmen mit einem durchgängigen Workflow liegt in der Studie von DUST UND WILDE [DUS16d] bei 13 Prozent (Bild 3-23).

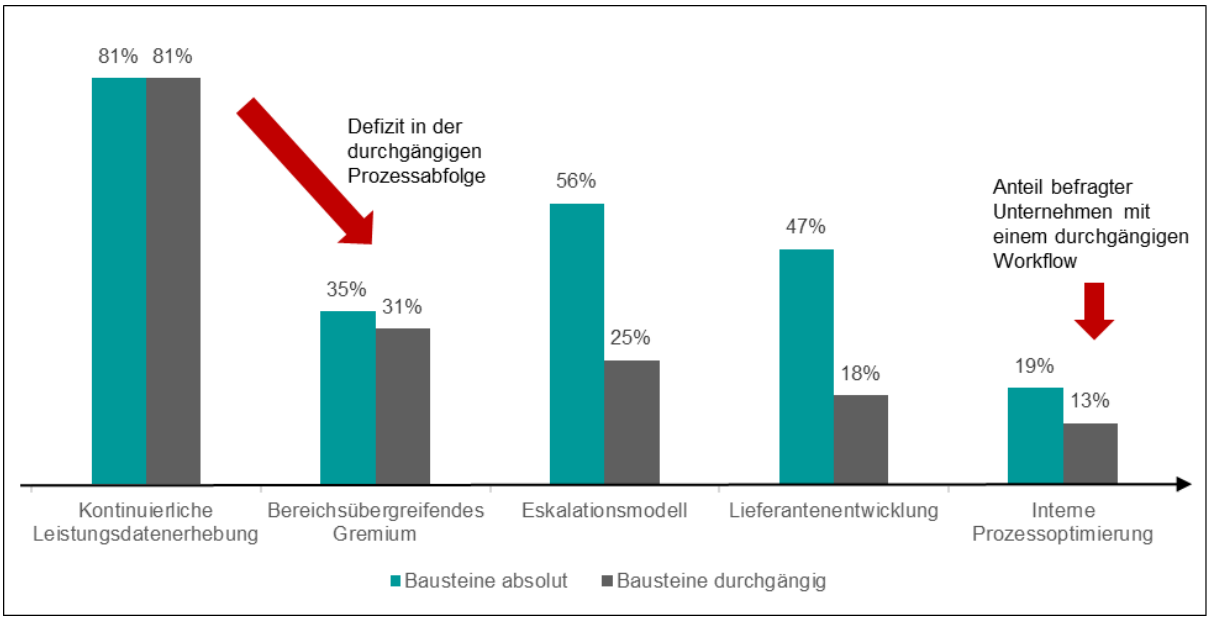


Bild 3-23: Anteil der Unternehmen mit Bausteinen in einer durchgängigen Prozessabfolge
Quelle: Eigene Darstellung in Anlehnung an [DUS16d]

Bereits bei der durchgängigen Prozessabfolge der Bausteine wird ein Defizit zwischen der kontinuierlichen Leistungsdatenerhebung (regelmäßige Bewertung aller Lieferanten) mit 81 Prozent und der Installation eines bereichsübergreifenden Entscheidungsgremiums (z.B. Lieferantensteuerkreis) mit 31 Prozent deutlich. Doch fehlt ein solches Gremium, können keine bereichsübergreifend abgestimmten Maßnahmen zur Wiederherstellung der Leistungserbringung von Lieferanten beschlossen werden. In diesen Fällen können die einzelnen Fachbereiche bei auftretenden Leistungsdefiziten von Lieferanten nur reaktiv und bereichsintern Maßnahmen durchführen. Der präventive Ansatz eines ganzheitlichen Lieferantenmanagements geht somit verloren.

Auch HEß weist in seiner Studie darauf hin, dass “trotz gravierender Risiken […] das Risikomanagement nur sehr rudimentär ausgeprägt [ist]” [HEß15]. Es gibt Mängel bei der Durchgängigkeit des Managements von der Unternehmensstrategie bis in die Markt- und Lieferantenstrategien. Mit Hilfe des TSM-Workflows wird durch das gestufte Bewertungssystem mit dem integrierten Trend- und Prognosemodell eine Informationsgrundlage für die Entscheidungen des Lieferantensteuerkreises generiert. Wie diese interpretierbaren Informationen mit Hilfe des Wissensmanagements weiterentwickelt werden können, wird im nachfolgenden Kapitel erörtert.

4 Wissensmanagement im Total Supplier Management

„Durch den Wechsel von der Industrie- zur Informations- und Wissensgesellschaft hat die Bedeutung von Wissen eine neue Dimension erlangt“ [NIK17]. Die zweckgebundene Vernetzung von Informationen zu robustem Wissen gilt dabei als „entscheidende Ressource zur Generierung nachhaltiger Wettbewerbsvorteile“ [SEU08]. Treiber der zunehmenden Bedeutung sind nach NORTH [NOR11] der strukturelle Wandel zur Informations- und Wissensgesellschaft, die Weiterentwicklung der Informations- und Kommunikationstechnologie sowie die wachsende Globalisierung. Dafür gibt es in Unternehmen verschiedene Aufgaben des Informations- und Wissensmanagements. Um diese Aufgaben abzugrenzen, ist zunächst eine Differenzierung zwischen den Begriffen Zeichen, Daten, Informationen und Wissen notwendig. Zur Visualisierung der Abgrenzung dient Bild 4-1.

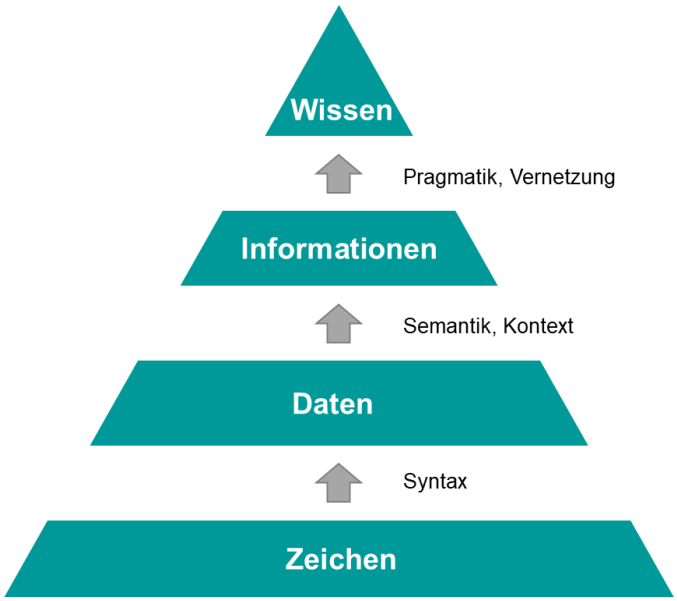


Bild 4-1: Abgrenzung der Begriffe Daten, Information, Wissen
Quelle: [BOD03]; Diese Abbildung ist auch ähnlich enthalten in [REH96].

Da in diesem Kapitel vorrangig das Wissen und das Wissensmanagement im Fokus stehen, werden die Begriffe Zeichen, Daten und Information kurz erläutert. Eine vertiefende Auseinandersetzung mit den Begriffen Daten, Information und Wissen wird von NIKODEMUS [NIK17] als Grundlage für Entscheidungen erörtert.

- *Zeichen* sind einzelne Elemente eines Datensatzes.
- *Daten* sind „Fakten über ein Objekt“ [DINENISO9000].
- *Information* sind „Daten mit Bedeutung“ [DINENISO9000].

Durch die Vernetzung von zweckdienlichen Informationen entsteht Wissen [BOD03, PRO12]. Vereinfacht wird in der Literatur auch postuliert, dass Wissen aus vernetzten Daten generiert werden kann [ADR98]. In der Literatur besteht jedoch Uneinigkeit über die Definition des Begriffs Wissen [NIK17]. Wissen ist laut DIN EN ISO 9000 eine „verfügbare Sammlung von Informationen, die eine berechtigte Überzeugung darstellen und mit großer Sicherheit wahr sind“ [DINENISO9000]. Unter Wissen verstehen HEINRICH UND STELZER aber auch „die Gesamtheit der Kenntnisse und Fähigkeiten zur Lösung von Problemen“ [HEI09]. Dabei kann implizites

und explizites Wissen unterschieden werden [SEU08]. Als implizites Wissen (embodied knowledge) werden Intuitionen, Gefühle oder subjektive Empfindungen, die schwer zu formalisieren oder kommunizieren sind, bezeichnet [REH96]. Explizites Wissen (disembodied knowledge) ist hingegen auf (elektronischen) Medien gespeichert. Das können beispielsweise Dokumente, Notizen oder auch Datenbanken sein. Explizites Wissen wird somit für eine weitere Datenverarbeitung nutzbar [REH96]. Möchte eine Organisation das implizite Wissen speichern, muss dieses zunächst in explizites Wissen überführt werden.

Das Wissensmanagement versteht sich in diesem Zusammenhang als „Führungsaufgabe, die sich mit der zielorientierten Nutzung und Weiterentwicklung von Wissen im Unternehmen befasst“ [HEI09]. Dabei wird sowohl das implizite als auch das explizite Wissen als wichtige Ressource koordiniert. Für eine weitere Betrachtung des Wissensmanagements, als Grundlage einer Lieferantenbewertung zur frühzeitigen Risikoprävention, werden nun im Folgenden die Aufgaben sowie der Nutzen betrachtet.

4.1 Aufgaben und Nutzen des Wissensmanagements

Die primäre Zielsetzung des Wissensmanagements ist es, standardisierte und strukturierte Voraussetzungen zu schaffen, damit eine lernende Organisation das unternehmensintern vorhandene und auch das neu erworbene Wissen nutzen kann [REH96]. Die Aufgaben des Wissensmanagements lassen sich anhand von acht Bausteinen erläutern (Bild 4-2). Diese stellen ein Konzept von Aktivitäten dar [HEI14].

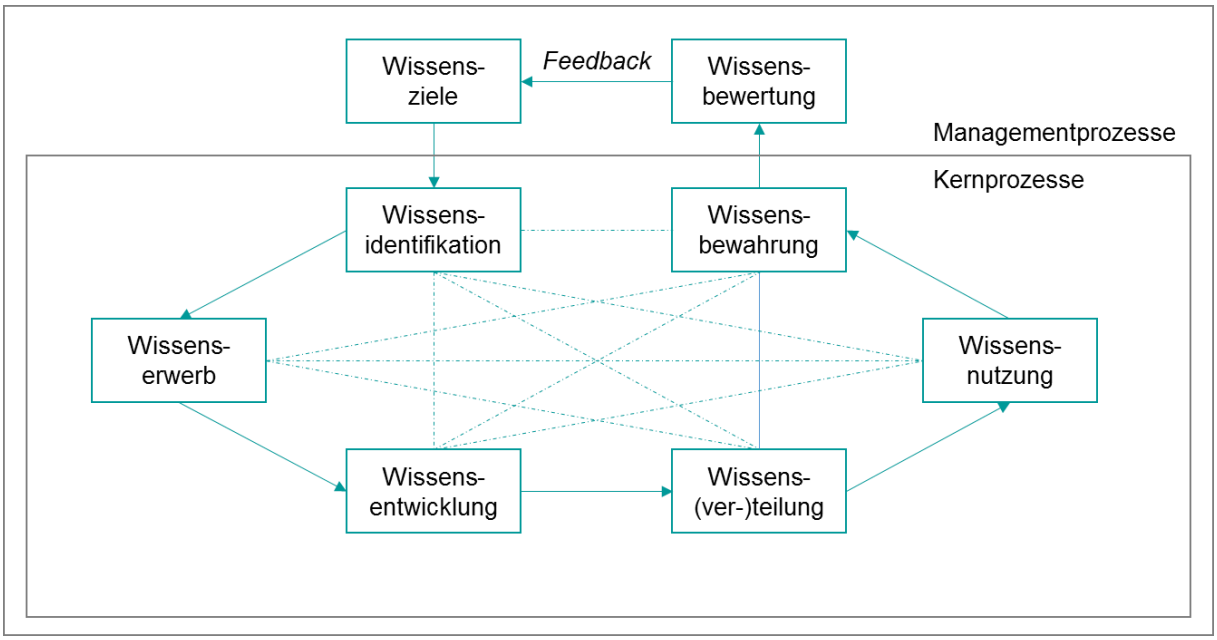


Bild 4-2: Bausteine des Wissensmanagements
Quelle: Eigene Darstellung in Anlehnung an [PRO12]

Zur übersichtlichen Darstellung der einzelnen Bausteine des Wissensmanagements sowie deren Nutzen werden die wesentlichen Erkenntnisse nach PROBST ET AL. [PRO12] und HEINRICH ET AL. [HEI14] zusammengefasst. Angefangen bei den Kernprozessen, stellen diese den operativen Umgang mit Wissen einer Organisation dar.

Supplier Risk Monitoring

Wissensidentifikation

Die Analyse und Beschreibung des Wissensumfeldes in einem Unternehmen ist Bestandteil der Wissensidentifikation. Dafür muss eine hinreichende Transparenz über das Wissen gewährleistet sein. Die Wissensidentifikation gibt einen Überblick über interne und externe Daten, Informationen und Fähigkeiten einer Organisation.

Wissenserwerb

Viele Datenquellen zur Generierung von Wissen sind unternehmensextern. Es muss sich demnach die Frage gestellt werden, wie diese Quellen in das eigene Unternehmensnetzwerk eingebunden werden. Die Nutzung von externem Know-how durch die Akquirierung von Experten kann eine Möglichkeit sein, um alle Potenziale des Wissenserwerbs zu nutzen.

Wissensentwicklung

Das Ziel der Wissensentwicklung ist „die Produktion neuer Fähigkeiten, neuer Produkte, besserer Ideen und leistungsfähigerer Prozesse“ [HAA01, PRO12] damit neues Wissen entstehen kann. So kann sich ein Unternehmen Markt- oder Wettbewerbsvorteile verschaffen. Die automatisierte Entwicklung des Wissens wird in der vorliegenden Arbeit als Wissensgenerierung bezeichnet. Dafür wird im Weiteren der Prozess des Data Mining verwendet.

Wissens(ver-)teilung

Durch die Verbreitung von bereits vorhandenem Wissen in einer Organisation sollen voneinander isolierte Informationen oder Erfahrungen für bestimmte Personen(-gruppen) nutzbar und zugänglich gemacht werden. Wem über welches Medium und in welchem Umfang Wissen zur Verfügung gestellt wird, muss zuvor definiert werden.

Wissensnutzung

Die Nutzung, also der produktive Einsatz und die gezielte An- bzw. Verwendung des Wissens, stellt das Ziel des Wissensmanagements dar.

Wissensbewahrung

Damit das Wissen einer Organisation auch zukünftig zur Verfügung steht, muss dieses gespeichert und regelmäßig aktualisiert werden. Eine standardisierte und strukturierte Sicherung des Wissens ist die Voraussetzung für eine effiziente Nutzung.

Wissensziele

Die operativen Kernprozesse benötigen strategische Vorgaben des Managements. Die *Wissensziele* unterstreichen die Bedeutung des Wissensmanagements.

Wissensbewertung

Um die Wissensziele zu *bewerten*, müssen diese gemessen werden. Daran lassen sich die Qualität sowie der Zielerreichungsgrad des Wissensmanagements beurteilen.

Zusammenfassend beinhaltet das Wissensmanagement nach REHÄUSER UND KREMAR [REH96] folgende Aufgaben:

- Management der Wissens- und Informationsquellen
- Management der Wissensträger- und Informationsressourcen
- Management des Wissensangebots
- Management des Wissensbedarfs
- Management der Infrastrukturen der Wissensverarbeitung (IKT)

Demnach ist die wichtigste Aufgabe des Wissensmanagements „eine Organisation fit zu machen für die „Wissensgesellschaft“ [[BAE08] mit Verweis auf [WIL97]]. „Die Wissensgesellschaft des 21. Jahrhunderts wird als Nachfolgerin der Industriegesellschaft des 19. und 20. Jahrhunderts verstanden“ [POL13]. Dabei werden durch das Management der Ressource Wissen Wettbewerbsvorteile zwischen Unternehmen generiert [ALE08].

Das Wissensmanagement mit den verschiedenen Aufgaben dient nun im Weiteren als Grundlage für die Tätigkeiten der Wissensgenerierung im TSM. Dafür werden die Aufgaben des Wissensmanagements in den TSM-Workflow überführt (Bild 4-3).

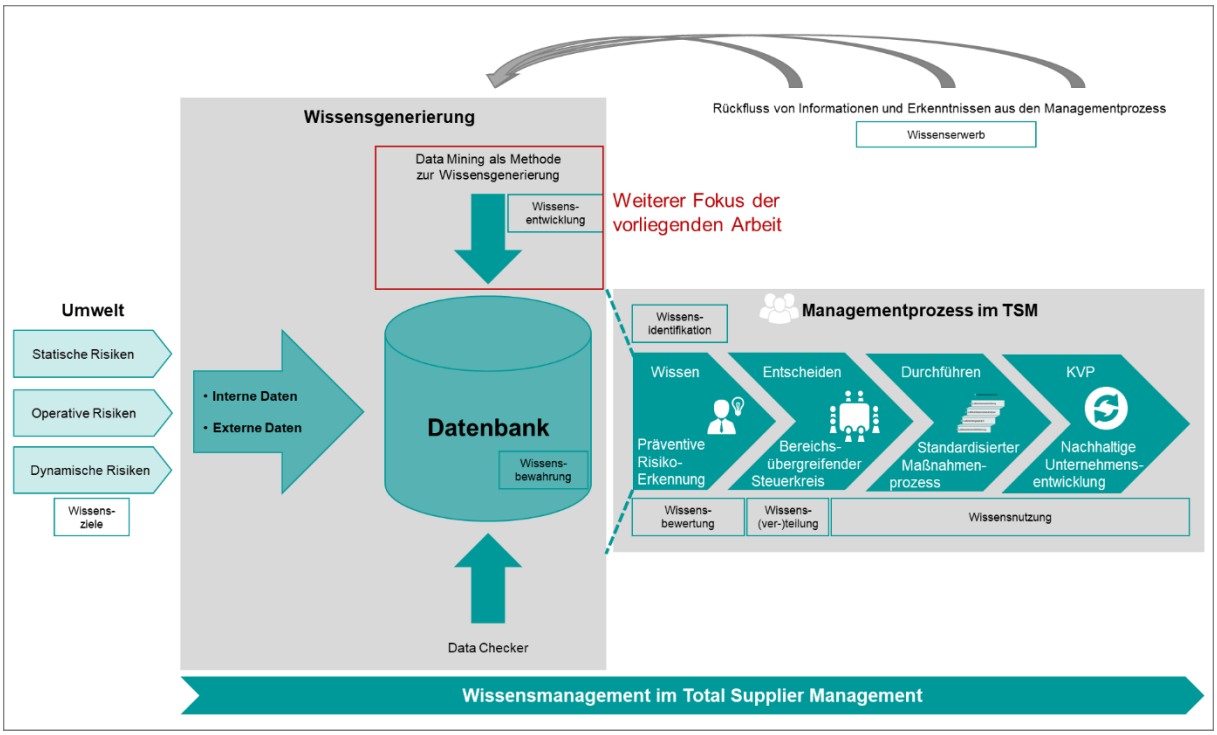


Bild 4-3: Wissensmanagement als Teil des Total Supplier Management Workflows
Quelle: Eigene Darstellung

Das Wissen wird durch die vielen internen und externen Informationsquellen gespeist. Abgeleitet aus dem Wissensmanagement beinhaltet der Komplex der Wissensgenerierung folgende Aufgaben:

- die Wissensentwicklung durch das Data Mining, um aus den vorhandenen Daten Wissen zu generieren sowie
- eine bereichsübergreifende Datenbank zur Aufbewahrung und Verteilung der Daten, Informationen und des Wissens der Fachbereiche.

Das Zusammenspiel dieser beiden Elemente, aber besonders die Wissensentwicklung, bilden die Grundlage für eine Lieferantenbewertung zur frühzeitigen Risikoidentifikation. Durch die Verknüpfung der Informationen zu Wissen werden potenziell kritische Lieferanten frühzeitig erkannt. Dieses Wissen wird durch die Teilnehmer des bereichsübergreifenden Lieferantensteuerkreises bewertet und für die Einleitung entsprechender Maßnahmen zur Wiederherstellung oder Absicherung der Lieferantenleistung genutzt. Bei der Durchführung der eingeleiteten Maßnahmen sowie beim Wissenserwerb im Sinne eines KVP wird zusätzliches Wissen generiert. Dieses wird ebenfalls wieder als interne Datenquelle in die Datenbank zur Sicherung des Know-hows eingespielt. Das gesamte Wissen dient dann der Steuerung der externen Wertschöpfungsnetzwerke.

Somit ist dargestellt worden, dass das Wissensmanagement in Verbindung mit dem TSM prozessorientiert ist. REMUS [REM02] hat die verschiedenen Möglichkeiten und Ansätze eines prozessorientierten Wissensmanagements untersucht. Dabei wird ein prozessorientiertes Wissensmanagement als Managementaufgabe definiert, „die für die regelmäßige Auswahl, Umsetzung und Evaluation von prozeßorientierten [sic] WM-Strategien zuständig ist, mit dem Ziel die Wissensverarbeitung in den operativen wissensintensiven Geschäftsprozessen zu unterstützen, zu verbessern und weiter-zuentwickeln [sic], um schließlich zur Kernwertschöpfung des Unternehmens beizutragen“ [REM02]

Bisher ist jedoch die Frage offengeblieben, wie die Begriffe Wissen und Management im Zusammenhang stehen. Von Management wird nach NIKODEMUS dann gesprochen, „wenn ein Umgang mit Objekten und Vorgängen dem (wirtschaftlichen) Vernunftsprinzip folgt“ [NIK17]. Für HEINRICH ET AL. [HEI14] ist das Management ein Synonym für Führung. Diese hat die „Aufgabe der zweck- und zielorientierten Harmonisierung des arbeitsteiligen sozialen Systems Organisation, um die Erfüllung der Organisazionszielezu [sic] sichern“ [HEI14]. Aufschluss über das Zusammenwirken von Wissen und Management gibt das Ebenenmodell des Wissensmanagements in Bild 4-4.



Bild 4-4: Ebenenmodell des Wissensmanagements
Quelle: [NIK17]

Zur Einordnung der vorliegenden Arbeit wird das Ebenenmodell nach NIKODEMUS [NIK17] kurz beschrieben. Wie auch bereits beim Lieferantenmanagement (Kapitel 2.2.2) gibt es beim Wissensmanagement die Ausprägung in eine normative, strategische und operative Ebene. Die normative Ebene dient der Verankerung der Wissensziele in der Unternehmenskultur (Wissenskultur). Der Schwerpunkt jedoch liegt auf dem strategischen und operativen Wissensmanagement. Auf der strategischen Ebene werden die Wissensziele definiert und die Ressource Wissen über das Prinzip des Managements in einem Wissenssystem koordiniert. Operativ findet die tägliche Ausgestaltung der Wissensorganisation statt. Dabei werden verschiedene Techniken zu einer Wissensinfrastruktur kombiniert.

Die vorliegende Arbeit bewegt sich somit im Rahmen der operativen und strategischen Managementebene. Um nun den weiteren Fokus auf eine effiziente Lieferantenbewertung im Rahmen der Datenmustererkennung zu legen, werden die Methoden zur Wissensgenerierung sowie die Einordnung des Data Mining in den Bereich des Wissensmanagements erörtert.

4.2 Methoden zur Wissensgenerierung

Innerhalb einer Organisation wird unternehmensspezifisches Wissen nach vier Prinzipien erzeugt. Diese stehen in einer Verbindung zueinander. Das individuelle Wissen wird durch die Verbindung zwischen implizitem und explizitem Wissen erzeugt [SCH96]. Um diesen Sachverhalt näher zu betrachten, wird im Weiteren auf die vier Prinzipien der Wissensentwicklung eingegangen (Bild 4-5).

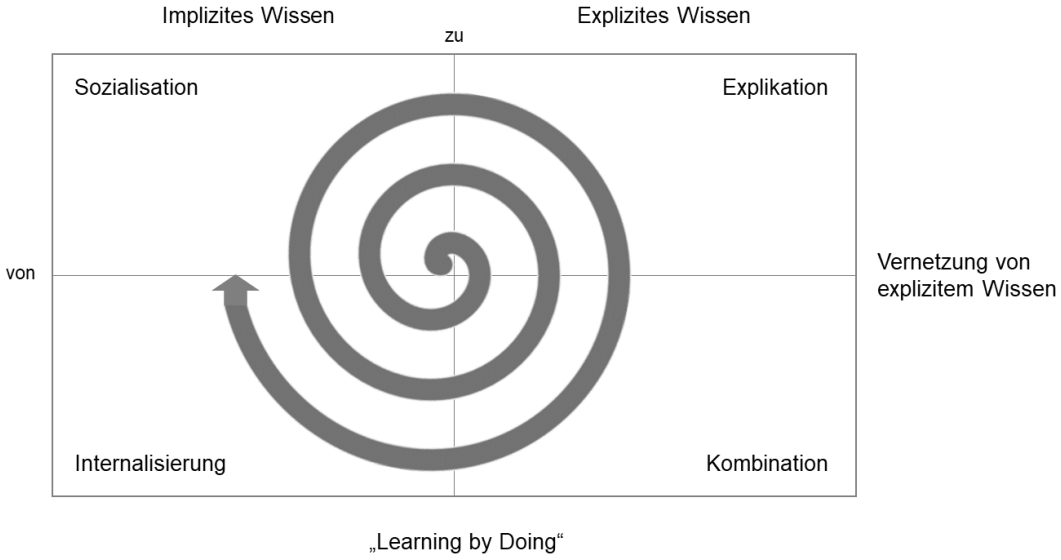


Bild 4-5: Die Spirale des Wissens mit den vier Prinzipien der Wissensentwicklung
Quelle: Eigene Darstellung in Anlehnung an [REH96] mit Verweis auf [NON95]

Die Aussagen über die Beschreibung der vier Prinzipien zur Wissensentwicklung sind in der Literatur mehrfach in ähnlicher Ausführung vorhanden. Zusammenfassend wird ein kurzer Überblick gegeben [NON95, REH96, NOR16, NIK17]:

Die *Sozialisation* wird auch als erlebtes Wissen bezeichnet. Personen tauschen implizit Wissen durch Beobachtung oder Kommunikation aus. Somit werden Erfahrungen innerhalb einer Organisation transferiert. Diese begrenzte Wissenserzeugung steht jedoch nicht der gesamten Organisation zur Verfügung, da es nicht zu explizitem Wissen wird.

Bei der *Explikation* entsteht durch die Transformation von implizitem zu explizitem Wissen neues, für die Organisation nutzbares Wissen. Diese Phase wird zur Produktion von konzeptuellem, neuem Wissen benötigt. Das heißt, dass das implizite Wissen durch ein kollektives Nachdenken explizite Konzepte erzeugt. Dieses Wissen wird für die entsprechenden Mitarbeiterinnen und Mitarbeiter zugänglich dokumentiert.

Durch *Kombination* von bestehendem explizitem Wissen wird neues explizites Wissen erzeugt. Bekanntes Wissen wird dadurch zusammengefasst und vernetzt, bzw. in einer anderen Form dargestellt. Verteiltes Wissen einer Organisation wird zusammengetragen und kann bereichsübergreifend genutzt werden.

Das explizite Wissen wird von der Organisation aufgenommen, ergänzt und neugeordnet in das System des Wissens *internalisiert*. Somit wird explizites wieder zu implizitem Wissen.

Diese Verbindung zwischen implizitem und explizitem Wissen stellt die Grundlage für die Wissensgenerierung dar. Zur Wissensgenerierung wird in der Literatur vielfach auf Data Mining verwiesen [BOD03, SCH09a, CLE16]. Ob Data Mining für die Anwendung im Bereich TSM nutzbar ist, wird im Rahmen der Dissertation geprüft. Dafür wird nun zunächst das Data Mining in den Bereich des Wissensmanagements eingeordnet. Bild 4-6 dient der Visualisierung.

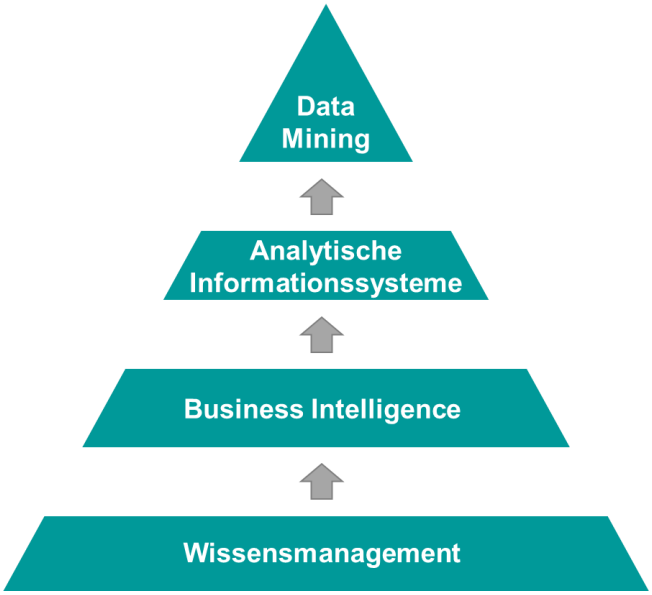


Bild 4-6: Begriffsabgrenzung vom Wissensmanagement zum Data Mining
Quelle: Eigene Darstellung in Anlehnung an [CLE16]

Data Mining wird als eine „Herangehensweise analytischer Informationssysteme, die wiederum dem Business Intelligence untergeordnet sind“ [CLE16] bezeichnet. Laut CLEVE UND LÄMMEL ist Data Mining „eine Sammlung von Techniken, Methoden und Algorithmen für die Analyse von Daten, die somit auch Grundtechniken für neuere und komplexere Ansätze, wie das Business Intelligence oder auch Big Data“ [CLE16], darstellen. Business Intelligence ist ein „Sammelbegriff für IT-Verfahren zur systematischen Sammlung, Analyse und Darstellung von Daten“ [STA17]. Diese Daten bilden in einem Unternehmen die Basis für Managemententscheidungen. Die Umsetzung und Nutzung dieser Verfahren erfolgt über analytische Informationssysteme. Bei diesen Informationssystemen werden die Analysen selbst in den Vordergrund gestellt. Diese Analysen werden in zwei möglichen Prozessen standardisiert bearbeitet. Neben dem Online Analytical Processing (OLAP) gehört auch das Data Mining dazu [CHA16].

Eine schnelle Bereitstellung von Antworten auf analytische Fragestellungen auf Basis strukturierter Daten wird durch OLAP erreicht. OLAP-Anwendungen haben den Fokus auf die Geschwindigkeit der Informationslieferung. Dabei steht „der Aufbau von mehrdimensionalen und hierarchischen Datenmodellen (Würfel/Cubes) im Vordergrund“ [BAN16]. Somit werden auf Basis der Vernetzung verschiedener Daten spezielle Informationen für Entscheidungsträger generiert. Nach diesen speziellen Informationen wird über festgelegte Regeln innerhalb der zur Verfügung stehenden Daten gesucht [SUM06].

Somit kann festgehalten werden, dass Data Mining ein Werkzeug des Wissensmanagements ist. Doch um im Data Mining Analysen in Bezug auf die Lieferantenbewertung durchführen zu können, werden nun die Verfahren zur Wissensgenerierung näher erörtert. Diese Erörterung dient im Anschluss zur Konkretisierung eines Data Mining-Prozesses (Kapitel 4.5).

4.3 Verfahren zur Wissensgenerierung im Data Mining

Ausgehend von der primären Forschungsfrage nach der Analyse von Datenmustern werden im Folgenden vier aufeinander aufbauende Verfahren zur Wissensgenerierung in Bezug zur vorliegenden Arbeit näher betrachtet. Das Trend- und Prognosemodell ist bereits Teil des Total Supplier Managements (Kapitel 3) und erfährt durch diese Integration eine Erweiterung zur hypothesenfreien Wissensgenerierung. Durch die weitere Integration der Cluster- und Assoziationsanalyse vergrößert sich die Datenbasis, welche als Grundlage für die Generierung von quantitativen Assoziationsregeln dient. Eine Vernetzung von Prognosen mit der Assoziationsanalyse wird auch bei SCHMITT ET AL. [SCH16] in Verbindung mit Daten aus dem Bereich Qualität angewendet. Die Verknüpfung der Cluster- und Assoziationsanalyse zur vorzeitigen Reduzierung von Assoziationsregeln legen ESTER UND SANDER sowie CLEVE UND LÄMMEL [EST00, CLE16] dar. Da als Ergebnis der Cluster- und Assoziationsanalyse eine Vielzahl von quantitativen Assoziationsregeln generiert wird, müssen diese Regeln über eine Relevanzprüfung auf ihre Bedeutung für das Auffinden potenziell kritischer Lieferanten geprüft werden. Diese Relevanzprüfung findet über einen strukturierten Prozess statt. Zusammenfassend ergibt sich für die weiteren Betrachtungen folgende Vernetzung von bisher diskutierten Verfahren:

- Trend- und Prognosemodell zur Prognostizierung von KPIs innerhalb der Zeit
- Clusteranalyse für die Betrachtung von Ähnlichkeiten innerhalb der Attribute
- Assoziationsanalyse zur Suche von Zusammenhängen in Datenmustern
- Relevanzprüfung der quantitativen Assoziationsregeln

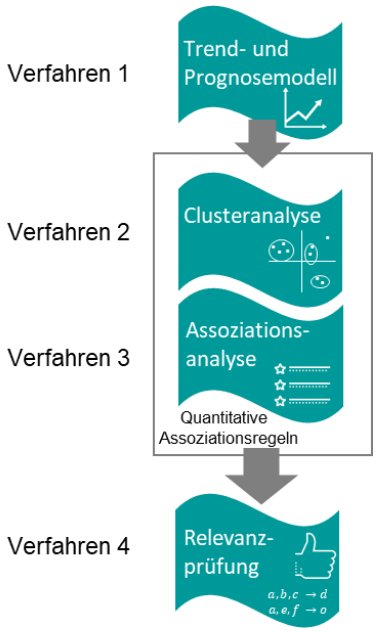


Bild 4-7: Vernetzung verschiedener Lieferantenbewertungsverfahren zur Generierung von Wissen
Quelle: Eigene Darstellung

Um die vier genannten Verfahren nun näher zu betrachten, wird im Folgenden eine detaillierte, generische Analyse in Bezug auf die mathematischen Verfahren vorgenommen. Ausgehend vom Trend- und Prognosemodell wird das konkrete Vorgehen aller weiteren Verfahren nacheinander betrachtet.

4.3.1 Trend- und Prognosemodell

Für die Betrachtung des Gesamtmodells zur Analyse von Datenmustern wird die Vorgehensweise des Trend- und Prognosemodells, welches auf die lineare Regressionsanalyse sowie die exponentielle Glättung zurückgreift [DUS10c], näher erläutert. Das bereits im TSM etablierte Vorgehen findet somit in Teilen zur Wissensgenerierung weiterhin Anwendung. Es wird im Weiteren davon ausgegangen, dass das Trend- und Prognosemodell als Teil des TSM nach DUST [DUS18] (Kapitel 3.1) für eine Wissensgenerierung übernommen und im Folgenden für die Weiterverwendung und Integration im Rahmen dieser Arbeit dokumentiert wird. Ein Anwendungsbeispiel des Trend- und Prognosemodells auf Basis des Tools „Watchlist“ ist in Anhang A beschrieben.

Zunächst muss für die weiteren Berechnungen mit dem Trend- und Prognosemodell eine hohe Datenqualität (Kapitel 5) vorliegen. Bearbeitet werden Datensätze von KPIs (z. B. Liefertreue oder ppm). Je größer die Datenbasis für die weiteren Berechnungen ist, desto robuster wird das Ergebnis [KÜH13]. Der Prozess des Gesamtmodells stellt sich in einer Übersicht wie folgt dar:

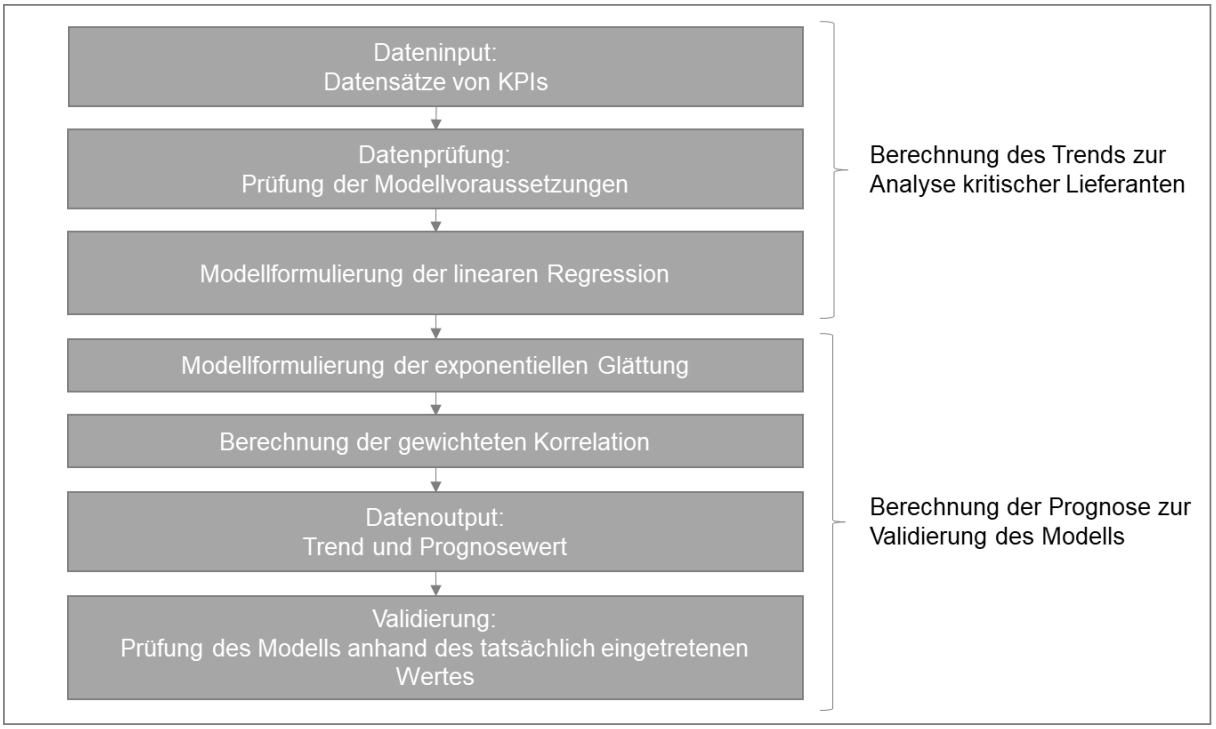


Bild 4-8: Prozess des Trend- und Prognosemodells
Quelle: Eigene Darstellung in Anlehnung an [DUS10c]

Kritische Lieferanten werden im TSM auf Basis des Trends identifiziert (Kapitel 3.4.1). Wenn ein Lieferant dem Lieferantensteuerkreis als kritisch gemeldet wird, werden Handlungsmaßnahmen beschlossen. Der Trend hat als Einzelinformation somit einen erheblichen Mehrwert für die Wissensgenerierung. Die Prognose dient lediglich zur Validierung des Gesamtmodells und hat keinen Einfluss auf das weitere Vorgehen zur Absicherung oder Wiederherstellung der Lieferantenleistung [DUS10c, HEL16, RAM17]. Auf Grund des Mehrwertes des Trends zur Wissensgenerierung wird im Weiteren dieser Teil des Trend- und Prognosemodells betrachtet.

Die Datensätze der KPIs werden zunächst als Dateninput aus den ERP-Systemen generiert und in das Modell eingepflegt. Anschließend werden im zweiten Prozessschritt die Voraussetzungen für die weiteren Berechnungen auf die Mindestvoraussetzungen hin überprüft. Die KPIs innerhalb eines Jahres sollten dabei beispielsweise monatlich erhoben sein. Da das Modell bereits seit mehreren Jahren in Industrieunternehmen eingesetzt wird, zeigen die Erfahrungen aus der Praxis, dass die besten Ergebnisse mit folgenden definierten Mindestvoraussetzungen erzielt werden [DUS10c, RAM17]:

- Mindestens 1 Wert pro KPI in den vergangenen zwei Monaten
- Mindestens 6 Werte pro KPI in den vergangenen 12 Monaten

Sind diese Voraussetzungen bei einem Datensatz nicht erfüllt, wird der Datensatz für die weitere Datenverarbeitung nicht mehr betrachtet. Somit entfällt für den Datensatz das Trendergebnis. FEINDT UND GRÜßING [FEI14] postulieren, dass ebenso die Prognosegenauigkeit mit einer Erweiterung der Datenbasis auf zwei bzw. drei Jahre um 15 bzw. 24 Prozent signifikant abnimmt. Der Grund dafür ist, dass innerhalb der Datenbasis zu viele Daten aus der Vergangenheit enthalten sind, die wenig Aktualität aufweisen. Diese werden jedoch auch für die Berechnung des Trends mit hinzugezogen, verändern so das Ergebnis und damit die Genauigkeit des Modells.

Zur Berechnung des Trends findet eine Regressionsrechnung zwischen den Größen x_i und y_i statt. Die Werte x_i repräsentieren in der vorliegenden spezifischen Anwendung den zeitlichen Verlauf auf der Abszisse, wobei die Werte y_i den jeweiligen Kennzahlenwert in Abhängigkeit der Zeit auf der Ordinate darstellen.

Zur Ermittlung der Regressionsgeraden wird üblicherweise die Methode der kleinsten Abweichungsquadrate angewendet [BLE15]. Zur Bestimmung der linearen Regressionsgeraden y_l gilt:

$$y_l = b_{xy}x + a_{xy} \tag{1}$$

Mit y_l Regressionswert an der Stelle x

Dabei gilt:

$$a_{xy} = y_m - b_{xy}x_m \tag{2}$$

Für die Berechnung des Anstiegs b_{xy} der Regressionsgeraden gilt:

$$b_{xy} = \frac{\sum_{i=1}^{n}(x_i - x_m)\cdot(y_i - y_m)}{\sum_{i=1}^{n}(x_i - x_m)^2} \tag{3}$$

Mit y_i Parameter y_i in Abhängigkeit von x_i

x_m Mittelwert von n x_i-Werten

y_m Mittelwert von n y_i-Werten

Im praktischen Umgang mitder Trendberechnung wird der Anstieg b_{xy} als Trend der lieferantenspezifischen Leistungserbringung bezeichnet. Da der Trend der lieferantenspezifischen Leistungserbringung als Indikator für eine steigende, gleichbleibende oder fallende Entwicklung der pro Monat gemessenen Lieferantenleistung betrachtet werden kann, wird dieser zur späteren Visualisierung (steigender, gleichbleibender oder fallender Trend in Rahmen von

Pfeilen, wie in Bild 4-9) in stark vereinfachter Form dargestellt [DUS18]. Für die visuelle Darstellung des Trends wird aufbauend auf HARTER [HAR15] eine Zuordnung von Zahlen verwendet.[1] Die Zuordnung erfolgt auf Basis der erfolgreichen Anwendungen im Rahmen vergangener wissenschaftlicher Praxisprojekte, in denen das Trend- und Prognosemodell verwendet worden ist [HAR15].[2] Mit dieser praxisorientierten Grundlage gilt im Weiteren folgende Zuordnung für den Trend der lieferantenspezifischen Leistungserbringung b_{xy}:

$$2:= \; b_{xy} \geq 0{,}07$$

$$1:= \; 0{,}07 \; > \; b_{xy} > 0{,}01$$

$$0:= \; 0{,}01 \; \geq \; b_{xy} > -0{,}01$$

$$-1:= \; -0{,}01 \; \geq \; b_{xy} > -0{,}07$$

$$-2:= \; b_{xy} \leq -0{,}07$$

Diese beschriebene Zuordnung wird im Visualisierungstool „Watchlist“ verwendet [RAM17, DUS18], um die grafische Darstellung des Trends der lieferantenspezifischen Leistungserbringung zu ermöglichen. Die grafische Darstellung des Trends der lieferantenspezifischen Leistungserbringung wird durch Pfeile übernommen, die mit der entsprechenden Zuordnung der b_{xy}-Werte verbunden sind. Dabei gibt es folgende Ausprägungen:

 :=2

 :=1

 :=0

 :=-1

 :=-2

Das allgemeine Ergebnis des Trend- und Prognosemodells ist eine Übersicht, die als kritisch definierte Lieferanten durch den negativen Trend (roter Pfeil) identifiziert. In Bild 4-9 ist beispielhaft ein anonymisiertes Analyseergebnis des Trend- und Prognosemodells dargestellt.

[1] In der vorliegenden Arbeit wird das Trend- und Prognosemodell erstmalig publiziert.

[2] Auf Basis einer empirischen Studie wurden abgeschlossene Forschungsprojekte in der Praxis ausgewertet, um eine hinreichend genaue Zuordnung zu bestimmen.

Watchlist - Indikator für kritische Lieferanten

Datum:

Beispiel

				PRÄVENTIV 12 Monate	PRÄVENTIV 3 Monate	REAKTIV Rang
		Leistungsbeschreibende Kriterien				
Information		Liefertreue				
Lieferanten-nummer	Auswahl für das Diagramm	aktueller Monat	Prognose t+1	12-Monats Trend	3-Monats Trend	Rang (aktuell)
L5		84%	93%	→	↓	6
L1	x	53%	69%	↘	↓	1
L2		67%	74%	↘	↘	2
L4		81%	88%	→	→	5
L6		70%	64%	→	↗	4
L3		67%	49%	↗	↑	2

Bild 4-9: Trend- und Prognosemodell im Rahmen der Watchlist
Quelle: Eigene Darstellung in Anlehnung an [RAM17]

Analysiert werden alle Lieferanten (L1 bis L6) in Bezug zur Leistungserbringung der Liefertreue. Zu sehen ist, dass die Merkmalsausprägung des aktuellen Monats sowie der entsprechende Prognosewert pro Lieferant ausgegeben wird. Mit den Pfeilen wird ein Indikator für einen schlechten Trendverlauf (rot), einen positiven Trendverlauf (grün) oder annähernd gleichbleibenden Trendverlauf (gelb) gegeben. Schlechte und damit rot dargestellte Trendverläufe sind als kritisch zu betrachten. Somit werden die Lieferanten, die dieses spezielle Datenmuster in ihren Datensätzen aufweisen, als kritische Lieferanten bezeichnet [DUS18]. Werden diese Trendverläufe im 12- oder 3-monatsbereich nach den kritischen Lieferanten gefiltert, wird dieses Vorgehen als Teil der Wissensgenerierung für ein präventives Handeln betrachtet [DUS18].

Zusätzlich ist es möglich, den Lieferanten anhand des Kennzahlen-Wertes im aktuellen Monat einen Rang zuzuweisen. Ein niedriger Rang weist in Bezug zur gesamten Lieferantenbasis auf einen kritischen Lieferanten hin, wo hingegen ein hoher Rang auf einen guten Lieferanten in Vergleich zur Lieferantenbasis hinweist. Dieser Vorgang ist jedoch reaktiv in Bezug auf das weitere Vorgehen zur Wiederherstellung oder Absicherung der Lieferantenleistung.

Das Trend- und Prognosemodell kommt bei einer regelmäßigen Zusammenarbeit zwischen Lieferant und Abnehmer zum Einsatz. Dabei ist es in das gestufte Bewertungsmodell eingebunden. Das geschieht über die folgenden drei Schritte:

1. Schritt: Die Ergebnisse der Leistungsmessung werden zur Priorisierung des Handlungsbedarfs genutzt. So wird z. B. bei einem stark negativen Trend ein dringender Handlungsbedarf kenntlich gemacht.

2. Schritt: Falls Lieferantenentwicklungsprojekte durchgeführt werden oder bereits abgeschlossen sind, werden bei positiven Trends Rückschlüsse auf die Wirksamkeit der entsprechenden Maßnahmen gezogen.

3. Schritt: Bei stark alternierenden Datenverläufen ist es mathematisch nicht möglich, eine realitätsnahe Prognose zu erstellen, sodass diese Werte ebenfalls markiert und anschließend kritisch betrachtet werden müssen.

Eine anwendungsorientierte Beschreibung des gestuften Bewertungsmodells ist in Kapitel 3.4.1 im Rahmen des TSM erfolgt. Zusammenfassend kann die frühzeitige Informationsgenerierung über potenzielle Risiken eine Steigerung der Leistungsdefizite bei kritischen Lieferanten durch die Einleitung präventiver Maßnahmen vermeiden, womit der Steuerungsaufwand und die Korrekturmaßnahmen zur Wiederherstellung der Leistungsfähigkeit des Lieferanten minimiert werden.

4.3.2 Clusteranalyse

Als Cluster werden „Häufungen oder Ballungen von Objekten, die zu allen anderen Objekten in demselben Cluster ähnlich und von allen Objekten in den anderen Clustern verschieden sind“ [VOS08], bezeichnet. Clusteranalytische Verfahren haben das Ziel, „die Beobachtungen in wenige homogene Gruppen oder Cluster zusammenfassen“ [SCH09c]. Bei der Bildung von Clustern steht die Zugehörigkeit eines Objektes nicht zu Beginn fest, sondern ergibt sich aus dem Ergebnis des Verfahrens [KÜS01]. Somit können ähnliche Merkmalsausprägungen zusammengefasst werden. In der vorliegenden Arbeit wird die Clusteranalyse verwendet, um in der nachfolgenden Assoziationsanalyse die Anzahl der möglichen Assoziationsregeln zu reduzieren (Kapitel 6).

Da die Datenbasis, die für die Clusteranalyse herangezogen wird, keiner spezifischen Verteilung unterzogen ist, wird die deterministische Vorgehensweise eines hierarchischen Clusterverfahrens angewendet [BAC10, WIN11]. Die Vorgehensweise wird nach SCHLITTGEN [SCH09c] sowie ESTER UND SANDER [EST00] mit folgendem Prozess beschrieben:

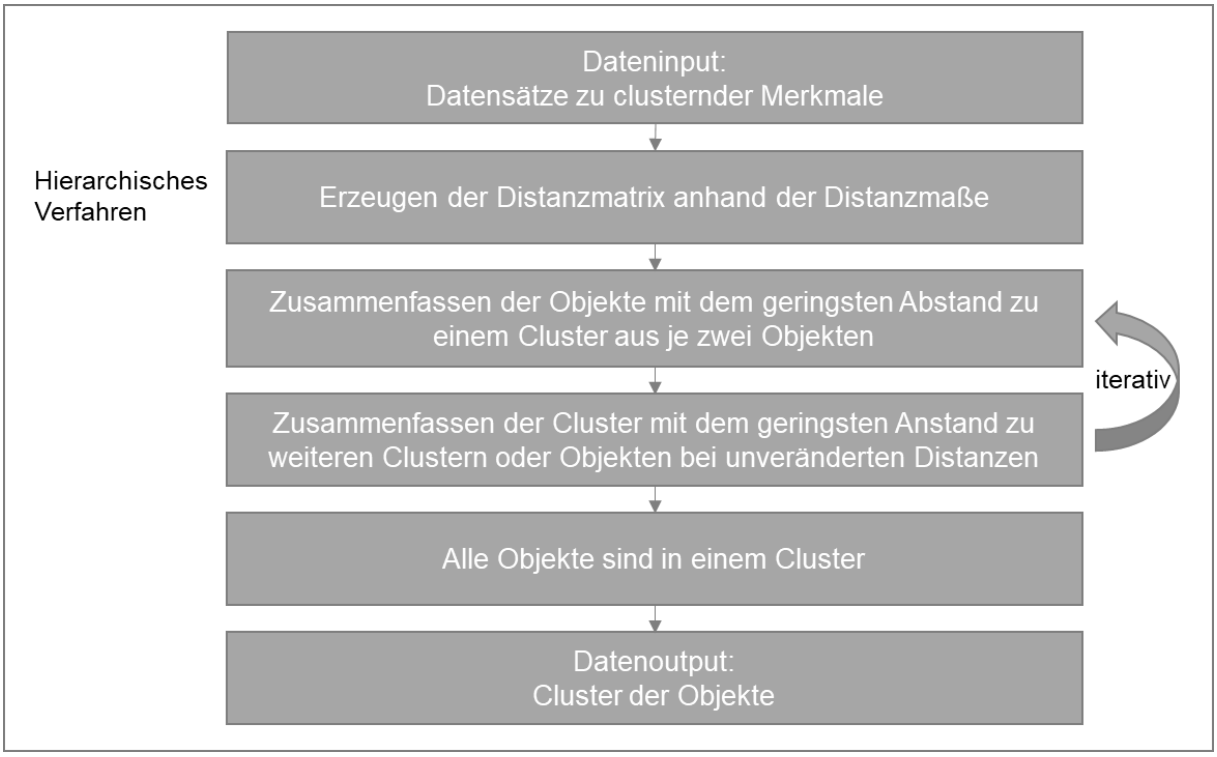


Bild 4-10: Prozess der hierarchischen Clusteranalyse
Quelle: Eigene Darstellung in Anlehnung an [EST00, SCH09c]

Da in der vorliegenden Arbeit metrisch skalierte Merkmale vorhanden sind, wird beispielsweise im weiteren Verlauf der vorliegenden Arbeit die Berechnung der Cluster mit Hilfe der Distanzmaße vorgenommen [MÜL13]. Die Clusteranalyse sieht dabei verschiedene Möglichkeiten zur

Berechnung von Distanzmaßen vor [STE11]. Das Distanzmaß gibt Aufschluss über die Ähnlichkeit verschiedener Merkmalsausprägungen. In der Literatur wird zur Berechnung der Distanzmaße die allgemeine L_p-Metrik verwendet [EST00, WAL01]:

$$dist(\alpha, \beta) = \sqrt[p]{\sum_{i=1}^{d}(\alpha_i - \beta_i)^p} \quad (4)$$

Mit α Ausprägung α des i-ten Merkmals

β Ausprägung β des i-ten Merkmals

Das Distanzmaß ist vom Parameter p abhängig. Der Parameter p repräsentiert eine Gewichtung auf einer größeren Distanz [PAS96]. Da eine Gewichtung der Distanzen in der vorliegenden Arbeit nicht notwendig ist, wird $p = 1$ gesetzt. Eine L_1-Metrik, als Sonderfall der L_p-Metrik, errechnet die Summe der rechtwinkligen Entfernungen zwischen den Merkmalsausprägungen. Da dieses Verfahren zur Routenplanung eingesetzt wird, wird es vereinfacht auch als Manhattan-Distanz bezeichnet [EST00]:

Manhattan-Distanz: $$dist(\alpha, \beta) = |\alpha_1 - \beta_1| + \cdots + |\alpha_d - \beta_d| \quad (5)$$

Da bei der hierarchischen Clusterbildung der Merkmalsausprägungen immer die minimalen Distanzen von zwei Clustern errechnet werden, kann mit dem Single-Linkage-Verfahren gearbeitet werden [EST00, WIN11]. Dies ist eine agglomerative Methode, bei der „der Abstand zwischen zwei Gruppen durch den kürzesten Abstand definiert ist, der zwischen zwei Gruppenmitgliedern existiert“ [SCH09c]. Somit gilt im Weiteren für diese Arbeit, dass die Distanz zwischen den zwei verschiedenen Klassen A und B gleich der kleinsten Distanz zwischen einer Merkmalsausprägung α und einer Merkmalsausprägung β ist [KAU84]:

$$dist(\mathrm{A}, \mathrm{B}) = min\, dist(\alpha, \beta), \text{ wobei } \alpha \in \mathrm{A}, \beta \in \mathrm{B} \quad (6)$$

Berechnet werden die Cluster bei der hierarchischen Clusterbildung bottom up. Aus den errechneten minimalen Abständen der Merkmalsausprägungen entsteht eine $d\ x\ d$ Distanzmatrix D, die wie folgt dargestellt wird:

$$D = \begin{matrix} \\ \text{Merkmalsausprägung d bis 1} \end{matrix} \overset{\text{Merkmalsausprägung 1 bis d}}{\begin{pmatrix} 0 & & & \\ & 0 & & \\ & & \ddots & \\ & & & 0 \end{pmatrix}}$$

Abstand zwischen zwei Merkmalsausprägungen

Diagonale

Abstand zwischen zwei Merkmalsausprägungen

Bild 4-11: Allgemeine Darstellung einer Distanzmatrix
Quelle: Eigene Darstellung

Die Vereinigung der Merkmalsausprägungen zu den verschiedenen Clustern erfolgt schrittweise, bis alle Merkmalsausprägungen in einem Cluster vereinigt sind. Das Ergebnis ist ein Dendrogramm (Baumstruktur), welches als Wurzeln alle einzelnen Merkmalsausprägungen enthält [MÜL13]. Die einzelnen Cluster verschmelzen somit stufenweise ineinander, bis nur noch ein großes Cluster über alle Merkmalsausprägungen vorhanden ist.

Um die optimale Clusteranzahl zu erhalten, wird auf den einzelnen Verschmelzungsstufen das Verschmelzungsniveau hinzugezogen. Das Verschmelzungsniveau gibt den Distanzzuwachs bei der Clusterbildung an [BAC10]. Alle Objekte innerhalb eines Clusters c sind zum angegebenen Verschmelzungsniveau kleiner oder gleich [BAC10]. Ist ein Zuwachs des Verschmelzungsniveaus zu erkennen, kann die zugehörige Clusteranzahl von $c-1$ als Lösung angenommen werden [BAC10]. Das Vorgehen der Clusterbildung ist im Anhang B anhand eines Beispiels dokumentiert. Durch die Clusterbildung entstehen Intervalle [NAU96]. Jedes Intervall entspricht im Weiteren einem Attribut bei der Betrachtung der Assoziationsanalyse. Die Ergebnisse der Clusteranalyse (Attribute) gehen nun als Input in die Assoziationsanalyse ein.

4.3.3 Assoziationsanalyse

Allgemein werden unter Assoziationen Zusammenhänge verstanden [EST00]. Eine Anwendung der Assoziationsanalyse ist die Warenkorbanalyse. Dabei wird die gleichzeitig gekaufte Ware eines Kunden untersucht [BOD03]. Somit ergeben sich Assoziationsmuster [KÜS01]. Bei der Suche nach Zusammenhängen können zwei aufeinander aufbauende Ansätze verwendet werden [EST00]:

- Apriori-Algorithmus zur Bildung allgemeiner Assoziationsregeln
- Erstellung quantitativer Assoziationsregeln auf Basis der Berechnungsgrundlagen des Apriori-Algorithmus

Ziel ist es, allgemeine Assoziationsregeln innerhalb einer Datenmenge zu finden. Somit wird zunächst der Apriori-Algorithmus näher erörtert. Allgemein lässt sich das Ziel dieses Algorithmus wie folgt beschreiben:

Wenn Ereignisse $x_1, \dots, x_n$ auftreten, treten oft auch die Ereignisse $y_1, \dots, y_n$ auf [BOD03]. Diese Zusammenhänge zwischen der Prämisse (Ursache) $\{x_1, \dots, x_n\}$ und der Implikation (Konsequenz) $\{y_1, \dots, y_n\}$ werden wie folgt dargestellt:

$$\{x_1, \dots, x_n\} \Rightarrow \{y_1, \dots, y_n\} \tag{7}$$

Aus dem Bereich Marketing kommend drückt CLEVE [CLE16] diese Zusammenhänge wie folgt für einen Warenkorb aus: „Wer Produkt A kauft, kauft häufig auch Produkt B“ [CLE16]. Wird diese Annahme zum Steuern der externen Wertschöpfungsnetzwerke genutzt, kann folgendes allgemein ausgedrückt werden:

Wenn Merkmal A bestimmte Ausprägungen hat (Prämisse X), hat Merkmal B (Implikation Y) häufig ebenfalls eine spezifische Ausprägung. Diese Regel bezieht sich dann immer auf die gesamte Datenbasis D, in der alle Lieferanten L mit den zugehörigen Merkmalsausprägungen (z.B. konkrete Kennzahlen eines Lieferanten für einen definierten Zeitraum) vertreten sind.

Bei der Assoziationsanalyse werden somit die Merkmalsausprägungen untersucht. Dabei wird allgemein folgendermaßen vorgegangen [EST00, CLE16]:

1. Bildung einer Boolschen Datenbasis
2. Attributsbildung für die Boolsche Datenbasis, wobei dafür jede Merkmalsausprägung einem neu gebildeten Attribut der Boolschen Datenbasis entspricht
3. Einsetzen der Attribute

Boolsche Bezeichnungen drücken eine zweiwertige Logik aus. Eine 1 entspricht dabei einem Wahrheitswert und eine 0 keinem Wahrheitswert [PER09]. Anders ausgedrückt bedeutet dies:

```
0 = FALSE
```

```
1 = TRUE
```

Durch dieses Vorgehen wird eine Vielzahl von Attributen gebildet. Besonders bei den Merkmalen, die eine Kennzahl repräsentieren, wäre jedes Attribut eine spezifische Ausprägung der Kennzahl (Attributsausprägung). Durch dieses Vorgehen wird die Boolsche Datenbasis je nach Anzahl der verschiedenen Ausprägungen sehr groß, was im weiteren Verlauf der Assoziationsanalyse zu einer hohen Anzahl von Assoziationsregeln und somit auch zu einem hohen Berechnungsaufwand führt.

Durch die vorgeschaltete Clusteranalyse sind verschiedene Cluster der Merkmalsausprägungen entstanden, die nun als Attribute betrachtet werden. Mit der Bildung dieser Cluster werden für „große Wertebereiche nicht zu viele Attribute erzeugt“ [PET09]. Jedes Cluster entspricht somit im Weiteren einem Attribut in der Boolschen Datenbasis. Durch den Einsatz der Cluster als Attribut in die Boolsche Datenbasis wird betrachtet, ob ein Wert der Datenbasis eines Lieferanten in einem Cluster enthalten ist.

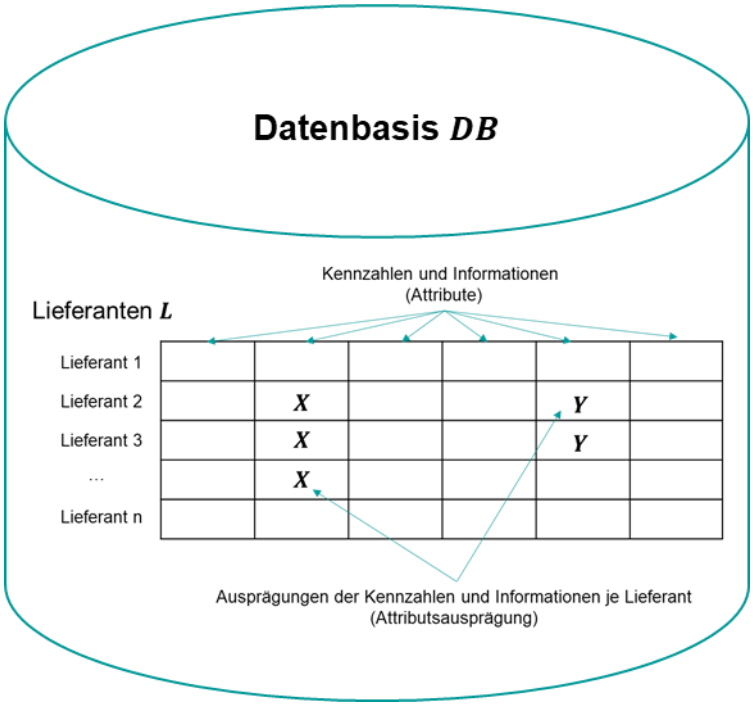


Bild 4-12: Zusammensetzung der Komponenten einer Assoziationsregel in Bezug auf die Datenbasis
Quelle: Eigene Darstellung

Durch die Assoziationsanalyse werden Regeln generiert, die die Aussage haben, welche Kombination spezifischer Attributsausprägungen möglicherweise eine bestimmte (Menge) weiterer Attributsausprägungen hervorruft. Dabei wird bei der Regelerstellung auf eine Definition von Hypothesen verzichtet. Die Assoziationsregeln werden auf Basis der verschiedenen Kombinationen der Attributsausprägungen erzeugt. Dabei ist es möglich, dass sehr viele Assoziationsregeln erzeugt werden. Diese Vielzahl an möglichen Assoziationsregeln erschwert das Auffinden relevanter, nützlicher Regeln [GAG98]. Bei der Auswahl relevanter und nützlicher

Regeln unterstützen Interessantheitsmaße. Interessantheitsmaße geben an, wie aufschlussreich (interessant) eine Regel für die entsprechende Aufgabenstellung ist [BEE03]. Somit bestimmt ein Interessantheitsmaß die Qualität der Assoziationsregel [CLE16]. Bei den Interessantheitsmaßen wird unterschieden in:

- Support
- Konfidenz
- Lift

Der Support einer Assoziationsregel stellt deren relative Häufigkeit dar, mit der die verschiedenen Attributsausprägungen dieser Regel vorkommen. Die Menge X stellt dabei die Menge der Prämissen und die Menge Y die Menge der Implikationen dar. Dabei gilt [EST00]:

$$sup(X) = \frac{|\{L \in D | X \subseteq L\}|}{|D|} \tag{8}$$

$$sup(X \to Y) = \frac{|\{L \in D | (X \cup Y) \subseteq L\}|}{|D|} \tag{9}$$

Je größer der Support ist, desto wichtiger ist, laut Literatur [SUM06, GLU08, GAB09, CLE16], die Relevanz der Regel.

Die Konfidenz $conf$ wird „als ein Maß für das Vertrauen in eine Regel“ [CLE16] bezeichnet. Das Interessantheitsmaß der Konfidenz wird dabei wie folgt berechnet [EST00, HET01]:

$$conf(X \to Y) = \frac{Support(X \to Y)}{Support(X)} \tag{10}$$

Die Konfidenz misst die Stärke der aufgestellten Regel [VOS08]. Dabei ist davon auszugehen, dass eine hohe Konfidenz auch im vorliegenden Fall ein hohes Maß an Vertrauen in die Regel beinhaltet. Da jedoch beide Interessantheitsmaße mathematisch voneinander abhängig sind, ist eine differente Aussage nicht zu erwarten. BEEKMANN [BEE03] und VOSSEN [VOS08] schlagen hierfür ein alternatives Interessantheitsmaß, den Lift, vor. Das Interessantheitsmaß Lift ist dabei ein Maß für die Wahrscheinlichkeit $P(Y)$ des Eintretens der Implikation Y. Je höher der Lift ist, desto höher ist die Korrelation von Prämisse und Implikation [BÜH08]. Das Interessantheitsmaß errechnet sich für die Regel $X \Rightarrow Y$ aus:

$$lift(X \Rightarrow Y) \coloneqq \frac{P(X \cup Y)}{P(X) \cdot P(Y)} \tag{11}$$

In der Datenbasis D sind verschiedene Datensätze zu den Lieferanten enthalten. Dies können beispielsweise KPIs in Form von Hardfacts, Trends der KPIs oder auch Informationen zu auftretenden Risikoereignissen sein. Diese Datensätze sind dynamisch und damit in einem bestimmten Zeitraum veränderlich. Stammdaten, die ebenfalls ein Teil der Datenbasis sind, gelten als statisch und damit als relativ unveränderlich. Stammdaten werden nur in wenigen Fällen verändert und sind unabhängig von den operativen Geschäftsprozessen [GAD17]. Stammdaten von Lieferanten können beispielsweise die Adresse des Geschäftssitzes oder auch Namen von Ansprechpartnern und Kontaktdaten enthalten.

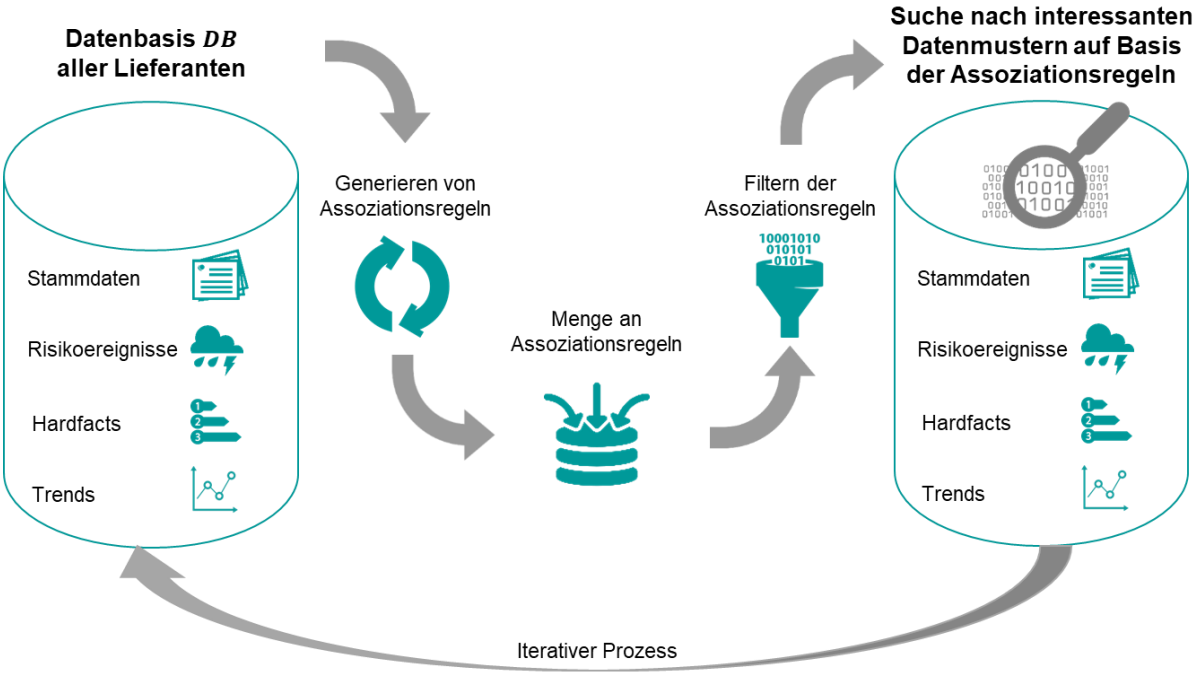


Bild 4-13: Anwendung der Assoziationsanalyse innerhalb der Lieferantenbasis
Quelle: Eigene Darstellung

Auf Grundlage der Datenbasis aller Lieferanten werden Assoziationsregeln zum Auffinden von potenziell kritischen Lieferanten mit Hilfe von Datenmustern generiert. Die verschiedenen Regeln finden im Rahmen des Vorgehens der Assoziationsanalyse Anwendung, wobei die Ergebnisse auf ihre Interessantheit geprüft werden (Kapitel 4.3.4 und Kapitel 6). Die Prüfung auf Interessantheit der Ergebnisse wird situationsabhängig vorgenommen, da für verschiedene Anwendungsfälle eine unterschiedliche Relevanz der Ergebnisse vorliegen kann. Diese Relevanz kann zunächst nicht mit den beschriebenen Interessantheitsmaßen (Support, Konfidenz und Lift) bestätigt werden. Das Verhalten der Interessantheitsmaße muss auf Basis einer Relevanzprüfung über einen längeren Zeitraum bei bereits relevanten, quantitativen Assoziationsregeln untersucht werden. Erst dann können Rückschlüsse gezogen werden, ab welchem Wert bzw. bis zu welchem Wert ein Interessantheitsmaß eine bestimmte Aussage hat.

Mit Hilfe der Assoziationsanalyse werden große Datenmengen auf Basis quantitativer Assoziationsregeln verarbeitet [SRI96, BÜC98, BEN01]. Zusätzlich sind eine einfache Bedienbarkeit für den Anwender sowie eine hohe Transparenz kennzeichnend [BEN01]. Die Ergebnisse sind jederzeit reproduzierbar. Dadurch könnte die Assoziationsanalyse mit Hilfe von IT-Systemen automatisiert werden [BEN01]. Bisherige Data Mining IT-Systeme können jedoch die in der vorliegenden Arbeit verwendete Berechnung zur Generierung quantitativer Assoziationsregeln nicht abbilden [NOR12, KOT15].

Dieses neu generierte Wissen wird zur Absicherung und Wiederherstellung der Leistungsfähigkeit von Lieferanten genutzt (Kapitel 4.5.6). Ergeben sich zusätzliche Informationen aus dieser Absicherung bzw. Wiederherstellung der Leistungsfähigkeit von Lieferanten, werden diese als Attributsausprägung mit in die Generierung weiterer Assoziationsregeln aufgenommen. Somit können zusätzliche relevante Assoziationsregeln gefunden werden. Das Verfahren der Assoziationsanalyse sowie der anschließenden Relevanzprüfung (Kapitel 4.3.4) ist somit iterativ [CLE16]. Je mehr iterative Prozesse durchlaufen werden, desto interessanter

werden die Assoziationsregeln. Grundlage dafür ist aber zunächst die Prüfung der quantitativen Assoziationsregeln auf Relevanz. Diese Relevanzprüfung wird im folgenden Kapitel betrachtet.

4.3.4 Relevanzprüfung

Die Ergebnisse der in dieser Arbeit genutzten Art der Assoziationsanalyse werden als quantitative Assoziationsregeln bezeichnet. Durch die Kombination der Attribute wird eine Vielzahl von quantitativen Assoziationsregeln aufgestellt [MÜL13], von denen nur wenige die entsprechende Relevanz aufweisen. Innerhalb der Datenbasis werden verschiedene Kombinationen der Attribute als Regel aufgenommen. Je mehr Attribute es gibt, desto mehr mögliche quantitative Assoziationsregeln entstehen. Nachdem die Gesamtheit der quantitativen Assoziationsregeln generiert worden ist, liegt somit die primäre Herausforderung der Datenmodellierung in der Identifikation relevanter, quantitativer Assoziationsregeln. Die nun folgende Relevanzprüfung ist in diesem Kapitel zunächst generisch beschrieben. Ein konkretes Beispiel dieser Prüfung ist in Kapitel 6 zu finden.

Um die Gesamtheit der möglichen quantitativen Assoziationsregeln auf relevante zu reduzieren, wird zunächst geprüft, wie viele Assoziationsregeln theoretisch auf Basis von definierten Rahmenbedingungen generiert werden können. Somit ist es möglich, die Gesamtanzahl aller möglichen quantitativen Assoziationsregeln zu berechnen. Alle Attribute werden in den Assoziationsregeln miteinander kombiniert. Die Reihenfolge der Kombination ist dabei für die Aussage einer quantitativen Assoziationsregel nicht relevant, da die Aussage selbst gleichbleibt.

Um die Gesamtanzahl aller möglichen quantitativen Assoziationsregeln zu berechnen, werden zunächst für die Erzeugung der Assoziationsregeln Rahmenbedingungen festgelegt. Dabei ist zu beachten, dass eine Regel aus zwei zusammengehörenden Elementen besteht: einem Regelkopf und einem Regelrumpf. „Der Regelkopf drückt eine Bedingung aus, die erfüllt sein muss, damit der Regelrumpf wahr wird.“ [GEH05]

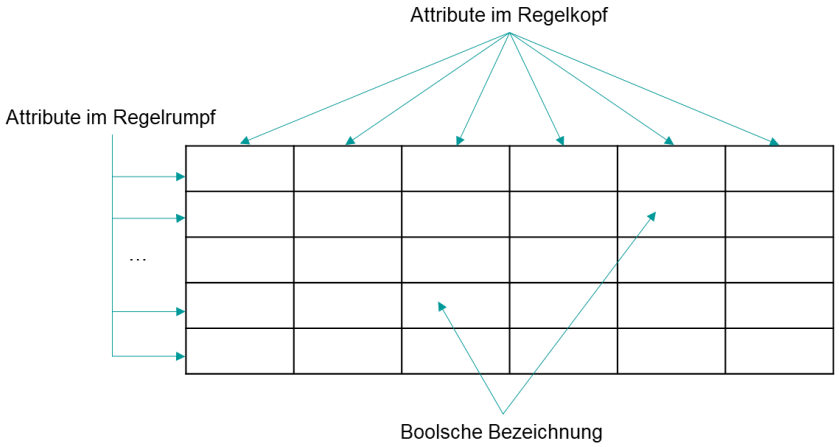


Bild 4-14: Zusammenhang zwischen Regelkopf und Regelrumpf
Quelle: Eigene Darstellung

Anhand eines vereinfachten Beispiels auf Basis von verschiedenen leistungsbeschreibenden Merkmalen (Attributen) aus Bild 4-30 wird somit im Folgenden die Formel zur Berechnung der Gesamtanzahl aller möglichen quantitativen Assoziationsregeln hergeleitet. Folgende Attribute werden zunächst verwendet:

- Liefertreue (LT)
- parts per million (ppm)

Diese beispielhaften Attribute werden mit boolschen Bezeichnungen beschrieben, wenn die Attribute dem Regelkopf oder Regelrumpf einer Assoziationsregel zugeordnet werden können. Aus der Zuordnung der Attribute zu Regelkopf oder Regelrumpf werden folgende, praxisnahe Rahmenbedingungen angewendet:

- Alle Attribute sind unterscheidbar.
- Leere Mengen sind im Regelkopf und Regelrumpf nicht vorhanden (es werden n Elemente ausgewählt).
- Die Reihenfolge der Attribute wird im Regelkopf und Regelrumpf nicht berücksichtigt.
- Attribute treten im Regelkopf und Regelrumpf einmalig auf und können somit nicht mehrfach ausgewählt werden.
- Es werden für eine Assoziationsregel nicht zwingend alle zur Verfügung stehenden Attribute ausgewählt.

Wird in der vorliegenden Arbeit weiterhin die *Generierung quantitativer Assoziationsregeln* beschrieben, wird damit die konkrete Anwendung der beschriebenen Rahmenbedingungen auf die Zuordnung der Attribute zu Regelkopf und Regelrumpf ausgedrückt.

Tabelle 4-1: Zuordnung von zwei Attributen zu Regelkopf und Regelrumpf
Quelle: Eigene Darstellung

	LT	ppm	Summe
LT	0	1	1
ppm	1	0	1
Summe			**2**

Bei zwei verwendeten Attributen liegt die Gesamtanzahl aller möglichen, quantitativen Assoziationsregeln bei 2. Werden nun drei Attribute zur Generierung der Assoziationsregeln verwendet, ergibt sich folgende Darstellung:

- Liefertreue (LT)
- parts per million (ppm)
- (Produktions-)Standort (PS)

Tabelle 4-2: Zuordnung von drei Attributen zu Regelkopf und Regelrumpf
Quelle: Eigene Darstellung

	LT	ppm	PS	LT, ppm	LT, PS	ppm, PS	LT, ppm, PS	Summe
LT	0	1	1	0	0	1	0	3
ppm	1	0	1	0	1	0	0	3
PS	1	1	0	1	0	0	0	3
LT, ppm	0	0	1	0	0	0	0	1
LT, PS	0	1	0	0	0	0	0	1
Ppm, PS	1	0	0	0	0	0	0	1
LT, ppm, PS	0	0	0	0	0	0	0	0
Summe								**12**

Die Gesamtanzahl aller möglichen, quantitativen Assoziationsregeln liegt bei drei verwendeten Attributen somit bei 12. Zusätzlich ergibt sich innerhalb der Zeilensummen eine Zahlenfolge aus 1 und 3.

Im Anhang C wird weiterhin die Verwendung von vier Attributen dargestellt. Dabei liegt die Gesamtanzahl aller möglichen, quantitativen Assoziationsregeln in Tabelle C-1 bei 50, wobei die Zeilensummen aus der Zahlenfolge 1, 3 und 7 besteht. Weitere Untersuchungen ergeben, dass bei der Zuordnung von fünf Attributen zum Regelkopf und Regelrumpf eine Gesamtanzahl aller möglichen, quantitativen Assoziationsregeln von 180 berechnet wird. Die Zahlenfolge innerhalb der Zeilensummen besteht aus 1, 3, 7 und 15, was auf die Mersenne-Zahlenfolge hinweist.

„Zahlen der Form $2^n - 1$ heißen Mersenne Zahlen." [REI07, GOB18] Die Mersenne Zahlenfolge bis n=5 beginnt mit 1,3,7,15 und 31. Die Zahlenfolge wurde nach ihrem Entdecker, dem Mathematiker Marin Mersenne benannt (1588-1648). [GOB18]

Für die Berechnung der Gesamtmenge aller möglichen quantitativen Assoziationsregeln werden auf Basis der definierten Rahmenbedingungen zunächst die folgenden kombiniert:

- *Alle Attribute sind unterscheidbar.*
- *Leeren Mengen sind im Regelkopf und Regelrumpf nicht vorhanden (es werden n Elemente ausgewählt).*
- *Die Reihenfolge der Attribute wird im Regelkopf und Regelrumpf nicht berücksichtigt.*
- *Attribute treten im Regelkopf und Regelrumpf einmalig auf und können somit nicht mehrfach ausgewählt werden.*

Diese Rahmenbedingungen lassen die Verwendung des Binominalkoeffizienten ohne Zurücklegen und ohne Berücksichtigung der Reihenfolge zu. Mit $0! = 1$ gilt [SCH08a]:

$$\binom{k}{n} = \binom{k}{k-n} \tag{12}$$

Zusätzlich zum Binominalkoeffizient wird mit der Rahmenbedingung

- *Es werden für eine Assoziationsregel nicht zwingend alle Attribute ausgewählt.*

die Mersenne-Zahlenfolge der Zeilensummen berücksichtigt. Aus diesem Grund ergibt sich für die Berechnung der Gesamtanzahl aller möglichen quantitativen Assoziationsregeln unter Berücksichtigung des Regelkopfes und des Regelrumpfes:

$$\sum_{n=1}^{k-1}(2^n - 1) \cdot \binom{k}{k-n} \tag{13}$$

Mit: k = Gesamtmenge der zu betrachtenden Attribute in der Assoziationsanalyse

n = Attribut in einer quantitativen Assoziationsregel

Zur Validierung der Formel (13) werden nun die Ergebnisse bis $k = 5$ herangezogen.

Tabelle 4-3: Validierung der Formel zur Errechnung der Gesamtanzahl aller möglichen, quantitativen Assoziationsregeln anhand der definierten Rahmenbedingungen

Quelle Eigene Darstellung

k	$\sum_{n=1}^{k-1}(2^n - 1) \cdot \binom{k}{k-n}$	**Validierung auf Basis manueller Überprüfung**	**Nachweis**
2	$(2^1 - 1) \cdot \binom{2}{2-1} = 2$	2	Tabelle 4-1
3	$\left[(2^1 - 1) \cdot \binom{3}{3-1}\right] + \left[(2^2 - 1) \cdot \binom{3}{3-2}\right] = 12$	12	Tabelle 4-2
4	$\left[(2^1 - 1) \cdot \binom{4}{4-1}\right] + \left[(2^2 - 1) \cdot \binom{4}{4-2}\right] + \left[(2^3 - 1) \cdot \binom{4}{4-3}\right] = 50$	50	Tabelle C-1
5	$\left[(2^1 - 1) \cdot \binom{5}{5-1}\right] + \left[(2^2 - 1) \cdot \binom{5}{5-2}\right] + \left[(2^3 - 1) \cdot \binom{5}{5-3}\right] + \left[(2^4 - 1) \cdot \binom{5}{5-4}\right] = 180$	180	Weitere Untersuchungen im Rahmen der vorliegenden Arbeit

Mit der Ausgangsbasis, dass die Gesamtanzahl aller möglichen, quantitativen Assoziationsregeln errechenbar ist, können die quantitativen Assoziationsregeln nun auf ihre mögliche Relevanz in Bezug auf eine praktische Nutzung geprüft und entsprechend reduziert werden. Das konkrete Vorgehen wird nun in einem stufenweisen Vorgehen näher betrachtet. Bild 4-15 dient dabei einem Überblick:

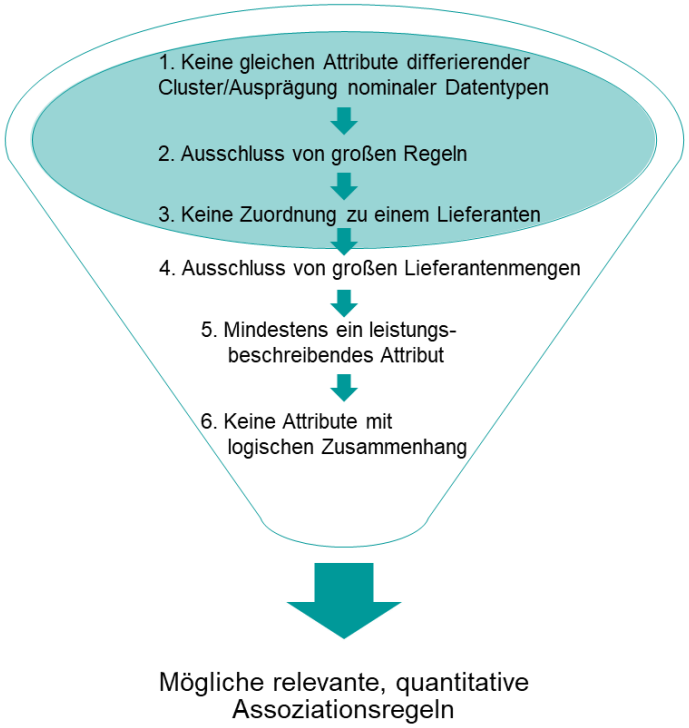


Bild 4-15: Stufenweises Vorgehen zur Relevanzprüfung
Quelle: Eigene Darstellung

Die Stufen werden nun näher betrachtet:

Stufe 1: Keine gleichen Attribute differierender Cluster oder Ausprägung nominaler Datentypen

Bisher sind alle Kombinationsmöglichkeiten der Attribute innerhalb der quantitativen Assoziationsregeln betrachtet worden. Es besteht somit die Möglichkeit, dass verschiedene Cluster eines Merkmals, die alle als Attribute in die Assoziationsanalyse eingehen (Kapitel 2.3.4.4), innerhalb einer quantitativen Assoziationsregel vorkommen.

Beispiel: Durch die Clusteranalyse werden die Merkmalsausprägungen eines Merkmals A in zwei Cluster aufgeteilt (Attribut A.1 und Attribut A.2). Beide Cluster gehen als Attribute in die Assoziationsanalyse ein. Bei zwei Clustern eines Merkmals A kann somit folgender vereinfachter Fall einer quantitativen Assoziationsregel auftreten:

$$Attribut\ A.1, Attribut\ A.2,\ Attribut\ B.1 \rightarrow Attribut\ C.1$$

Bezogen auf die Gesamtmenge der Objekte wären in Attribut A.1 und Attribut A.2 alle Objekte enthalten. Diese quantitative Assoziationsregel ist somit von der Aussagekraft gleich zu folgender quantitativen Assoziationsregel:

$$Attribut\ B.1 \rightarrow Attribut\ C.1$$

Eine Betrachtung von Attributen, die gemeinsam eine Grundgesamtheit darstellen, werden innerhalb einer quantitativen Assoziationsregel ausgeschlossen. Alle Attribute, die in verschiedene Cluster unterteilt sind, werden somit durch die Formel (13) nur einmal betrachtet. Die Clusteranzahl eines Attributes wird für die Kombination vernachlässigt. Somit gilt:

k = Gesamtmenge der zu betrachtenden Attribute in der Assoziationsanalyse vor der Clusteranalyse

n = Attribut in einer quantitativen Assoziationsregel

Auf dieser Basis wird die Anzahl der generierten quantitativen Assoziationsregeln erheblich reduziert.

Stufe 2: Ausschuss von großen Regeln

Um die Anzahl der Regeln auf ein analysierbares Maß zu reduzieren, werden nun alle Regeln ausgeschlossen, die zu viele Attribute in einer Regel enthalten. Die Rahmenbedingungen zur Generierung der quantitativen Assoziationsregeln sieht vor, dass die Regeln $n + 1$ aufsteigend erzeugt werden. Das heißt, dass pro k ein Attribut in einer Regel hinzu kommt. Somit sind kleine Regeln mit wenigen Attributen in großen Regeln mit vielen Attributen enthalten. Bild 4-16 stellt einen beispielhaften Fall zur Visualisierung dar.

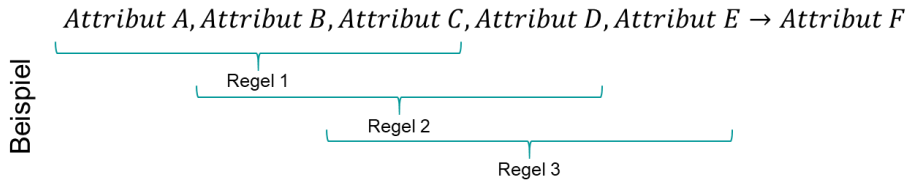


Bild 4-16: Kombination von Assoziationsregeln
Quelle: Eigene Darstellung

Innerhalb der quantitativen Assoziationsregeln werden beispielhaft die Regeln 1 bis 3 generiert. Diese lauten:

$Attribut\ A,\ Attribut\ B,\ Attribut\ C \rightarrow Attribut\ F$

$Attribut\ B,\ Attribut\ C,\ Attribut\ D \rightarrow Attribut\ F$

$Attribut\ C,\ Attribut\ D,\ Attribut\ E \rightarrow Attribut\ F$

Diese drei Regeln sind jedoch auch in der quantitativen Assoziationsregel in Bild 4-16 enthalten. Somit ist die quantitative Assoziationsregel aus Bild 4-16 obsolet, da Teile dieser Regel bereits generiert worden sind. Es ist also bei Bedarf eine Kombination der kleineren Regeln möglich, um eine große Regel darzustellen. Die Grenze, wo die zumutbare Anzahl enthaltener Attribute liegt, kann differieren. Diese Grenze muss abhängig im Prozessschritt „Umfeldverständnis“ definiert werden.

Stufe 3: Keine Zuordnung zu einem Lieferanten

Quantitative Assoziationsregeln, die keinem Lieferanten aus der Lieferantenbasis zuzuordnen sind, werden nun gefiltert und reduziert. Indikator dafür ist das Interessantheitsmaß Support sup als relative Häufigkeit. Dabei gilt:

$$\sup(X \rightarrow Y) = 0 \tag{14}$$

Liegt dieser Fall für quantitative Assoziationsregeln vor, sind die entsprechenden Regeln zum Auffinden potenziell kritischer Lieferanten nicht zielführend, da keine Lieferanten aus der Lieferantenbasis zuzuordnen sind. Diese quantitativen Assoziationsregeln werden somit wiederum ausgeschlossen.

Stufe 4: Ausschluss von großen Lieferantenmengen

Das Ziel der Assoziationsanalyse ist es, frühzeitig Risiken bei Lieferanten zu erkennen, die in ihren Datenmustern oder durch die Zugehörigkeit zu einer Regel auffallen. Wären viele Lieferanten auffällig, könnte das Rückschlüsse auf eine nachteilige Beschaffungspolitik sowie eine zu verbessernde Umsetzung des strategischen und operativen Lieferantenmanagements sein (Kapitel 2.2.2). Liegt dieser Fall nicht vor, können quantitative Assoziationsregeln, denen große Teilmengen aus der Lieferantenbasis zugeordnet sind, ausgeschlossen werden.

Stufe 5: Mindestens ein leistungsbeschreibendes Attribut

Zur frühzeitigen Risikoidentifikation wird die Leistungsfähigkeit aller Lieferanten der Lieferantenbasis beurteilt (Kapitel 3.4.1). Liegt in einer quantitativen Assoziationsregel kein leistungsbeschreibendes Attribut vor, hat diese Regel demnach keine Risikorelevanz und kann ebenfalls ausgeschlossen werden. Eine Regel, die sich beispielsweise wie folgt zusammensetzt, sagt demnach nichts über die Leistungsfähigkeit der Lieferantenbasis aus:

$$Währung,\ Produktionsland \rightarrow Anzahl\ der\ Mitarbeiter$$

Stufe 6: Keine Attribute, die in einem logischen Zusammenhang stehen

Bei der Assoziationsanalyse werden zur Erzeugung der quantitativen Assoziationsregeln alle Attribute miteinander kombiniert. Es kann dabei vorkommen, dass Attribute einen Einfluss aufeinander haben und damit voneinander abhängig beziehungsweise in einem sachlogischen Zusammenhang zueinanderstehen. Dies kann folgende Ursachen haben:

- Kausalität
- Korrelation
- Berechnung von Kennzahlen
- Logik

Im letzten Schritt der Relevanzprüfung werden somit Attribute, die in einem sachlogischen Zusammenhang zueinanderstehen, innerhalb einer quantitativen Assoziationsregel untersucht. Beispielsweise stehen die Attribute der Kennzahl ppm sowie die Anzahl auftretender Fehlerreporte in einem Zeitraum in einem solchen Zusammenhang. Liegen Fehlerreporte vor, steigt auch die ppm (Kapitel 5.2.4).

Sind Attribute voneinander abhängig oder bedingen sich gegenseitig, verliert somit die quantitative Assoziationsregel an Aussagekraft. In diesem Fall kann auf diese quantitative Assoziationsregel verzichtet werden. Damit sind die Stufen eins bis sechs der Relevanzprüfung abgeschlossen.

Durch das stufenweise Vorgehen zur Relevanzprüfung von quantitativen Assoziationsregeln wird die Anzahl der Regeln auf ein vermeintliches Minimum reduziert. Regeln, die keine Relevanz für das Umfeldverständnis haben, sind nun von weiteren Betrachtungen ausgeschlossen. Das Ergebnis dieses Prozesses sind relevante, quantitative Assoziationsregeln. Die relevanten, quantitativen Assoziationsregeln werden weiter analysiert und bewertet, um potenziell kritische Lieferanten zu finden.

Für eine weitere Analyse wird implizites Wissen (Kapitel 4.2) benötigt. Somit entfällt eine Automatisierung der Analyse. Es wird auf Erfahrungswerte und Softfacts der Fachbereiche zurückgegriffen. Um nun relevante, quantitative Assoziationsregeln herauszufiltern, denen bestimmte Lieferantengruppen zuzuordnen sind, postuliert CLEVE [CLE16] weitere Dimensionen der Interessantheit:

Validität:	Maß, ob das Datenmuster oder die Assoziationsregel auch für weitere neue Attribute gültig ist
Neuartigkeit:	Kriterium, ob das neue Datenmuster das bisherige Wissen ergänzt oder diesem widerspricht
Nützlichkeit:	Praktischer Nutzen des neu gewonnenen Wissens für den Anwendenden
Verständlichkeit*:*	Interpretationsmöglichkeiten durch den (oder die) Anwender

Über die Dimension der Nützlichkeit können die Grenzen für die Interessantheitsmaße Konfidenz und Lift entsprechend in ihren Ausprägungen eingegrenzt werden. Wo diese Grenzen liegen, kann je nach Umfeldverständnis variieren und ist unternehmensspezifisch zu prüfen. Somit können über einen lernenden Effekt weitere Eingrenzungen konkretisiert werden.

Bisher sind die Verfahren Trendberechnung des Trend- und Prognosemodells, Clusteranalyse, Assoziationsanalyse und Relevanzprüfung generisch beschrieben worden. Ein konkretes Beispiel dieser Verfahren auf Basis der Konzeptionsprüfung ist in Kapitel 6 zu finden.

4.4 Potenzielle Data Mining-Prozesse

Das Verständnis des Begriffs Data Mining ist in der Literatur sehr heterogen. Zum einen vereint der Begriff des Data Mining verschiedene Verfahren im Prozess des Knowledge Discovery in Database (KDD). Der KDD wird oft als Gesamtprozess zur Generierung von Wissen mit einer starken Verbindung zur Datenbanktechnologie verstanden. Synonym zum KDD wird mehrheitlich unter dem Begriff Data Mining eben dieser Gesamtprozess verstanden [CLE16, SAS17]. Lediglich FAYYAD [FAY96] differenziert das Data Mining als eine Phase des KDD-Prozesses. In der vorliegenden Arbeit liegt die Konzentration jedoch auf der Bezeichnung Data Mining als Gesamtprozess und nicht als einzelner Prozessschritt.

Data Mining nutzt Verfahren der Statistik, der künstlichen Intelligenz sowie der Mustererkennung. Dabei wird in einer Datenmenge mit Hilfe von Kombinationen nach explizitem Wissen, das z. B. durch Aufdecken versteckter Zusammenhänge ermittelt wird, gesucht [HEI09]. Das Ziel ist, Wissen („information-diamond“ [ADR98]) durch aussagekräftige Muster aus großen Datenmengen automatisiert zu erhalten [HIP17]. Um dieses Ziel zu erreichen, werden in der Literatur [FAY96, CIO07, GAB09, CLE16, SAS17] verschiedene Prozesse postuliert:

- Data Mining im KDD-Prozess nach FAYYAD [FAY96]
- Data Mining-Prozess nach SEMMA
- Data Mining-Prozess nach CRISP-DM

Diese drei Prozesse werden im Folgenden mit ihren verschiedenen Prozessschritten betrachtet und inhaltlich untersucht. Die erarbeiteten Erkenntnisse dienen im Kapitel 4.5 als Grundlage zur Entwicklung eines Data Mining-Prozesses für den Workflow des TSM.

4.4.1 Data Mining im KDD-Prozess

Wie bereits beschrieben, sieht FAYYAD [FAY96] das Data Mining als eine Phase innerhalb des KDD-Prozesses. KDD definiert der Autor als nicht-trivialen Prozess, der valide, neuartige potenziell nützliche und schließlich verständliche Datenmuster identifiziert [FAY96]. Der Prozess des KDD wird auch von CIOS ET AL. [CIO07] als KDP (Knowledge Discovery Process) beschrieben. Insgesamt enthält der KDD-Prozess folgende Phasen [FAY96, CLE16]:

- Datenselektion
- Datenvorverarbeitung
- Datentransformation
- Data Mining
- Evaluation und Interpretation

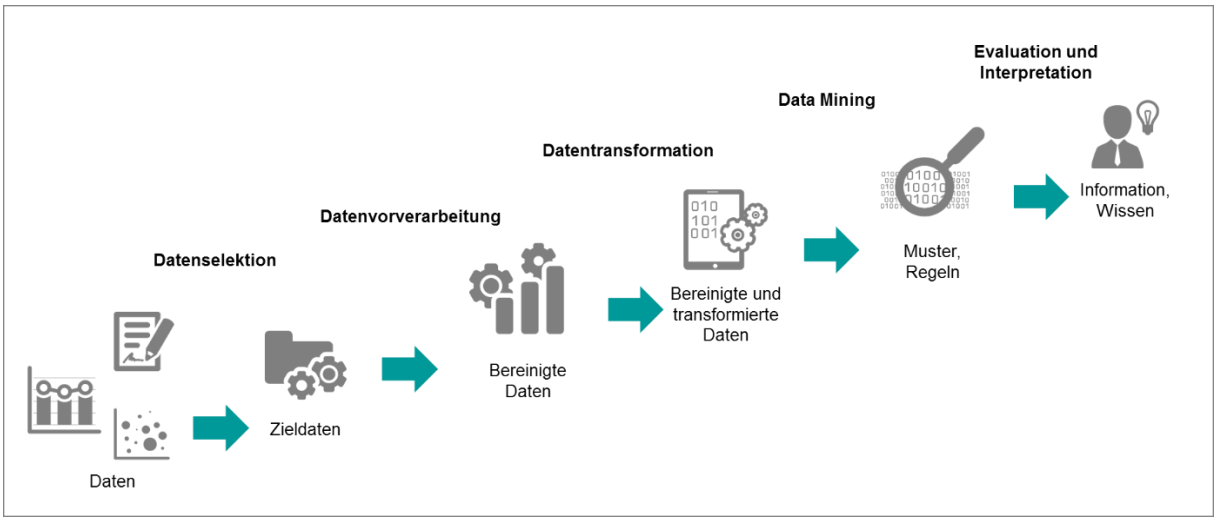


Bild 4-17: Data Mining im KDD-Prozess
Quelle: Eigene Darstellung in Anlehnung an [FAY96, EST00, CLE16]

In Bild 4-17 sind die einzelnen Phasen des KDD-Prozesses dargestellt. Diese werden im Folgenden zusammengefasst erläutert [FAY96, ADR98, EST00, GAB09, CLE16]:

Datenselektion

Geeignete Daten bzw. Datenmengen, die für die Aufgabenstellung relevant sind, werden aus dem Gesamtdatenbestand ausgewählt. Es können sowohl externe als auch interne Daten genutzt werden. Für die Weiterverarbeitung der ausgewählten Daten wird eine Datei mit einem Zieldatenbestand gespeichert. Somit fällt die Konzentration auf die reduzierte Datenmenge, bei der die Analyse durchgeführt werden soll.

Datenvorverarbeitung

Der Zieldatenbestand wird nun in der Vorverarbeitungsphase bereinigt. Ziel ist es, einen Datenbestand zu erhalten, der ausgewertet werden kann. Dazu muss die Datenqualität überprüft und gegebenenfalls verbessert werden. Fehlende Daten werden hinzugefügt und fehlerhafte oder widersprüchliche Daten korrigiert. Der bereits vorhandene Datenbestand kann in dieser Phase durch weitere Attribute angereichert werden, sofern es die jeweilige Aufgabenstellung erfordert. Die Kenntnis über die vorliegende Datenqualität ist für die weiteren Analyseschritte sowie deren Ergebnisse von hoher Bedeutung. Die Datenqualität beeinflusst die Robustheit der Analyseergebnisse signifikant.

Datentransformation

In der Phase der Datentransformation wird der Datenbestand in das vom Analyseverfahren geforderte adäquate Datenformat umgewandelt. Beispielhafte Transformationsschritte sind das Diskretisieren numerischer Werte, die Umwandlung nominaler in numerische Werte oder auch eine Gruppierung von metrischen Werten in Intervalle. Ziel ist es, die spezifischen Anforderungen des Analyseverfahrens an den auszuwertenden Datensatz zu erfüllen.

Data Mining

Das Data Mining stellt den Kernprozess des KDD für die Wissensgenerierung dar. Durch den Einsatz geeigneter mathematischer Methoden, die auf die Aufgabenstellung abgestimmt sind, wird nun das Modell entwickelt. Das Ziel des ausgewählten Verfahrens ist die Suche und das

Auffinden von Datenmustern, die bisher unbekannt waren. Dazu muss das entsprechende Analyseverfahren ausgewählt werden.

Evaluation und Interpretation

Die Ergebnisse (Datenmuster) aus der Data Mining-Methode werden nun eingeschätzt und interpretiert. Durch diesen Prozessschritt entsteht bisher unbekanntes Wissen. Dieses Wissen muss bezüglich der Verwendbarkeit bewertet werden. Sofern die Aufgabenstellung anhand der gefundenen Muster nicht im definierten Maße erfüllt wird, können vorherige Prozessschritte wiederholt werden, um ein zufriedenstellendes Ergebnis zu erzielen. Die Muster werden nach dem Kriterium der Interessantheit beurteilt. Folgende Dimensionen sind dabei denkbar:

- Validität des Musters
- Neuartigkeit des generierten Wissens auf Basis der Muster
- Nützlichkeit des Musters
- Verständlichkeit der Aussage

Zusammenfassend soll durch diesen Prozess Wissen generiert werden, welches vorher noch nicht bekannt war. Der KDD-Prozess wird vorrangig in der Statistik, beim maschinellen Lernen sowie bei der Arbeit mit Datenbanksystemen angewendet [EST00]. Er ist dazu geeignet, „Informationen aus vorliegenden Daten zur Theorieentwicklung zu gewinnen“ [GAB09].

4.4.2 Data Mining-Prozess nach SEMMA

Das SEMMA-Modell wird von dem Unternehmen SAS Institute verwendet [SAS17]. SEMMA steht als Abkürzung für die folgenden Schritte im Prozess (Bild 4-18):

- **S**ample
- **E**xplore
- **M**odify
- **M**odel
- **A**ssess

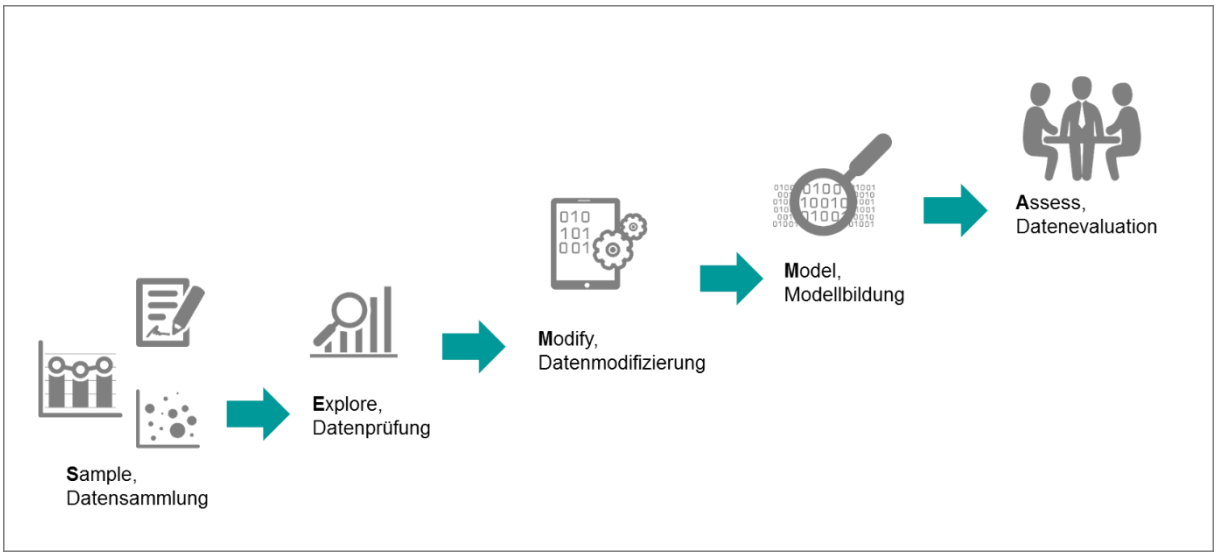


Bild 4-18: Data Mining-Prozess nach SEMMA
Quelle: Eigene Darstellung

Zusammenfassend werden nun die einzelnen Prozessschritte kurz erläutert [CLE16, SAS17]:

Sample, Datensammlung

Relevante Daten werden zunächst aus dem Gesamtdatenbestand extrahiert. Somit wird ein Datenbestand zusammengestellt, der alle für die weiteren Auswertungen relevanten Informationen enthält.

Explore, Datenprüfung

Die extrahierten Daten werden auf Unregelmäßigkeiten im Bereich der Datenqualität untersucht. Somit wird die Datenqualität überprüft und ein größeres Datenverständnis erreicht.

Modify, Datenmodifizierung

Der ausgewählte Datenbestand wird auf das Analyseverfahren angepasst. Die Datentransformation ermöglicht, den Datensatz für das Analyseverfahren zu nutzen.

Model, Modellbildung

Die Daten werden je nach Analyseverfahren verarbeitet. Es wird mit Hilfe von Software nach Datenkombinationen gesucht, die zuverlässige Aussagen und Antworten für das Ausgangsproblem generieren.

Assess, Datenevaluation

Die Ergebnisse aus dem Analyseverfahren werden evaluiert. Die Nützlichkeit und Zuverlässigkeit der gewonnenen Aussagen werden überprüft.

Obwohl der SEMMA-Prozess und die entsprechende SAS-Software zunächst unabhängig voneinander sind, werden beide miteinander verbunden. Dabei müssen nicht alle Data Mining-Phasen in der Software genutzt werden. Je nach Bedarf können einzelne Schritte ausgeblendet werden. Aber auch beim SEMMA-Prozess sollte iterativ vorgegangen werden. Für ein robustes Ergebnis ist es sinnvoll, verschiedene Phasen zu wiederholen. Eine valide Datengrundlage ist für den gesamten Prozess zwingend [SAS17].

4.4.3 Data Mining-Prozess nach CRISP-DM

Eine weitere Möglichkeit zur Modellierung eines Data Mining-Prozesses bildet das CRISP-DM-Modell mit seinen sechs idealtypischen Phasen [GAB09]. Dieses Modell ist durch einen Zusammenschluss verschiedener Unternehmen erarbeitet worden [CIO07]. Das Akronym CRISP-DM bedeutet aufgeschlüsselt folgendes:

- **Cr**oss
- **I**ndustry
- **S**tandard
- **P**rocess for
- **D**ata **M**ining

Das Ziel dieses standardisierten Prozesses ist die Validierung der berechneten Ergebnisse [CLE16]. Dabei werden die folgenden Phasen unterschieden (Bild 4-19).

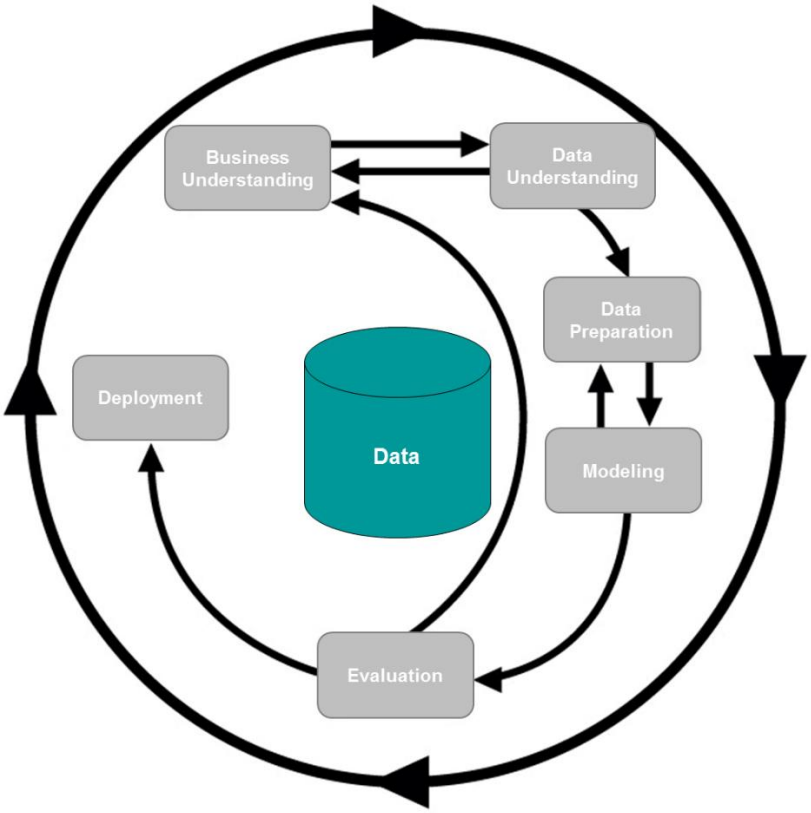


Bild 4-19: CRISP-Modell
Quelle: [GAB09, IBM11, CLE16]

Nachfolgend werden die einzelnen Schritte des Modells erläutert [CIO07, GAB09, IBM11, CLE16]:

Business Understanding, Aufgabendefinition

Die erste Phase stellt die Basis des CRISP-DM dar. Die Phase beinhaltet folgende Aspekte:

- Definition der Problemstellung
- Situationsbewertung
- Festlegung der Data Mining-Ziele
- Anfertigung des Projektplans

Die betriebswirtschaftliche Betrachtungsweise bei der Aufgabendefinition stellt sicher, dass der Data Mining-Prozess der Verbesserung von Betriebsabläufen bzw. der Reduzierung von Prozesskosten dient. Operationale Zielkriterien müssen aus betriebswirtschaftlicher Perspektive definiert sowie Gestaltungs- bzw. Handlungsalternativen dargelegt werden.

Data Understanding, Datenauswahl

Die Datenauswahl umfasst primär die Auseinandersetzung mit den Daten des Unternehmens, die schon vorhanden sind oder die noch extern beschafft werden müssen. In der Data Understanding-Phase werden folgende Punkte bearbeitet:

- Katalogisierung und Beschaffung der Ursprungsdaten
- Beschreibung der Daten

- Exploration bzw. Visualisierung der Daten
- Überprüfung der Datenqualität

Die Katalogisierung und Beschaffung der Daten hat zwei Ziele: Einerseits soll eine Übersicht geschaffen werden, die zeigt, welche Quellen für die Daten genutzt werden können. Andererseits soll der Zugang zu den möglichen Daten hergestellt werden, sodass diese im Falle einer angestrebten Verwendung kurzfristig abgefragt werden können. Der nächste Schritt beinhaltet die Beschreibung der relevanten Daten. Der Fokus liegt auf dem Datenformat, der Datenmenge (Anzahl der Merkmale und Anzahl der Attribute) und der Bedeutung der Attribute. Das Ergebnis der Datenbeschreibung muss sich mit den Anforderungen an die Daten aus der ersten Phase (Business Understanding) decken. Nach der Datenbeschreibung folgt die Datenexploration. Diese dient dazu, die Daten besser kennenzulernen. Dazu werden OLAP-Abfragen eingesetzt, die zu einem deskriptiven Output in Form einer Tabelle führen. Dieser Vorgang wird durchgeführt, um mögliche Unregelmäßigkeiten innerhalb der Datenqualität zu identifizieren. Dieser Teilprozessschritt zielt primär auf die Begutachtung der Vollständigkeit der Daten ab. Für die relevanten Attribute sollte die Menge an fehlenden Werten auf ein Minimum reduziert sein.

Data Preparation, Datenaufbereitung

Die Datenaufbereitung beinhaltet alle Handlungen zur Generierung einer Datenmenge, die den Data Mining-Verfahren als Input dient. Dabei werden folgende Aufgaben erfüllt:

- Auswahl der Daten
- Bereinigung der Daten
- Konstruktion der Daten
- Integration der Daten
- Formatierung der Daten

Innerhalb der Auswahl der Daten ist es möglich, vorab einige der Attribute zu vernachlässigen, sofern diese eine nicht ausreichende Datenqualität vorweisen. Im Anschluss werden die Daten bereinigt. Innerhalb der Datenbereinigung wird die Entscheidung getroffen, wie mit fehlerhaften oder fehlenden Daten, die für eine exakte Analyse unbedingt notwendig sind, weiter verfahren wird. Fehlende Datensätze sind mittels Schätzverfahren anzunehmen. Falls dies nicht umsetzbar ist, sind gegebenenfalls Stichproben aus den Datensätzen, die vollständig zur Verfügung stehen, verwendbar. Somit werden neue Datensätze konstruiert. Durch die nachfolgende Datenintegration werden relationale Datenbankstrukturen in eine Tabelle mit Daten übertragen. Die Zeilen bilden die Datensätze und die Spalten die Merkmale bzw. Attribute ab. Abschließend wird in diesem Prozessschritt das Datenformat untersucht. Gegebenenfalls muss das Datenformat, wie z. B. die Zeichenlänge, an den Algorithmus angepasst werden.

Modeling, Auswahl und Anwendung von Data Mining-Verfahren

Die Modeling Phase beschreibt die eigentliche Anwendung der Data Mining-Verfahren. Es werden unterschiedliche Algorithmen verwendet, um die definierte Aufgabenstellung zu lösen. Die verschiedenen Algorithmen haben unterschiedliche Anforderungen an die Datensätze. Ein iterativer Vorgang, der das Datenformat mit dem Analyseverfahren abgleicht, ist unumgänglich. Folgende Aufgaben sind in dieser Prozessphase enthalten:

- Auswahl der Algorithmen
- Erzeugung der Trainings- und Testdaten
- Aufbau des Modells
- Bewertung des Modells (technische Sichtweise)

Die Aufgabendefinition legt fest, welcher Algorithmus verwendet werden soll. Die Daten, die zuvor in der Data Preparation-Phase aufbereitet worden sind, werden in Trainings- und Testdaten differenziert. Anhand des Trainingsdatenbestandes wird das Modell erlernt. Dagegen wird die Modellgüte auf einem disjunkten Testdatenbestand von den Testdaten bestimmt. Wenn anschließend die Test- und Trainingsdaten vorhanden sind, folgt die Anwendung des Modells, indem die Algorithmen durchgeführt werden. Zum Abschluss ist noch die technische Modellbewertung durchzuführen.

Evaluation, Bewertung und Interpretation der Ergebnisse

Die Ergebnisse des Analyseprozesses werden interpretiert und bewertet. Die Phase Evaluation befasst sich hauptsächlich mit einem Vergleich des Soll- und Ist-Zustands bezüglich der Aufgabendefinition und Ziele aus betriebswirtschaftlicher Sicht. Folgende Gesichtspunkte werden in der Evaluationsphase genauer betrachtet:

- Bewertung der Ergebnisse (betriebswirtschaftliche Sichtweise)
- Prozessrückblick
- Maßnahmendefinition

Bei der Bewertung des Ergebnisses könnte eine Kosten-Nutzen-Analyse für das komplette Data Mining-Projekt durchgeführt werden, um der betriebswirtschaftlichen Reflexion gerecht zu werden. Weitere Punkte, die in die Ergebnisbewertung einfließen sind beispielsweise die Vollständigkeit und Übersichtlichkeit der Ergebnisdarstellung oder auch der Neuigkeitsgehalt und die Nützlichkeit der Ergebnisse. Der Prozessrückblick beinhaltet danach eine Prüfung, ob der Kern der Aufgaben im Data Mining-Prozess bis zu diesem Zeitpunkt abgearbeitet worden ist. Final werden auf Basis der Analyseergebnisse Maßnahmen definiert.

Deployment, Anwendung der Ergebnisse

Die letzte Phase im CRISP-DM-Prozess umfasst die Anwendung und Umsetzung der Analyseergebnisse. Diese enthält folgende Punkte:

- Umsetzungsplanung
- Überwachung der Planung
- Erzeugung des Abschlussberichts
- Projektrückblick

Mit der Umsetzungsplanung definierter Maßnahmen soll eine strukturierte Vorgehensweise sicherstellt werden. Dabei sind Aspekte des Projektmanagements zu beachten. Für eine zielführende Durchführung der Maßnahmen ist eine Kontrollfunktion bezüglich des Fortschritts der definierten Maßnahme zu installieren. Zum Schluss des Data Mining-Prozesses ist ein Abschlussbericht anzufertigen. Dieser sollte lediglich die wichtigsten Zahlen, Daten und Fakten beinhalten. Der Projektrückblick dient der kontinuierlichen Verbesserung des Data Mining-

Prozesses. Dazu ist es wichtig, die Ergebnisse des abgeschlossenen Prozesses kritisch zu würdigen und gegebenenfalls aufgetretene Probleme und Auffälligkeiten zu verbessen bzw. zukünftig zu vermeiden.

4.4.4 Kritische Auseinandersetzung

In Kapitel 4.4.1 bis Kapitel 4.4.3 werden verschiedene Ansätze von Data Mining-Prozessen betrachtet. Dabei ergeben sich Gemeinsamkeiten, aber auch Unterschiede. Diese werden nun kritisch gewürdigt.

Auch wenn die einzelnen Prozessschritte teilweise unterschiedlich benannt werden, ähneln sich ihre Inhalte. Das Ziel, Wissen zu erhalten, ist bei allen drei Prozessen gleich. Die Vielfalt der Prozessschritte ist jedoch different. Eine Zusammenfassung der Prozesse mit ähnlichen Inhalten visualisiert Bild 4-20.

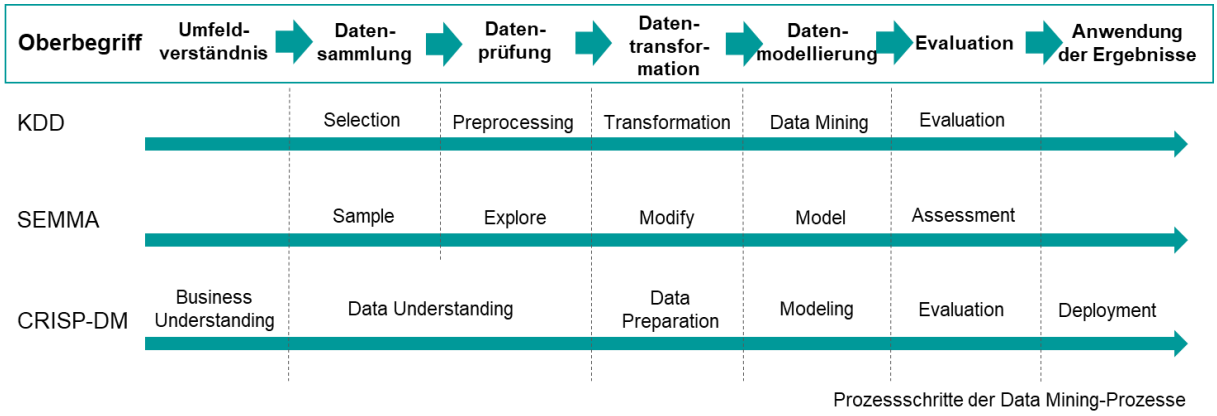


Bild 4-20: Vergleich der Prozessschritte von KDD, SEMMA und CRISP-DM
Quelle: Eigene Darstellung

Die fünf Prozessschritte des KDD können im Rahmen einer praktischen Umsetzung durch Softwareunterstützung mit denen des SEMMA-Prozesses gleichgesetzt werden [AZE08]. Ein Vergleich zwischen dem KDD-Prozess und CRISP-DM zeigt, dass zwei zusätzliche Prozessschritte hinzukommen: Business Understanding und Deployment.

Um die drei Data Mining-Prozesse auf die Anwendbarkeit zur Wissensgenerierung im Lieferantenmanagement hin zu überprüfen, werden nun die Anforderungen an eine Lieferantenbewertung aus Kapitel 2.3.2 hinzugezogen. Alle drei Prozesse werden anhand der Erfüllungsgrade beurteilt. Die Erfüllungsgrade der Anforderungen differenzieren sich dabei ausgehend von „erfüllt“ (100 Prozent) in „teilweise erfüllt“ (50 Prozent) und „nicht erfüllt“ (0 Prozent). Dargestellt werden die Erfüllungsgrade durch

- ● Anforderung ist erfüllt,
- ◑ Anforderung ist teilweise erfüllt oder
- ○ Anforderung ist nicht erfüllt.

Zu jeder Anforderung erfolgt eine kurze spezifische Begründung in Bezug auf den Erfüllungsgrad. Der Prozess des KDD und SEMMA ähneln sich stark. Lediglich die Wortwahl der einzelnen Prozesse differiert. Aus diesem Grund werden beide Prozesse gemeinsam analysiert. Danach wird diesem Ergebnis das Analyseergebnis des CRISP-DM gegenübergestellt.

Tabelle 4-4: Erfüllungsgrad zur Wissensgenerierung durch KDD und SEMMA
Quelle: Eigene Darstellung

Anforderung	Erfüllungsgrad	Begründung
Strategie	●	Beschaffungsspezifische Einflüsse werden über die Datensammlung berücksichtigt
Crossfunktionalität	●	Bereichsübergreifende Betrachtung möglich
Teamorientierung	●	Berücksichtigung verschiedener bereichsspezifischer Kriterien
Kontinuität	●	Regelmäßige Anwendung der Prozesse möglich
Vollständigkeit	◑	Umfeldverständnis und Anwendung der Ergebnisse fehlen
Transparenz, Nachvollziehbarkeit, Objektivität und Akzeptanz	●	Prozesse sind eindeutig und für alle Beteiligten nachvollziehbar
Zuverlässigkeit	●	Ergebnisse der Prozessschritte sind klar definiert und verständlich
Offenheit der Modellstruktur/ Flexibilität	●	Veränderungen (z.B. andere Rahmenbedingungen) können innerhalb der Prozessschritte implementiert werden
Praktikabilität und Wirtschaftlichkeit	◑	Anwendung der Ergebnisse fehlt
Technik	●	IT-Systemunterstützung kann in jeden Prozessschritt implementiert werden
Lösungen	●	Je nach angewendeten Verfahren ermöglichen die standardisierten Prozesse nachvollziehbare und robuste Lösungen
Bewertungskommunikation Bewertungskonsequenzen	◑	Anwendung der Ergebnisse fehlt

Zum Durchlaufen der Prozesse KDD und SEMMA ist nicht bekannt, welche Informationen benötigt werden, das Verständnis für das zu analysierende Umfeld (Business Understanding) fehlt. Somit ist die Gefahr hoch, dass nicht die Daten und Informationen gesammelt werden, welche für die Wissensgenerierung im Lieferantenmanagement benötigt werden. Zu diesen Daten und Informationen zählen, wie in Kapitel 4.6.2 beschrieben, leistungsbeschreibende und nicht leistungsbeschreibende Merkmale.

Weiterhin ist im TSM-Workflow die bereichsübergreifende Kommunikation zwischen den Fachbereichen ein wichtiger Bestandteil. Die Data Mining-Prozesse KDD und SEMMA gehen bisher von der Anwendung der Analyseverfahren sofort in die Bewertung der Ergebnisse (Evaluation/Interpretation) über. Dabei werden die Ergebnisdarstellung sowie die Kommunikation der Ergebnisse an Stakeholder und weitere Interessengruppen nicht explizit durchgeführt.

Auch eine Dokumentation der Ergebnisse wird nicht durch die Data Mining-Prozesse beschrieben. Eine Projektdokumentation beschreibt die „Zusammenstellung ausgewählter, wesentlicher Daten über Konfiguration, Organisation, Mitteleinsatz, Lösungswege, Ablauf und erreichte Ziele des Projektes“ [DIN 69901]. Lediglich beim CRISP-DM wird ein Abschlussbericht über die definierten Maßnahmen angefertigt.

Tabelle 4-5: Erfüllungsgrad zur Wissensgenerierung durch CRISP-DM
Quelle: Eigene Darstellung

Anforderung	Erfüllungsgrad	Begründung
Strategie	●	Beschaffungsspezifische und weitere Einflüsse werden bereits durch das Umfeldverständnis berücksichtigt
Crossfunktionalität	●	Bereichsübergreifende Betrachtung möglich
Teamorientierung	●	Berücksichtigung verschiedener bereichsspezifischer Kriterien sowie weiterer Informationen je nach Umfeldverständnis
Kontinuität	●	Regelmäßige Anwendung der Prozesse möglich
Vollständigkeit	●	Einflussnahme des Umfeldverständnisses auf den Gesamtprozess sowie die Anwendung der Ergebnisse sind im Sinne eines KVP ergänzt
Transparenz, Nachvollziehbarkeit, Objektivität und Akzeptanz	◐	Datensammlung und Datenprüfung findet in einem Prozessschritt statt; keine Differenzierung
Zuverlässigkeit	●	Ergebnisse der Prozessschritte sind klar definiert und verständlich

Tabelle 4-2: Erfüllungsgrad zur Wissensgenerierung durch CRISP-DM (Fortsetzung)

Anforderung	Erfüllungsgrad	Begründung
Offenheit der Modellstruktur/ Flexibilität	●	Veränderungen (z.B. andere Rahmenbedingungen im Bereich des Umfeldverständnisses) können innerhalb der Prozessschritte implementiert werden
Praktikabilität und Wirtschaftlichkeit	●	Ergebnisse werden angewendet wobei die Erfahrungen aus der Anwendung in das Umfeldverständnis eingehen können
Technik	●	IT-Systemunterstützung kann in jeden Prozessschritt implementiert werden
Lösungen	●	Je nach angewendeten Verfahren ermöglichen die standardisierten Prozesse nachvollziehbare und robuste Lösungen, die praktisch anwendbar sind
Bewertungskommunikation Bewertungskonsequenzen	●	Ergebnisse werden kommuniziert und entsprechende Maßnahmen im Rahmen der Anwendung umgesetzt

Beim Prozess des CRISP-DM werden die Prozessschritte der Datensammlung und der Datenprüfung in einem Schritt des Data Understanding zusammengefasst. Da jedoch die Prüfung der Datenqualität ein wesentlicher Bestandteil der Wissensgenerierung ist, kann im Verlauf der vorliegenden Arbeit auf eine Zusammenführung der Prozessschritte Datensammlung und Datenprüfung nicht verzichtet werden.

Da keiner der Data Mining-Prozesse alle Anforderungen zur Wissensgenerierung erfüllt, ist eine Kombination der Prozessschritte vorteilhaft. Bereits in Kapitel 2.3.4 ist eine Kombination zur Generierung von Synergieeffekten zwischen verschiedenen Lieferantenbewertungsverfahren angewendet worden. Die Defizite eines alleinigen Data Mining-Prozesses werden damit durch Prozessschritte eines anderen Data Mining-Prozesses ausgeglichen. Um im weiteren Verlauf der Arbeit auf eine einheitliche Wortwahl zurückgreifen zu können, werden die einzelnen Oberbegriffe der Data Mining-Prozessschritte zur Anwendung im TSM verwendet (Bild 4-21).



Bild 4-21: Data Mining-Prozessschritte zur Anwendung im TSM
Quelle: Eigene Darstellung

Wird nun zusätzlich die softwarebasierte Unterstützung der einzelnen Data Mining-Prozesse aus der Literatur betrachtet, gibt es weitere Unterschiede (Tabelle 4-6). Ein weitreichenderer Überblick über bisherige Anwendungsgebiete und die damit verbundene Softwareunterstüt-

zung ist in HARDING ET AL. [HAR06] zu finden. In diesem Zusammenhang postulieren die Autoren [HAR06], dass der Prozess nach CRISP-DM in der Handhabung der Berichtserstellung einfacher als der nach SEMMA ist. Eine einfache Nutzungsmöglichkeit ist wichtig. Somit ist der Aufwand für Schulungen beim Anwender minimal.

Tabelle 4-6: Anwendung der Data Mining-Prozesse
Quelle: Eigene Darstellung

Model	KDD	SEMMA	CRISP-DM
Anwendung	Wissenschaft	Industrie	Industrie
Unterstützende Software	MineSet™	Enterprise Miner	Clementine®
Anwendungsgebiete	Medizin, Ingenieurswesen, Produktion, E-Business	Marketing	Medizin, Ingenieurswesen, Marketing, Vertrieb

Der Prozess des KDD wird in der Wissenschaft genutzt, wohingegen die Prozesse des CRISP-DM und SEMMA in der Industrie verwendet werden [HAR06]. Auch die Anwendungsgebiete der drei Prozesse sind teilweise different. Die Vermutung liegt nahe, dass es mit der eingesetzten Softwareunterstützung in den jeweiligen Bereichen zusammenhängen könnte. Wissenschaftliche Untersuchungen dazu gibt es bisher nicht. Weitere frei verfügbare Softwareprodukte sind beispielsweise RapidMiner oder auch die Programmiersprache R. Beide werden zur Analyse im Rahmen von Data Mining eingesetzt [GRO15, KOT15].

Da der Prozess des Data Mining für diese Arbeit eine Kombination aus verschiedenen Prozessen ist, kann eine einzelne Software für einen spezifischen Prozess keine Unterstützung mehr bieten. Um aber dennoch die in Kapitel 4.3 ausgewählten Verfahren abbilden zu können, wird im weiteren Verlauf dieser Arbeit auf eine Eigenentwicklung als Softwareunterstützung zurückgegriffen. Diese Eigenentwicklung wird als *Analyzer* bezeichnet.

Der *Analyzer* ist eine begrenzte Softwareunterstützung im Rahmen der Datenmodellierung, der spezifisch für die vorliegende Arbeit entwickelt worden ist. Es wird somit nicht der gesamte Data Mining-Prozess abgebildet, sondern nur der Prozessschritt der Datenmodellierung, bei dem auf Grund der großen Datenmenge zur Generierung der quantitativen Assoziationsregeln eine softwarebasierte Unterstützung notwendig ist.

Der *Analyzer* dient in der vorliegenden Arbeit als erste, softwarebasierte Unterstützung zur Untersuchung der generellen Machbarkeit im Rahmen der Konzeptionsprüfung (Kapitel 6). Um die Machbarkeit des in der vorliegenden Arbeit entwickelten Konzeptes prüfen zu können, werden mit Hilfe des *Analyzers* verschiedene Prozessschritte im Rahmen der Datenmodellierung durchlaufen (in Bild 4-22 farblich gekennzeichnet). Im Folgenden wird der *Analyzer* allgemein beschrieben (Bild 4-22). Im Rahmen der Konzeptionsprüfung (Kapitel 6) wird dieser nochmals anhand eines konkreten Beispiels erläutert.

Allgemein bildet der *Analyzer* in diesem Zusammenhang folgenden Prozess ab:

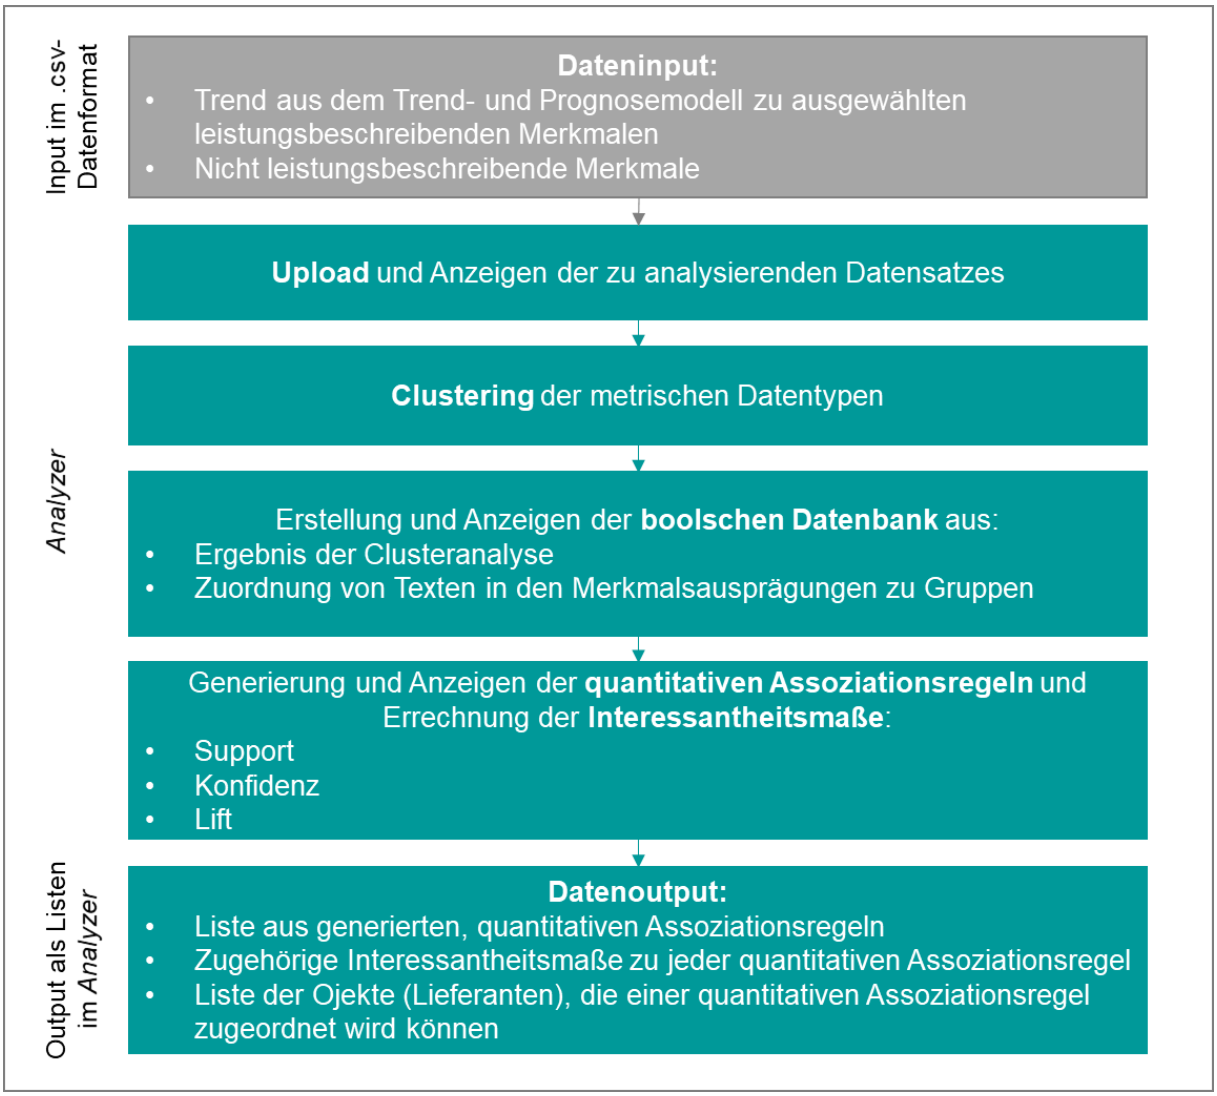


Bild 4-22: Abgebildeter Prozess im *Analyzer* zur Generierung von quantitativen Assoziationsregeln
Quelle: Eigene Darstellung

Zunächst wird ein beliebiger Datensatz aus leistungsbeschreibenden Merkmalen und nicht leistungsbeschreibenden Merkmalen (Kapitel 4.5.2) sowie Trendergebnisse aus dem Trend- und Prognosemodell als Dateninput für den Analyzer mit Hilfe einer Datei im csv-Dateiformat eingespielt. Die Trendergebnisse des Trend- und Prognosemodells werden hier als gegeben betrachtet und sind Teil des Datensatzes. Ist der Datensatz in den *Analyzer* geladen, wird er angezeigt. Somit kann überprüft werden, ob die Daten korrekt vorliegen. Danach werden die metrischen Daten geclustert. Das Ergebnis des Clusterings, die verschiedenen Attribute, finden sich in der boolschen Datenbank wieder. Zusätzlich sind auch alle nicht metrischen Datentypen in der boolschen Datenbank enthalten. Diese nicht metrischen Datentypen werden je nach ihren Merkmalsausprägungen zusammengefasst. Diese Zusammenfassung wird wiederum als Attribut dargestellt. Nachdem die boolsche Datenbank erstellt worden ist, werden auf dieser Basis die quantitativen Assoziationsregeln generiert. Zu jeder quantitativen Assoziationsregel werden die Interessantheitsmaße Support, Konfidenz und Lift berechnet und visualisiert.

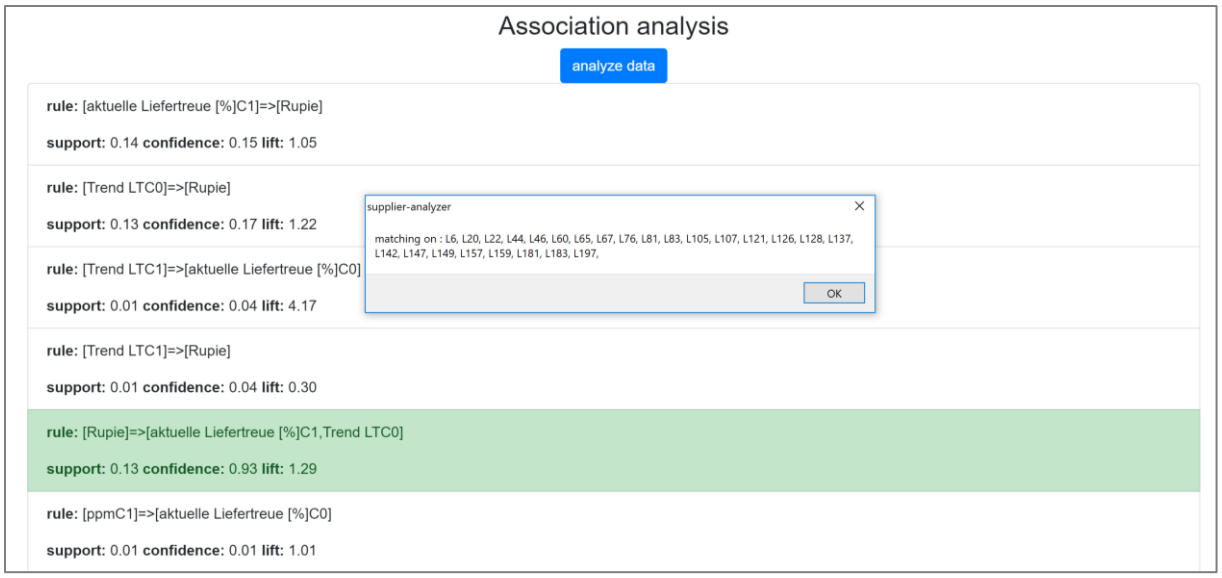


Bild 4-23: Beispiel eines Ergebnisses des *Analyzers*
Quelle: Eigene Darstellung

Als Ergebnis des *Analyzers* wird somit eine Liste aus den generierten, quantitativen Assoziationsregeln sowie den drei Interessantheitsmaßen dargestellt. Zusätzlich ist es möglich, durch die Auswahl einer bestimmten quantitativen Assoziationsregel auch die Menge der Lieferanten anzeigen zu lassen, auf die diese Regel zutrifft (Bild 4-23). Dieses Ergebnis des *Analyzers* ist wiederum der Dateninput für die Relevanzprüfung. Somit können große Datenmengen verarbeitet und die entstandenen quantitativen Assoziationsregeln priorisiert werden.

Die bisher gewonnen Erkenntnisse über die Ausprägungen der Data Mining-Prozesse werden im Folgenden Kapitel für die Übertragung auf den Workflow des TSM genutzt. Somit kann ein Data Mining-Prozess für das Konzept der Wissensgenerierung zur frühzeitigen Risikoidentifikation in externen Wertschöpfungsnetzwerken entwickelt werden.

4.5 Entwicklung eines Data Mining-Prozesses

Die Betrachtung der in der Literatur postulierten Data Mining-Prozesse (Kapitel 4.4) gibt einen Überblick über die Möglichkeit von strukturierten Abläufen zur Erzeugung von Wissen. Um das Data Mining zur Risikobetrachtung im TSM nutzen zu können, werden die Prozesse des Data Mining mit dem Wissensmanagement und dem TSM vernetzt. Ein Idealprozess wird modelliert. Für diese Modellierung werden Elemente aus den vorhergehenden Betrachtungen genutzt. Der Fokus liegt dabei auf

- dem Workflow des TSM mit den Prozessschritten Informieren, Entscheiden, Durchführen und KVP (Kapitel 3.4),
- der Verknüpfung des Wissensmanagements und des TSM mit dem Schwerpunkt der Wissensgenerierung (Kapitel 4.1),
- den Verfahren zur Wissensgenerierung im Bereich des Lieferantenmanagements (Kapitel 2.3.4.4 und Kapitel 4.3) sowie
- dem Aufbau der Data Mining-Prozesse aus Wissenschaft und Praxis (Kapitel 4.4).

Zunächst wird nun die Bedeutung des Data Mining-Prozesses im Bereich der Wissensgenerierung hervorgehoben. Dazu werden die Treiber betrachtet, die einen direkten Einfluss auf den Idealprozess haben.

4.5.1 Treiber und Aufgaben des Data Mining-Prozesses

Die Treiber des Data Mining und damit der Generierung von Wissen sind vielfältig. RUDOW ET AL. [RUD14] nennen in diesem Zusammenhang die IuK-Systeme (Betriebliche Informations- und Kommunikationssysteme) und PIAZZA [PIA10] die auszuwertende Datenbasis. GABRIEL ET AL. [GAB09] haben die verschiedenen Einflussgeber in einer Grafik zusammengefasst (Bild 4-24). Diese werden im Folgenden näher betrachtet.

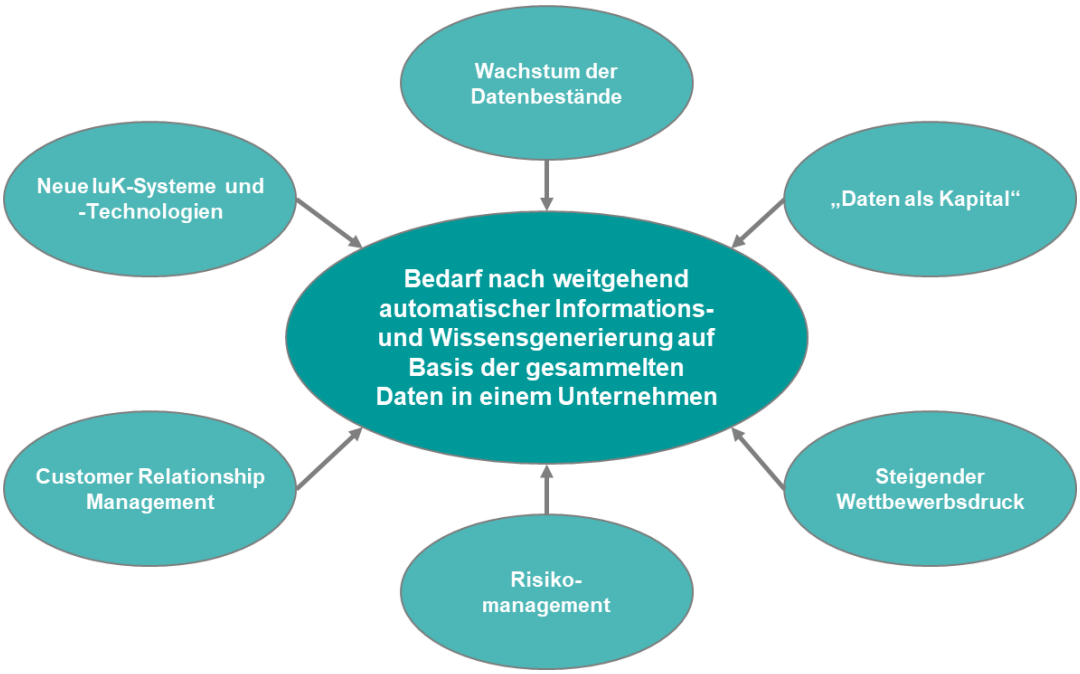


Bild 4-24: Treiber des Data Mining
Quelle: Eigene Darstellung in Anlehnung an [GAB09]

Supplier Risk Monitoring

Neue IuK-Systeme

Die Entwicklung neuer IuK-Systeme schreitet stetig voran. Auf Grundlage dieser Systeme werden verschiedene Analysemethoden im Rahmen der Business Intelligence, wie das Data Mining, eingesetzt [VOß01]. Die Analyse von große Datenmengen ist mit diesen Systemen automatisierbar und somit effizient möglich [SCH06b].

Wachstum der Datenbestände

Durch die Anforderung der Dokumentation von Geschäftsdaten [DINENISO9001] und der stetigen Erzeugung neuer Informationen wächst der Datenbestand kontinuierlich an [SCH97, STE15]. In diesem Zusammenhang sprechen GABRIEL ET AL. von „explosionsartigen Wachstumsraten des Datenvolumens“ [GAB09]. Diese auswertbaren Daten, welche mit Hilfe von Data Mining zu Wissen vernetzt werden, liegen in den IuK-Systemen strukturiert ab.

Daten als Kapital

Daten bilden die Grundlage für Informationen und Wissen. Erst durch die Vernetzung der Informationen zu Wissen gewinnen diese an Bedeutung [BOD97]. Die „…wachsende […] Bedeutung des Wissens und des Lernens [gelten] als Schlüsselfaktoren für den Unternehmenserfolg“ [GAB09]. Folglich bilden die Daten auch die Basis für die Analysen im Rahmen des Data Mining. Dies nimmt eine wichtige Rolle bei der praktischen Umsetzung des Wissensmanagements ein [GAB09]. Doch bevor die Daten analysiert werden können, müssen diese oft in eine konsistente Form gebracht werden [HEI14]. HEINRICH ET AL. [HEI14] beschreiben in diesem Zusammenhang das Metadatenmanagement.

Steigender Wettbewerbsdruck

Den Bedarf nach Wissen auf Grund des steigenden Wettbewerbsdrucks beschreiben unter anderem REHÄUSER UND KREMAR [REH96], BODENDORF [BOD03] sowie BRODERSEN UND PFÜLLER [BRO13]. Der Umgang mit der Ressource Wissen ist unterschiedlich [BRO13]. Dieser hängt von den Unternehmensstrukturen, den aktuellen Herausforderungen, der Geschäftsstrategie sowie den eingesetzten Managementinstrumenten ab [PAW11]. Als Wettbewerbsfaktoren postulieren RUDOW ET AL. [RUD14] die Segmente der Globalisierung, Qualität, Organisations- und Arbeitsstruktur sowie das Personal. Das Data Mining kann dabei unterstützen mögliche Risiken der Wettbewerbsfaktoren effizient und frühzeitig zu erkennen.

Risikomanagement

Das Risikomanagement ist „zu einem neuen Management-Paradigma geworden“ [GAB09]. Um in einer Organisation eine unternehmensspezifische Risikobetrachtung durchzuführen, werden zunächst alle Risiken identifiziert. Nur mit einem bekannten Risiko ist eine anschließende Bewertung möglich [WIE10]. Das Data Mining unterstützt diesen Prozess durch effiziente und strukturierte Analyseverfahren (Kapitel 4.1 und 4.3). Mit Hilfe der Ergebnisse aus den Analyseverfahren kann dann entscheiden werden, wie mit einem Risiko umgegangen und welche Maßnahme ggf. eingeleitet wird.

Supplier Risk Monitoring

Customer Relationship Management

Ein großer Anwendungsbereich des Data Mining ist das Marketing [ADR98, EST00]. Im damit verbundenen Customer Relationship Management kann es bei der Entdeckung neuer Marktzusammenhänge [HEL17] oder auch bei der Erstellung von Zielkundenprofilen [GAB09] unterstützen. Mit Hilfe der IuK-Systeme wird eine kontinuierliche Interaktion mit dem Kunden für eine langfristige Bindung angestrebt [WER17].

Das Data Mining kann in den Bereichen auf unterschiedliche Art und Weise eingesetzt werden. Zusammenfassend werden folgende Aufgaben in der Literatur genannt [EST00, ELM17]:

- *Vorhersage*: Mit Hilfe von aktuellen Datensätzen können Verhaltensmuster in der Zukunft prognostiziert werden.
- *Identifizierung*: Datenmuster können dazu verwendet werden, um die Existenz eines Attributs, eines Ereignisses oder einer Tätigkeit zu identifizieren.
- *Klassifikation*: Mit Hilfe von Trainingsdaten werden Attribute einer Klasse zugeordnet. Das Ziel ist, eine Funktion zu erlernen, die zukünftige Daten anhand ihrer Attribute selbstständig in einer Klasse zuordnet.
- *Optimierung*: Im Bereich von Problemen des Operations Research werden Funktionen gesucht, durch die beschränkte Mittel, wie beispielsweise Zeit, Geld oder auch Materialien unter gegebenen Einschränkungen minimiert oder maximiert werden.

In Bezug zum Anwendungsbereich des Customer Relationship Management spricht WERNER [WER17] vom Supplier Relationship Management als Gegenstück in Bezug auf die Lieferanten-Abnehmer-Beziehung und damit das Lieferantenmanagement. Da das Data Mining in den Bereichen Marketing bzw. Customer Relationship Management bereits etabliert ist, liegt die Vermutung nahe, dass die im Data Mining enthaltenen statistischen Verfahren auch im Bereich des Lieferantenmanagements und damit speziell im TSM eingesetzt werden können. Diese Vermutung wird im folgenden Kapitel durch die Erarbeitung eines Gesamtmodells näher untersucht.

4.5.2 Data Mining zur Risikobetrachtung im Total Supplier Management

Der Prozess des Data Mining wird bisher in unterschiedlichen Unternehmensbereichen eingesetzt. Besonders in Unternehmensbereichen mit umfangreichen Datenbeständen ist das Anwendungspotenzial hoch. Durch die Vernetzung der unterschiedlichen Informationen werden Zusammenhänge innerhalb der Datenmuster erkannt, wodurch Wissen generiert wird. Aus diesem Wissen wird das weitere unternehmerische Handeln abgeleitet [GAB09]. In Tabelle 4-7 sind die aktuellen unternehmerischen Anwendungsfelder mit den jeweiligen Aufgaben abgebildet.

Tabelle 4-7: Anwendungsfelder des Data Mining
Quelle: Eigene Darstellung in Anlehnung an [GAB09]

Unternehmensbereich	Aufgaben
Marketing	• Kundensegmentierung • Warenkorbanalyse • Preisfindung
Controlling	• Ergebnisabweichungsanalyse • Entdeckung von Controllingmustern • Prognoseberechnung
Produktion	• Materialbedarfsplanung • Qualitätssicherung und -kontrolle
Finanzdienstleistungen	• Kreditrisikobewertung • Ermittlung von Risikofaktoren und Kursprognosen

Des Weiteren nennen ESTER UND SANDER [EST00] weitere Einsatzgebiete des Data Mining in den Bereichen Astronomie (Datenauswertung der Teleskope), Erdwissenschaften (Datenauswertung von Erdbeobachtungssatelliten) sowie bei E-Commerce-Anwendungen (Auswertungen über Nutzerverhalten) und Datenschutz (Datenmuster von Gruppen). PIAZZA [PIA10] setzt das Data Mining im Personalmanagement ein.

Bisher ist keine Publikation bekannt, die eine Nutzung des Data Mining sowie der Wissensgenerierung auf Basis von Datenmustern im Bereich des TSM beschreiben. Diese neue Art der Wissensgenerierung wird im Folgenden als Gesamtmodell mit dem Namen *Total Supplier Risk Monitoring* betrachtet. Als vereinfachter Überblick werden zunächst drei Bereiche differenziert (Bild 4-25):

- die Umwelt,
- die Wissensgenerierung durch Data Mining und
- der Managementprozess im Rahmen des TSM.

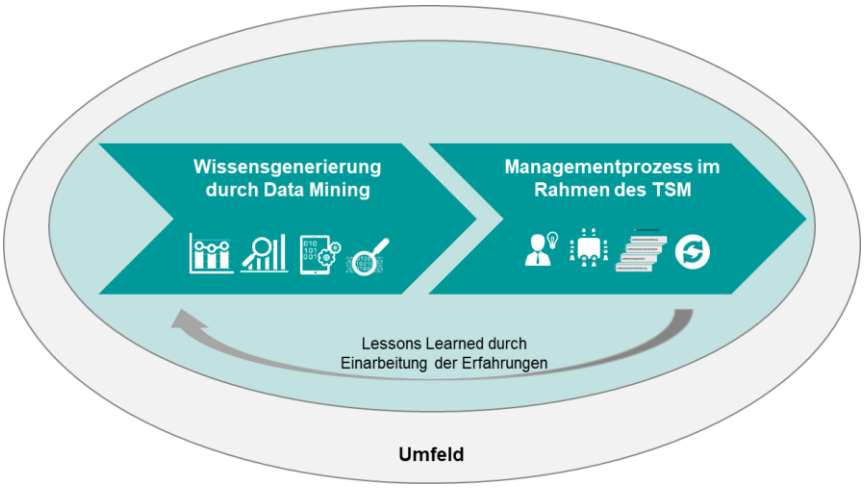


Bild 4-25: Gesamtmodell des Total Supplier Risk Monitoring
Quelle: Eigene Darstellung

In diesem Modell sind Komponenten des Wissensmanagements (Wissensgenerierung), des Data Mining und des TSM enthalten. Die Umwelt ist als externer Einflussgeber auf das System zu sehen. Um diese drei Bereiche innerhalb des gesamtheitlichen Kontextes weiter zu betrachten, wird das Modell weiter differenziert (Bild 4-26).

Als Umwelt wird in diesem Modell der Einfluss im Rahmen der Lieferanten-Abnehmer-Beziehung auf das Modell verstanden. Nach der differenzierten Risikobetrachtung im TSM (Kapitel 3.3.5) betrifft dies statische, operative und dynamische Risiken. Diese Betrachtung ist notwendig, um die Aufgabenstellung an das Modell zu verstehen (Umfeldverständnis). Der Schritt des Umfeldverständnis (Business Understanding) ist aus dem Prozess des CRISP-DM (Kapitel 4.4.3) als erste Stufe des Gesamtmodells übernommen worden (Business Understanding).

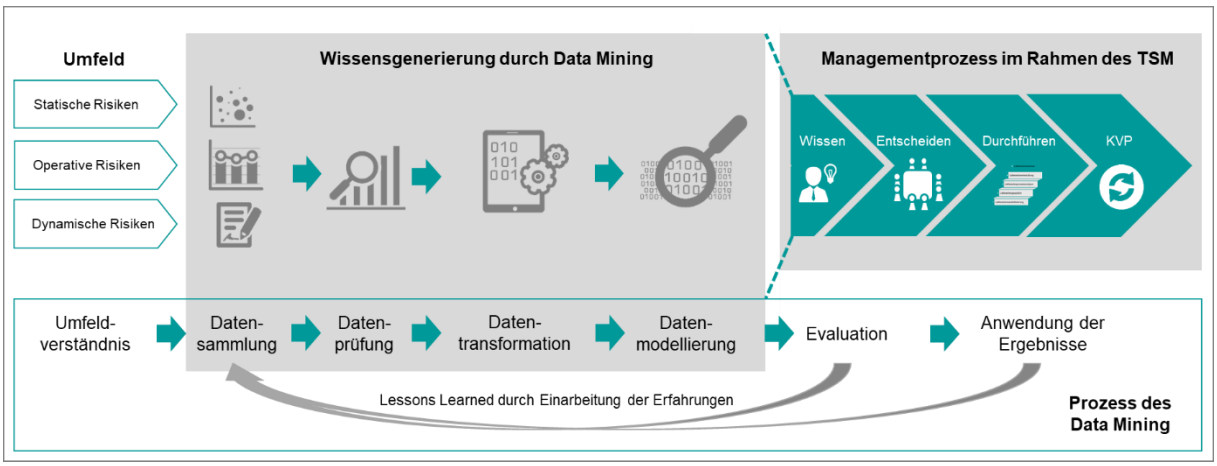


Bild 4-26: Data Mining im Total Supplier Management
Quelle: Eigene Darstellung

Auf dem Bereich der Wissensgenerierung mit den Data Mining-Schritten

- Datensammlung,
- Datenprüfung,
- Datentransformation und
- Datenmodellierung

liegt der weitere Fokus der vorliegenden Arbeit. Der Schritt der Datenmodellierung wird zunächst in den weiteren Kapiteln durch die Auswahl geeigneter Data Mining-Verfahren erörtert. Nach Auswahl der geeigneten Data Mining-Verfahren für die Erarbeitung des Gesamtmodells werden die Datensammlung, -prüfung und -transformation betrachtet.

Das Wissen, das durch die Datenmodellierung (Data Mining-Verfahren) generiert wird, fließt in den Lieferantensteuerkreis ein. Dort werden die Ergebnisse bewertet, sodass sie später innerhalb des Eskalationsmodells sowie beim KVP genutzt werden können. Der Managementprozess bildet somit für die Evaluation und Anwendung der Analyseergebnisse aus dem Bereich der Wissensgenerierung den letzten Schritt, bevor die Iterationsschleife beginnt.

4.6 Data Mining im Rahmen des Wissens- und Total Supplier Managements

Bisher sind verschiedene Analysen mit dem Gesamtergebnis der Datenmustererkennung separat betrachtet worden. In diesem Kapitel wird das Data Mining nun generisch angewendet. Dazu werden die bisher diskutierten, theoretischen Grundlagen in Bezug zur Aufgabenstellung der vorliegenden Arbeit vereint:

- Workflow des TSM in Verbindung mit dem Wissensmanagement
- Wissensgenerierung mit Hilfe des Data Mining
- Data Mining-Verfahren zur Generierung von Datenmustern im Rahmen der Datenmodellierung

Auf Basis dieser verschiedenen Grundlagen wird das Gesamtmodell für den Anwendungsfall einer Lieferantenbewertung beschrieben, um präventive Maßnahmen einzuleiten. Die Entwicklung dieses Gesamtmodells wird mit Hilfe der Data Mining-Prozessschritte aus Bild 4-26 vorgenommen. Diese sind in Bild 4-27 nochmals separiert dargestellt:

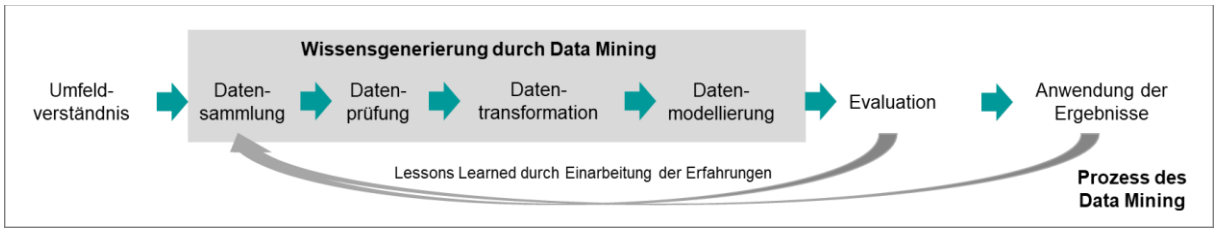


Bild 4-27: Data Mining-Prozessschritte im Rahmen des TSM
Quelle: Eigene Darstellung

Begonnen wird mit dem Prozessschritt des Umfeldverständnisses, um dann die Prozessschritte der Wissensgenerierung näher zu erörtern. Zum Abschluss werden die Ergebnisse im Rahmen des TSM-Prozesses evaluiert und angewendet.

4.6.1 Umfeldverständnis

Das Ziel der vorliegenden Arbeit ist die Konzeption eines Modells zur effizienten Wissensgenerierung im Bereich des TSM. Dieses generierte Wissen soll im Rahmen des Wissensmanagements zur frühzeitigen Risikoerkennung genutzt werden. Wie in Kapitel 4.5.2 beschrieben, ist es dafür zunächst wichtig, die Aufgabenstellung für den Data Mining-Prozess zu verstehen. Dies geschieht im Prozessschritt des Umfeldverständnisses. Diesen Prozessschritt beschreiben CIOS ET AL. [CIO07] als Erlangung eines Verständnisses für die betriebswirtschaftlichen Ziele und Anforderungen. Diese werden dann in eine Problemdefinition, die es mit Hilfe des Data Mining zu lösen gilt, verfasst. In Bild 4-28 wird somit das Umfeldverständnis in den Kontext des Data Mining-Prozesses sowie die Aufgaben des Wissensmanagements und dem Workflow des TSM im Rahmen der vorliegenden Arbeit einordnet.

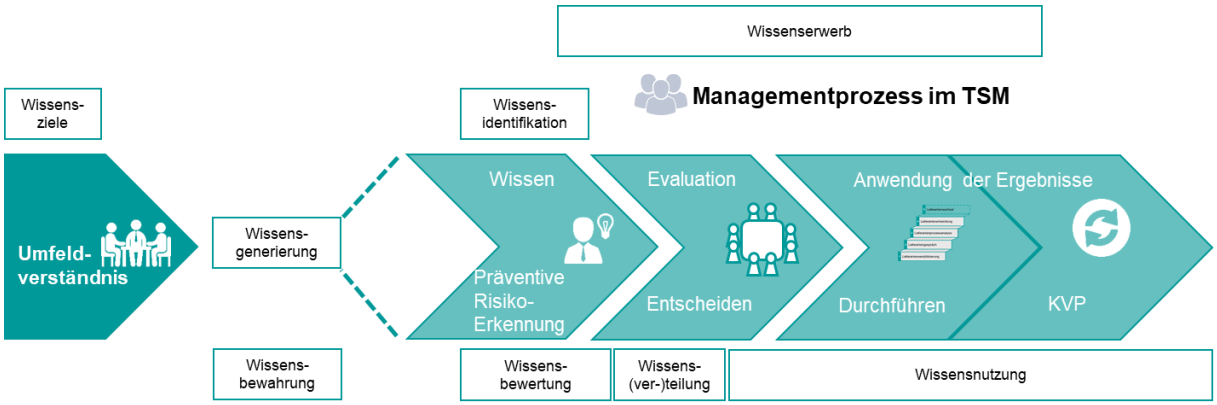


Bild 4-28: Umfeldverständnis des Data Mining-Prozesses im Kontext zum TSM sowie der Verbindung zu den acht Bausteinen des Wissensmanagements
Quelle: Eigene Darstellung

Risiken sollen im externen Wertschöpfungsnetzwerk möglichst frühzeitig erkannt werden, damit präventive Maßnahmen eingeleitet werden können (Kapitel 1.2). Diese Risiken haben ihren Ursprung in der Lieferanten-Abnehmer-Beziehung (Kapitel 3.3). Somit soll innerhalb des Data Mining nach Lieferanten gesucht werden, welche möglicherweise die Anforderungen des Abnehmers nicht erfüllen. Diese Lieferanten werden in der vorliegenden Arbeit als potenziell kritische Lieferanten bezeichnet. Bei potenziell kritischen Lieferanten besteht ein erhebliches Versorgungsrisiko [ZOB09], was aber nicht zwingend eintreten muss.

Allgemein hat jeder Lieferant spezielle Ausprägungen im Rahmen der unternehmensspezifisch festgelegten Kennzahlen sowie bei den allgemeinen Informationen, wie beispielsweise dem Geschäftssitz oder Produktionsstandort. Daraus lassen sich verschiedene lieferantenspezifische Merkmale definieren: leistungsbeschreibende und nicht-leistungsbeschreibende Merkmale. Diese Merkmale sind für die vorliegende Arbeit besonders in Bezug auf potenziell kritischen Lieferanten von Relevanz.

Leistungsbeschreibende Merkmale haben ihren Ursprung in den dynamischen Daten. Diese dynamischen Daten reflektieren Kennzahlen zur Steuerung der Geschäftsprozesse. Für die Beschreibung eines kritischen Lieferanten werden bei Leistungsdefiziten oft Muster dieser Merkmale definiert, ab denen ein Lieferant als kritisch gilt. Im Rahmen des TSM sind dies Lieferanten mit einem negativen Trend im Trend- und Prognosemodell. Im Rahmen der Hypothesenfreiheit der Assoziationsanalyse werden leistungsbeschreibenden Merkmale mit ihren entsprechenden Ausprägungen ohne eine vorherige Interpretation, ob die Merkmalsausprägung kritisch ist oder nicht, verwendet.

Zusätzlich zu den leistungsbeschreibenden können *nicht-leistungsbeschreibende Merkmale* für potenziell kritische Lieferanten zur Beurteilung der Leistung von Lieferanten hinzugezogen werden. Diese Merkmale können dynamisch und auch statisch, d.h. unveränderlich, wie z.B. ein Produktionsstandort, ausgeprägt sein. Zu statischen, nicht-leistungsbeschreibenden Merkmale können dynamische Risikoereignisse zugeordnet werden (Kapitel 3.3.5). Sind beispielsweise politische Unruhen in einem Land bekannt, kann diese Information für die Risikobetrachtung hinsichtlich der dort ansässigen Lieferanten hinzugezogen werden.

Im Zuge der Risikobetrachtung werden diese leistungsbeschreibenden und nicht-leistungsbeschreibenden Merkmale in einer Datenbank gesammelt und gespeichert. Die Vorgehensweise der Datensammlung wird im Folgenden erörtert.

4.6.2 Datensammlung

Mit dem Prozessschritt der Datensammlung beginnt der Prozess der Wissensgenerierung. Zur Einordnung der einzelnen Prozessschritte im Kontext des Wissensmanagement und des TSM dient Bild 4-29.



Bild 4-29: Wissensgenerierung des Data Mining-Prozesses im Kontext zum TSM sowie der Verbindung zu den acht Bausteinen des Wissensmanagements
Quelle: Eigene Darstellung

Innerhalb der Datensammlung wird eine Differenzierung der Daten nach ihrer Relevanz für die Aufgabenstellung in Bezug auf das Umfeldverständnis vorgenommen. Die Einteilung von relevanten und nicht-relevanten Daten für die Analyse durch das Data Mining beschreiben HEINZ ET AL. [HEI02] als schwierig. Beim Vorgehen zur Identifizierung relevanter Daten und Datenquellen lehnt sich die vorliegende Arbeit an den Prozess von SCHMITT ET AL. [SCH16] an. Dieser Prozess gliedert sich in vier Stufen. Bezogen auf den Data Mining-Prozessschritt des Umfeldverständnis ergibt sich das folgende gestufte Vorgehen (Bild 4-30). Generisch kann auf Basis dieses Vorgehens jedem lieferantenbezogenen Merkmal eine Datenquelle zugeordnet werden. Es ist jedoch unternehmensspezifisch zu prüfen, welche leistungsbeschreibenden und nicht-leistungsbeschreibenden Merkmale auf Basis der in Kapitel 3.3.5 erörterten Risikobetrachtung im TSM eine Relevanz für den weiteren Workflow aufweisen. Die Kriterien für eine Relevanzprüfung können dabei folgendermaßen ermittelt werden [DUS18]:

- In der Vergangenheit eingetretene Risiken, die anhand von leistungsbeschreibenden und nicht-leistungsbeschreibenden Merkmale identifiziert werden (dokumentierte Risiken)
- Mitarbeiterbefragung, um vermiedene Risiken zu identifizieren (nicht dokumentierte Risiken)

Auf der Basis von Häufigkeit des Eintretens sowie der Bedeutung werden die relevanten Risiken und somit auch die entsprechenden leistungsbeschreibenden und nicht-leistungsbeschreibenden Merkmale definiert [DUS18]. An diese Merkmale werden verschiedene Anforderungen gestellt, damit sie auch im weiteren Data Mining-Prozess verwendet werden können. Die Anforderungen an die leistungs- und nicht leistungsbeschreibenden Merkmale werden wie folgt zusammengefasst:

- *Aussagekraft*: Das Merkmal muss eine sinnvolle Aussage über einen relevanten Tatbestand bzw. Prozess im Rahmen der Supply Chain Risikobetrachtung enthalten. Beispiels-

weise sollten nicht ausschließlich korrelierende Merkmale genutzt werden. Diese Merkmale weisen eine Redundanz auf und haben somit keinen Mehrwert für die Aussagekraft des generierten Wissens.

- *Permanente und stabile Verfügbarkeit*: Das Merkmal muss dauerhaft zur Verfügung stehen. Zusätzlich darf sich das Merkmal im Inhalt, wie beispielsweise in Bezug auf die Berechnung einer Kennzahl, nicht verändern.
- *Repräsentativität*: Repräsentiert ein Merkmal ein Risiko, wird für ein betrachtetes Risiko eine Kennzahl definiert. Zusätzlich muss dieses Merkmal auch eine Aussage über eine repräsentative Grundgesamtheit zulassen.
- *Zweckneigung*: Das zu betrachtende Merkmal muss zur Lösung der Aufgabe und damit für das entsprechend anzuwendende Analyseverfahren geeignet sein.

Diese vier Anforderungen stellen die Mindestvoraussetzungen im Rahmen der Datensammlung dar. Sind die Mindestvoraussetzungen erfüllt, werden die Daten in einem strukturierten Prozess gesammelt. Dieser Prozess wird nachfolgend in Bild 4-30 beschrieben.

Die im Bild 4-30 beschriebenen und zugehörigen, relevanten Prozesse, Daten und Datenquellen sind im Rahmen der vorliegenden Arbeit als Beispiele zu betrachten, da diese in Abhängigkeit der Risikobetrachtung im TSM (Kapitel 3.3.5) unternehmensspezifisch angepasst und nicht pauschal definiert werden können. Im Folgenden wird das Bild 4-30 näher erörtert.

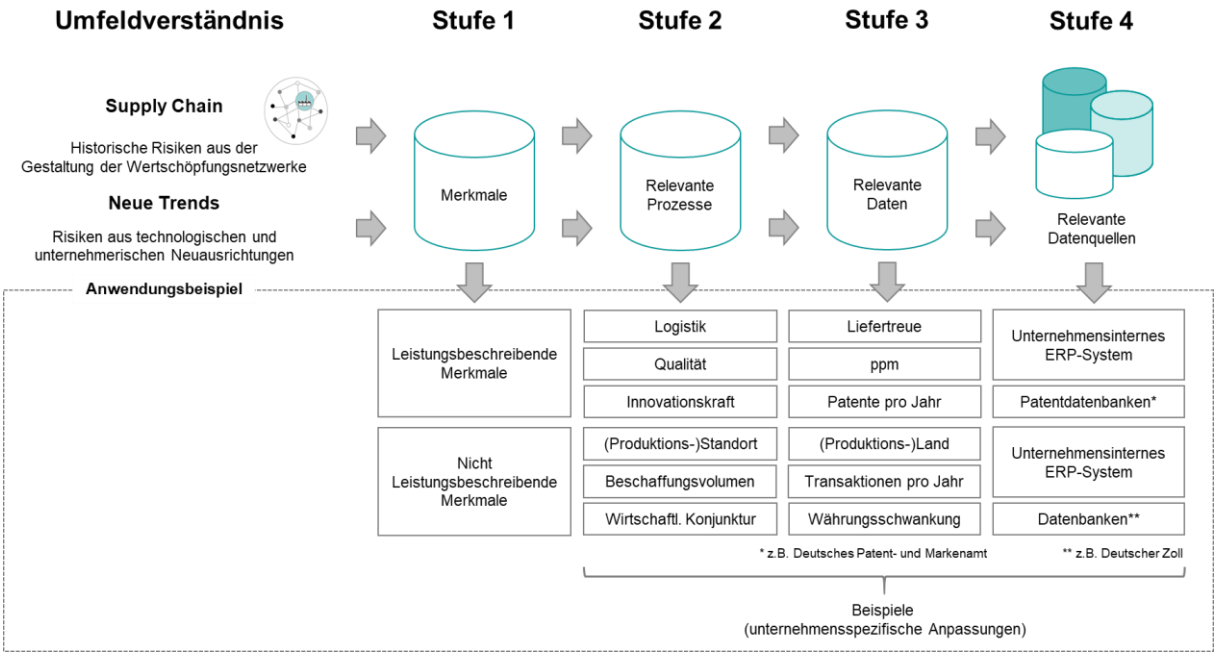


Bild 4-30: Vierstufiges Vorgehen zur Identifizierung relevanter Daten und Datenquellen
Quelle: Eigene Darstellung in Anlehnung an [SCH16]

Aus dem Umfeldverständnis und der damit verbundenen differenzierten Risikobetrachtung (Kapitel 3.3.5) werden in der *ersten Stufe* zur Datensammlung die leistungsbeschreibenden und nicht-leistungsbeschreibenden Merkmale der Lieferantenbasis betrachtet. Leistungsbeschreibende Merkmale dienen der Risikoidentifikation mit Hilfe von Kennzahlen. Die nicht-leistungsbeschreibenden Merkmale bestehen im vorliegenden Beispiel aus allgemeinen Informa-

tionen, wie z.B. dem Namen, dem (Produktions-)Standort des Lieferanten oder auch der Anzahl der Transaktionen (Bestellungen), die in einem bestimmten Zeitraum durchgeführt werden.

Durch die steigende externe Wertschöpfung sowie die komplexen Produktionsprozesse muss in der *zweiten Stufe* eine ganzheitliche Betrachtung der relevanten Prozesse stattfinden [SCH16]. In Bezug auf die vorliegende Arbeit und das Anwendungsbeispiel aus Bild 4-30 sind das die logistischen und qualitativen Prozesse sowie die Innovationskraft als Rückkopplung zu erfolgreichen Forschungs- und Entwicklungsprozessen. Für die nicht-leistungsbeschreibenden Merkmalen sind das beispielsweise der Produktionsstandort zur Überwachung der Logistik oder auch das Beschaffungsvolumen zur Überprüfung der Beschaffungsprozesse.

Diese relevanten Prozesse werden mit Hilfe von Kennzahlen beurteilt [SCH16]. Die spezifischen Kennzahlen sind in der *dritten Stufe* auszuwählen und werden als Datensätze abgespeichert. Logistische Prozesse können beispielsweise über die Kennzahl Liefertreue und qualitative Prozesse durch die Kennzahl ppm bewertet werden. Analog dazu ist der Bezug zwischen den weiteren in Bild 4-30 dargestellten relevanten Prozessen und Daten zu sehen.

Gespeichert werden die Kennzahlen in Form von Daten. Die Gesamtheit der Daten stellt die Datenbasis dar [SCH16]. Diese ist wiederum verteilt auf verschiedene Datenquellen. Im *vierten Schritt* der Datensammlung werden diese Datenquellen ausgewählt. Diese Datenquellen können beispielsweise unternehmensinterne ERP-Systeme oder auch interne sowie externe Datenbanken sein. Das Ergebnis dieses vierstufigen Vorgehens zur Identifikation relevanter Daten und datenquellen sind Smart Data [MAN17]. Die Gesamtheit aller Daten der Datenquellen stellt die Masse von Big Data dar. Für den Prozess des Data Mining wird die Datenbasis im weiteren Verlauf auf die notwendige Datenqualität überprüft.

Es ist möglich, dass eine „unreflektierte Verwendung aller zur Verfügung stehender Daten (Big Data) […] zu kontraproduktiven Ergebnissen führen kann“ [MAN17]. Somit ist es notwendig, dass die leistungs- und nicht-leistungsbeschreibenden Merkmale aus den Datenquellen für die weiteren Analyseverfahren als Smart Data betrachtet werden.

4.6.3 Datenprüfung

Die verschiedenen Datenquellen, aus denen die relevante Datenbasis entsteht, weisen eine unterschiedliche, teilweise mangelhafte Qualität der Datensätze auf [STA16]. Somit muss die Datenbasis auf die gewünschte Datenqualität überprüft werden, um für die weitere Verarbeitung im Data Mining-Prozess genutzt werden zu können [SCH17] (siehe hierzu auch Kapitel 5). VOSSEN [VOS08] nennt in dem Zusammenhang zwei Aspekte mangelnder Datenqualität:

- Qualitätsprobleme innerhalb vereinzelter Quellen
- Qualitätsprobleme auf Grund des Datenbankdesigns

Unter mangelnder Datenqualität auf Grund des Datenbankdesigns versteht der Autor beispielsweise Konflikte zwischen Tabellen- und Merkmalsnamen [VOS08]. Aus diesem Grund sollte das Datenbankdesign so gewählt werden, dass eine effiziente Wissensgenerierung möglich ist [TIE97]. SCHMITT ET AL. [SCH16] werden in ihren Ausführungen in Bezug auf Datenqualitätsmängel konkreter. Für sie sind z. B. die Mehrdeutigkeit von Eingabefeldern durch

ungenügende Definitionen oder auch einzelne fehlerhafte Daten durch manuelle Eingaben problematisch.

Konkrete Lösungsansätze zur Analyse der Datenqualität sind hingegen bei DUST [DUS15, DUS18] zu finden. Dabei wird auf die Analyse der Konzeption (von Kennzahlen), der Datenverfügbarkeit, der -validität und -plausibilität mittels verschiedener Data Checker verwiesen (Kapitel 5.2). Die Ursache einer schlechten Datenqualität liegt dabei laut DUST in „historisch gewachsenen IT-Strukturen, sodass die Auswahl und Berechnung von Daten nicht einer durchgängigen Systematik folgt“ [DUS18].

Doch bisher fehlen praxisgeeignete Instrumente (IT-Systeme) zur Prüfung und Verbesserung der Datenqualität [STA16]. Auch SCHMITT ET AL. [SCH16] sehen hier weiteren Forschungsbedarf, um die Anzahl der fehlerhaften Datensätze zu verringern. In Kapitel 5 wird aus diesem Grund explizit auf die Themen der Prüfung und Verbesserung der Datenqualität nochmals vertiefend eingegangen. Dabei soll auch untersucht werden, welche Analyseprozesse für die notwendige Qualitätsprüfung der Daten genutzt werden können.

4.6.4 Datentransformation

Im weiteren Verlauf der vorliegenden Arbeit wird zur Verdeutlichung des zu erarbeitenden Modells der Datenbasis zunächst eine geeignete Datenqualität unterstellt. Somit beginnt der Prozessschritt der Datentransformation. Die Daten werden, für die im nächsten Prozessschritt durchzuführenden Analyseverfahren aufbereitet. Dies geschieht bereits mit Hilfe der Auswahl von leistungsbeschreibenden und nicht leistungsbeschreibenden Merkmalen im Rahmen der Datensammlung (Bild 4-30), die für die Analyseverfahren notwendig sind [CHA09].

Im weiteren Verlauf werden die Verfahren Trendberechnung aus dem Trend- und Prognosemodell, Clusteranalyse, Assoziationsanalyse sowie Relevanzprüfung zur Mustererkennung in Datensätzen eingesetzt. Diese fordern bestimmte Bedingungen zur Datenaufbereitung. Die Anforderungen der Analyseverfahren in Bezug auf die Aufgabenstellung der vorliegenden Arbeit werden in Tabelle 4-8 erläutert.

Tabelle 4-8: Datentransformation von Big Data zu Smart Data für die Data Mining-Verfahren
Quelle: Eigene Darstellung

Position	Verfahren	Smart Data für das Auffinden potenziell kritischer Lieferanten	Datentypen
1	Trendberechnung aus dem Trend- und Prognosemodell	• Mindestens 1 Wert pro KPI in den vergangenen zwei Monaten • Mindestens 6 Werte pro KPI in den vergangenen 12 Monaten	• Metrisch
2	Clusteranalyse	• KPIs mit beliebiger Skalierung	• Metrisch
3	Assoziationsanalyse	• Leistungsbeschreibende Merkmale • Nicht-leistungsbeschreibende Merkmale	• Metrisch • Ordinal • Nominal
4	Relevanzprüfung	• Quantitative Assoziationsregeln	• Metrisch • Ordinal • Nominal

Werden die Daten für die vier Analyseverfahren aufbereitet, muss auf das Zielformat geachtet werden. Beispielsweise nutzt das die Trendberechnung aus dem Trend- und Prognosemodell ausschließlich metrisch skalierte Daten (Kennzahlen). Da in der vorliegenden Arbeit Kennzahlen geclustert werden, beschränkt sich die Betrachtung ebenfalls auf metrisch skalierte Datentypen [LAN15]. Bei der Assoziationsanalyse kommen zusätzlich zu den Daten der Clusteranalyse weitere Daten hinzu (nicht leistungsbeschreibende Attribute), die für die Generierung der Datenmuster (quantitative Assoziationsregeln) verwendet werden. Somit werden bei der Assoziationsanalyse alle Datentypen verwendet [EST00]. Diese Datentypen, die zur Generierung der quantitativen Assoziationsregeln genutzt werden, fließen danach in die Relevanzprüfung ein. Die Datentypen werden dabei wie folgt differenziert [HEI14]:

Metrische Datentypen

Metrische oder auch kardinale Datentypen bestehen aus einer Zahl und sind durch eine Dimension geprägt. Zusätzlich besitzen diese einen absoluten oder natürlichen Nullpunkt. Bei der Arbeit mit einer metrischen Skala sind alle mathematischen Operationen gestattet.

Ordinale Datentypen

Diese Datentypen folgen einem natürlichen Rang n-ter Ordnung. Die Merkmale sind qualitativ geprägt und geben an, ob mit Hilfe des paarweisen Vergleichs eine Alternative größer, gleich oder kleiner als eine andere Alternative ist. Die Einschätzung von Alternativen kann beispielsweise mit „gut“, „mittel“ und „schlecht“ vollzogen werden.

Nominale Datentypen

Die Bewertung erfolgt über Unterschiede durch die Zuordnung von Kategorien. Diese qualitativen Merkmalsausprägungen haben keine natürliche Ordnung. Sie können über „ja“ oder „nein“ bzw. „erfüllt“ oder „nicht erfüllt“ ausgedrückt werden.

Sind alle Daten auf ihre Datenqualität hin überprüft (Kapitel 4.6.3 sowie Kapitel 5) und transformiert, wird diese Datenbasis mit Hilfe der entsprechenden statistischen Verfahren zur Datenmustererkennung analysiert. Diese Analyse der Datenmuster geschieht im Rahmen der Datenmodellierung.

4.6.5 Datenmodellierung

Die Datenmodellierung repräsentiert den Analyseschritt mit Hilfe statistischer Verfahren. Das Ziel ist die Identifizierung von relevanten Assoziationsregeln. Auf Basis dieser relevanten Assoziationsregeln werden die Datenmuster der zugeordneten Lieferanten analysiert, um Wissen über die externen Wertschöpfungsnetzwerke zu erhalten. Um dieses Ziel zu erreichen, wird die Datenmodellierung in der vorliegenden Arbeit in drei statistische Verfahren gegliedert (Kapitel 4.3):

- Trendberechnung aus dem Trend- und Prognosemodell
- Clusteranalyse
- Assoziationsanalyse
- Relevanzprüfung

Diese vier Verfahren werden, wie in Kapitel 4.3 beschrieben, angewendet. Durch die Verbindung der Clusteranalyse mit der Assoziationsanalyse werden quantitative Assoziationsregeln erzeugt. Um diese Verfahren nochmals in den Kontext des Gesamtmodells zu bringen, dient Bild 4-31 zur Visualisierung.

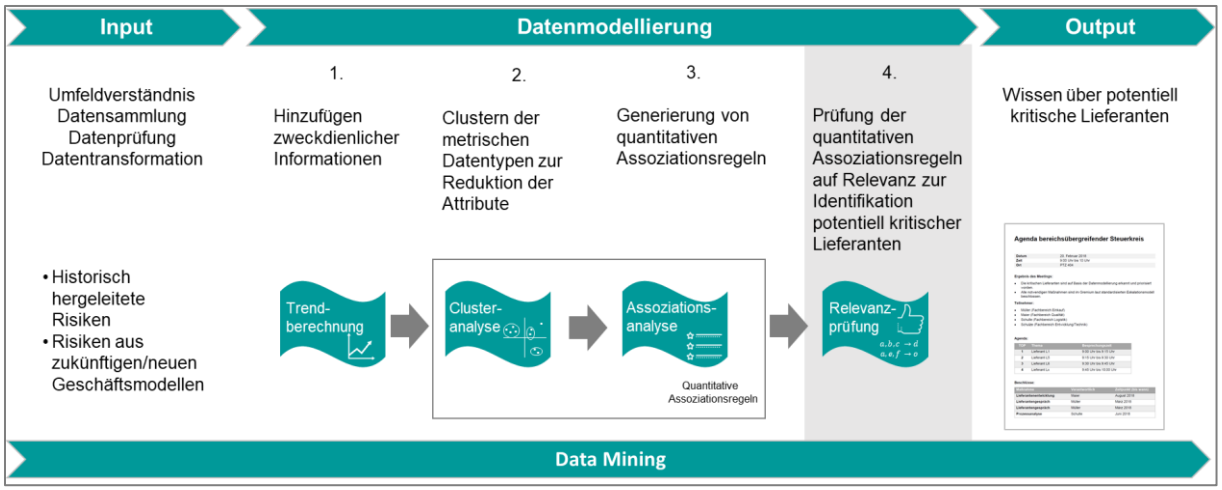


Bild 4-31: Anwendung der Datenmodellierung im Kontext des Data Mining
Quelle: Eigene Darstellung

Der Input für den Schritt der Datenmodellierung entsteht aus den Ergebnissen der in Kapitel 4.5.1 bis Kapitel 4.5.4 beschriebenen Data Mining-Prozessschritte. Im Folgenden dient Tabelle 4-9 dazu, die vier kombinierten Analyseverfahren der Datenmodellierung deutlich voneinander in ihrem In- und Output abzugrenzen. Das Alleinstellungsmerkmal und damit der Mehrwert eines jeden Verfahren sind entsprechend hervorgehoben.

Tabelle 4-9: Abgrenzung der Verfahren im Rahmen der Datenmodellierung
Quelle: Eigene Darstellung

Position	Analyseverfahren	Input	Output
1	Trendberechnung aus dem Trend- und Prognosemodell	• Merkmalsausprägungen zu folgenden Kennzahlen über die vergangenen 12 Monate (Auswahl von leistungsbeschreibenden Merkmalen): ○ Z.B. Termintreue Liefertreue ○ Z.B. ppm • *Bewertung aller Lieferanten*	• *Trend* über 12 Monate • *Trend* über die letzten 3 Monate • Ergebnisse über alle Lieferanten in Bezug zu ○ Z.B. Termintreue Liefertreue ○ Z.B. ppm
2	Clusteranalyse	• Alle aktuellen leistungsbeschreibenden Merkmale (Kennzahlen) • Nicht leistungsbeschreibende Merkmale (metrische Datentypen) • Trend über 12 Monate und • Trend über die letzten 3 Monate in Bezug auf ○ Z.B. Termintreue Liefertreue ○ Z.B. ppm • *Bewertung aller Lieferanten*	• *Cluster* der leistungsbeschreibenden und nicht leistungsbeschreibenden Attribute aller Lieferanten
3	Assoziationsanalyse	• Cluster der leistungsbeschreibenden und nicht leistungsbeschreibenden Attribute aller Lieferanten • *Alle weiteren, nicht leistungsbeschreibende Attribute (z.B. Text)*	• Quantitative Assoziationsregeln über die *gesamte Datenbasis aller Lieferanten*
4	Relevanzanalyse	• Quantitative Assoziationsregeln aus leistungsbeschreibenden und nicht leistungsbeschreibenden Attributen	• *Teilmenge aus quantitativen Assoziationsregeln, die auf potenziell kritische Lieferanten hinweisen*

Die genutzten Verfahren sind in der vorliegenden Arbeit bereits beschrieben worden (Kapitel 4.3). Als Analyseergebnis der Relevanzprüfung können zusammenfassend drei Zustände festgestellt werden:

- Kritische Lieferanten werden auf Basis des Trends aus dem Trend- und Prognosemodell gefunden und dem Steuerkreis als solche gemeldet (Hypothese)
- Die quantitative Assoziationsregel hat eine hohe praktische Relevanz zum Auffinden weiterer potenziell kritischer Lieferanten gegenüber der reinen Trendbetrachtung (hypothesenfrei).
- Die quantitative Assoziationsregel hat eine geringe praktische Relevanz. Somit wird diese zunächst verworfen und die Ausgangsbasis (z.B. Anpassung der Cluster oder Änderung der Interessantheitsmaße) in einem lernenden Prozess verändert.

Diese drei Zustände sind Bild 4-32 dargestellt und werden im Folgenden näher erläutert.

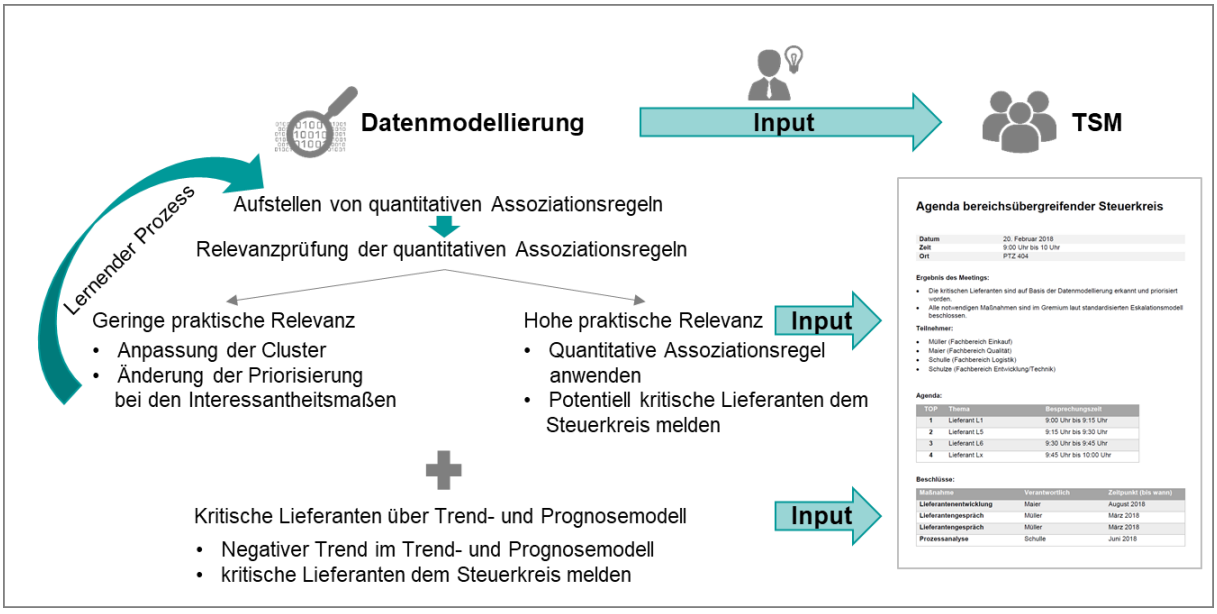


Bild 4-32: Beispiel für einen lernenden Prozess zwischen Datenmodellierung und dem TSM
Quelle: Eigene Darstellung

Kritische Lieferanten werden über über den Trend aus dem Trend- und Prognosemodell gefunden.

Lieferanten mit einem negativen Trend in der Leistungserbringung z.B. in den Bereichen Logistik (Liefertreue) und Qualität (ppm) werden als kritische Lieferanten bezeichnet. Diese werden über das Trend- und Prognosemodell gefiltert und gefunden. Diese als kritisch definierten Lieferanten werden im Lieferantensteuerkreis gemeldet.

Die quantitative Assoziationsregel hat eine hohe praktische Relevanz.

Nach der Relevanzprüfung werden quantitative Assoziationsregeln mit hoher praktischer Relevanz regelmäßig untersucht. Dabei kann es beispielsweise vorkommen, dass bereits durch die Trendberechnung auf Basis des Trend- und Prognosemodells als kritisch definierte Lieferanten mit Weiteren, bisher nicht als kritisch eingestuften Lieferanten einer Regel zugeordnet werden. In diesem Fall wird geprüft, ob die bisher nicht als kritisch eingestuften Lieferanten

ebenfalls nun priorisiert betrachtet werden oder aber nicht. Die Analyseergebnisse im Rahmen der Datenmodellierung dienen als Wissensinput für den bereichsübergreifenden Steuerkreis.

Die quantitative Assoziationsregel hat eine geringe praktische Relevanz.

Hat die quantitative Assoziationsregel nach der Relevanzprüfung eine geringe Aussagekraft, geht diese Information in den Data Mining-Prozess ein. Das Ergebnis fließt in die Generierung neuer relevanter, quantitativer Assoziationsregeln ein (Bild 4-32). Gegebenenfalls ist es zielführend zur Datenselektionsphase zurückzukehren, wenn festgestellt wird, dass sich die gewünschten Ergebnisse nicht mit der genutzten Datenbasis erreichen lassen. Es entsteht ein iterativer und somit lernender Prozess.

Die während der Datenmodellierung genutzten Verfahren gehen jedoch nicht der Frage nach, warum eine Implikation eintritt. Vielmehr ist das Ergebnis, dass eine bestimmte Implikation auf eine bestimmte Prämisse folgt. Somit steht auch nur die Auffälligkeit von potenziell kritischen Lieferanten anhand ihrer Zuordnung zu quantitativen Assoziationsregeln und spezifischen Datenmustern im Vordergrund, ohne die Ursache für das Analyseergebnis zu beantworten. Die Ursache für eine entsprechende Auffälligkeit von potenziell kritischen Lieferanten kann, über die vorliegende Arbeit hinausgehend, auf Basis kausalanalytischer Betrachtungen zusätzlich analysiert werden. Diese kausalanalytischen Betrachtungen sind über experimentelle Langzeitstudien möglich [HET01].

Das durch die Datenmodellierung erworbene Wissen über potenziell kritische Lieferanten wird in den Managementprozess eingesteuert. Es ist somit im weiteren Verlauf des Managementprozesses zu eruieren, ob die Lieferanten zukünftig tatsächlich kritisch werden können und welche präventiven Maßnahmen unternommen werden, um dies zu verhindern bzw. die vorhandene Leistungsfähigkeit abzusichern.

4.6.6 Evaluation und Anwendung der Ergebnisse

Bisher ist das Wissen zur präventiven Risikoerkennung und der damit verbundenen Steuerung der externen Wertschöpfung generiert worden. Nun fließt es in den Managementprozess des TSM ein. Somit sind die mit dem Data Mining verbundenen Schritte der *Evaluation* sowie der *Anwendung der Ergebnisse* in den Managementprozess integriert. Mit dieser Integration kann das so entstandene explizite Wissen für die Organisation genutzt werden (Bild 4-33).

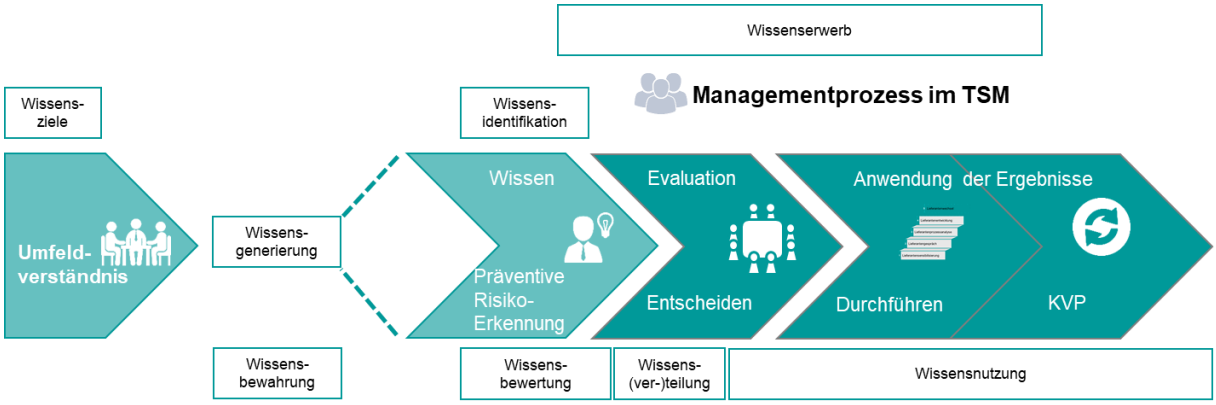


Bild 4-33: Evaluation und Anwendung der Ergebnisse des Data Mining-Prozesses im Kontext zum TSM sowie der Verbindung zu den acht Bausteinen des Wissensmanagements

Quelle: Eigene Darstellung

Die Wissens(ver-)teilung übernimmt der Lieferantensteuerkreis als Expertenteam. Allen beteiligten Fachbereichen steht das generierte und bewertete Wissen regelmäßig zur Verfügung. Der Steuerkreis tagt nach einer festgelegten Agenda. In dieser Zeit entscheidet der Steuerkreis über Maßnahmen zur Sicherung oder Wiederherstellung der Leistungserbringung beim Lieferanten und hält diese in einem Beschluss fest. Zur Auswahl der Maßnahmen dient das standardisierte Eskalationsmodell (Kapitel Durchführen. Der Lieferantenmanager wird vom Steuerkreis mit der Durchführung von Maßnahmen zur Sicherung und Wiederherstellung der Lieferantenperformance beauftragt. Das generierte Wissen wird an die Lieferantenmanager zur Durchführung der Maßnahmen verteilt und dann innerhalb der Lieferantenentwicklungsprojekte genutzt (Kapitel 3.4.3).

Das Wissen, das die Lieferantenmanager mit der Durchführung von Lieferantenentwicklungsprojekten sammeln, geht wiederum in die Datenbasis zur neuen Wissensgenerierung ein. Dieser iterative Prozess wird ständig durchlaufen. So entsteht ein weiterer ganzheitlicher, lernender Prozess im Bereich des Data Mining.

Das Vorgehen im Rahmen des Data Mining erfüllt die Anforderungen an eine Wissensgenerierung im Rahmen der Lieferantenbewertung (Kapitel 2.4). Der Steuerkreis ist mit diesem Prozess in der Lage, effizient Wissen aus einer großen Datenbasis zu generieren. Diese Datenbasis ist bereichsübergreifend. Über quantitative Assoziationsregeln werden mögliche, kritische Datenmuster aus leistungsbeschreibenden und nicht leistungsbeschreibenden Attributen gefunden. Mit der zusätzlichen Vernetzung der Trendberechnung auf Basis des Trend- und Prognosemodells ist es möglich, dem Steuerkreis Wissen zur Verfügung zu stellen, auf dessen Basis präventive Entscheidungen über Maßnahmen zur Absicherung oder Wiederherstellung der Lieferantenleistung getroffen werden (Kapitel Durchführen).

4.7 Zusammenfassung und Fazit

In der Vergangenheit ist das Sammeln und (teilweise) manuelle Auswerten von Daten zur Bewertung von Lieferanten [JAN08] meist mit einer hohen Bindung von Ressourcen (Zeit, Mitarbeiter etc.) gekoppelt gewesen [GIE11]. Mit Hilfe von Data Mining als Teil des Wissensmanagements kann dieser Aufwand durch die automatisierte Wissensgenerierung gesenkt werden. Große Datenmengen aus verschiedenen Datenquellen werden durch statistische Verfahren standardisiert analysiert. Das Data Mining vereint verschiedene Disziplinen (Bild 4-34). Diese stehen durch die Vernetzung des Wissensmanagements in einer engen Verbindung.

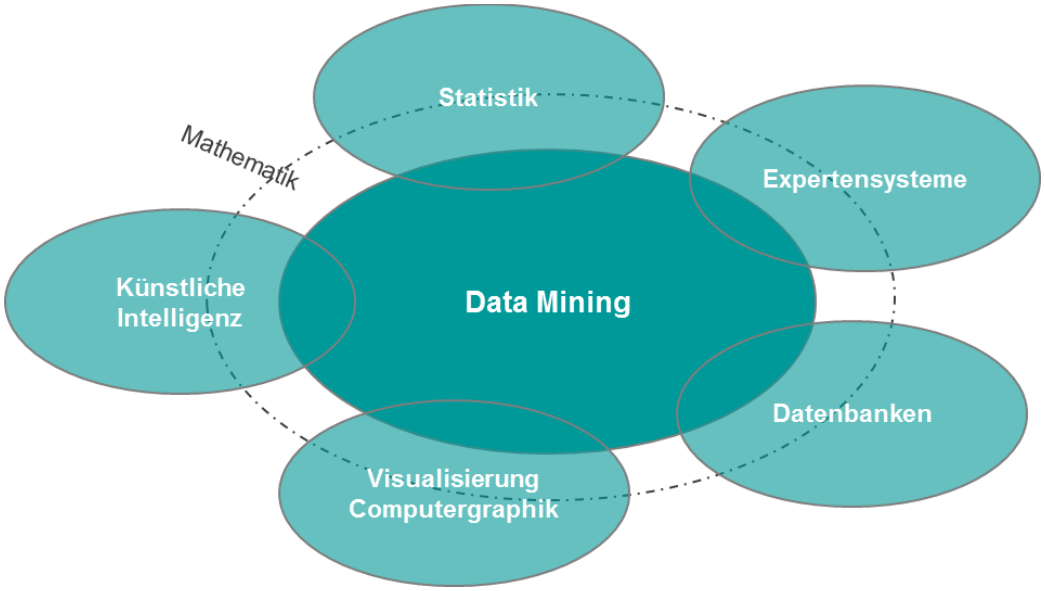


Bild 4-34: Interdisziplinarität des Data Mining
Quelle: Eigene Darstellung in Anlehnung an [ADR98, CHA98, CLE16]

Mit den Verfahren der Statistik werden die relevanten Daten in Bezug auf die jeweilige Aufgabenstellung analysiert. Die entsprechende Aufgabenstellung wird durch das Umfeldverständnis definiert. Für das Suchen und Finden von Datenmustern der potenziell kritischen Lieferanten werden vier statistische Verfahren genutzt:

- Trendberechnung auf Basis des Trend- und Prognosemodells
- Clusteranalyse
- Assoziationsanalyse
- Relevanzprüfung

Die *Trendberechnung auf Basis des Trend- und Prognosemodells* wird als Indikator für das Einleiten präventiver Maßnahmen im Lieferantensteuerkreis genutzt (Kapitel 3.4.2). Somit kann anhand des Verlaufs der Merkmalsausprägungen frühzeitig eine prognostizierte Leistungsverringerung der Lieferanten kenntlich gemacht werden. Für diese Merkmalsausprägungen sind verschiedene Wertebereiche definiert. Für eine weitere Bertachtung der Datenmuster auf Basis der Assoziationsanalyse ist es zielführend, eine Clusteranalyse vorzuschalten.

Die *Clusteranalyse* erweist sich als Möglichkeit, eine bestimmte Anzahl von Daten in Intervalle bzw. Cluster zu gliedern. Es ist für die jeweiligen Merkmale zu prüfen, wie viele Intervalle not-

wendig sind [EST00]. Diese geclusterten Merkmale gehen wiederum als Attribute in die Assoziationsanalyse ein. Damit verringert sich die Anzahl der Attribute, womit die Anzahl der Assoziationsregeln reduziert wird.

Die Einteilung der Daten in Intervalle ist wiederum Basis für die *Assoziationsanalyse*. Somit werden quantitative Assoziationsregeln erstellt. Nach MÜLLER UND LENZ werden oft sehr viele Assoziationsregeln gefunden [MÜL13]. Die Relevanzprüfung in Bezug zu den generierten quantitativen Assoziationsregeln ist dabei ebenfalls ein wichtiger Bestandteil. Dadurch können relevante von weniger relevanten Informationen extrahiert werden. Eine generelle Empfehlung, welche Höhe die einzelnen Interessantheitsmaße haben sollen, ist in der Literatur nicht zu finden. Letztlich müssen diese Maße unternehmensspezifisch definiert werden. Diese Definitionen können über eine Langzeitstudie analysiert werden.

Die generierten, quantitativen Assoziationsregeln bilden die Grundlage für die *Relevanzprüfung*. Über diesen strukturierten Prozess werden die quantitativen Assoziationsregeln auf ihre Interessantheit hin geprüft. In der Literatur wird das Maß der Interessantheit bisher weitestgehend über die Interessantheitsmaße Support, Konfidenz, Lift betrachtet [EST00, HET01, SUM06, BÜH08, GLU08, GAB09, CLE16]. Da jedoch in den bekannten Publikationen nicht beschrieben ist, wie sich diese Interessantheitsmaße idealerweise für die vorliegende Arbeit verhalten sollten, muss zunächst auf das beschriebene Vorgehen (Kapitel 4.3.4) verwiesen werden. Über Langzeitstudien ist dann zukünftig eine Prüfung der Interessantheitsmaße, über die in der Relevanzprüfung identifizierten, quantitativen Assoziationsregeln möglich, um zu untersuchen, wie sich die bekannten Interessantheitsmaße verhalten und ob diese ebenfalls als Indikator innerhalb der Relevanzprüfung quantitativer Assoziationsregeln nutzbar sind.

Das Data Mining kann bei einer Vielzahl unterschiedlicher Problemstellungen unterstützen [SCH16]. Durch die Hypothesenfreiheit des Data Mining werden die Hypothesen durch die statistischen Verfahren aus den Daten semi-automatisch generiert [MÜL13]. Das heißt, es muss zu Beginn keine Theorie aufgestellt werden, die durch die Statistik bewiesen oder widerlegt wird. Aus diesem Grund eignet sich dieser standardisierte Prozess für das Auffinden von Datenmustern, denen potenziell kritische Lieferanten zugeordnet werden können. Diese Zuordnung hängt von der Relevanz und Interessantheit der einzelnen quantitativen Assoziationsregel ab.

Zusammenfassend hat die Datenmodellierung auf Basis der Kombination von statistischen Verfahren folgende Vorteile:

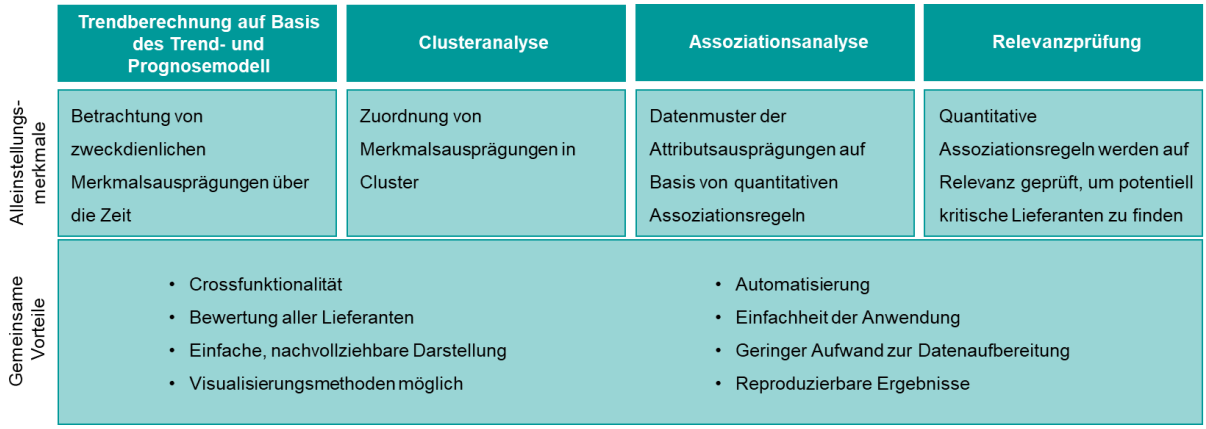


Bild 4-35: Vorteile der angewendeten Kombination von Analyseverfahren
Quelle: Eigene Darstellung in Anlehnung an [LIN05]

Risiken entlang der Supply Chain werden auf dieser Basis frühzeitig identifiziert, um ggf. präventive Maßnahmen durch den Lieferantensteuerkreis definieren und durchführen zu lassen. Die Grundlage der Entscheidung Maßnahmen umzusetzen, bildet ein transparentes und bereichsübergreifendes Wissen, dass durch die Auswertung der leistungsbeschreibenden und nicht-leistungsbeschreibenden Merkmalen über die Lieferanten generiert wird. Die Daten, die in den Data Mining-Prozess einfließen, werden von mehreren Abteilungen eines Unternehmens bereitgestellt. Doch haben diese bereitgestellten Daten eine schlechte Qualität, kann das zu entsprechend fehlerhaften Ergebnissen führen [HEß08]. Es ist somit notwendig, die Daten zu prüfen. Diese in Kapitel 4.6.3 beschriebene Herausforderung der Datenprüfung soll nun im Rahmen der Datenqualität näher erörtert werden.

5 Datenqualität

„Die Digitalisierung verändert alle Bereiche eines Unternehmens“ [FRA16]. Der Umgang mit großen Datenmengen sowie der zugehörigen Technologie stellt dabei eine entscheidende Herausforderung dar. „Der gemeinsame Blick aller Akteure eines Unternehmens als auch einer Supply Chain auf die gleiche Datenmenge mit den gleichen Möglichkeiten zur Analyse verbessert die Kommunikation untereinander und führt zu schnellen Entscheidungen“ [FRA16].

Doch die Entscheidungsgrundlage zur Einleitung von Maßnahmen bei Lieferantendefiziten und drohenden Risiken ist nur so gut, wie die Daten, auf denen das Wissen basiert. Dabei sind die Möglichkeiten der Datenherkunft verschieden (Kapitel 4.6.2). Die Daten aus den verschiedenen Datenquellen sind dabei zunächst unsortiert. Dieses Phänomen der unsortierten Datenmengen wird als Data-Lake (Datensee oder Datenmeer) bezeichnet [STA17, WER17]. Diesen Data-Lake der Big Data gilt es über eine standardisierte Methode für die Wissensgenerierung nutzbar zu machen. Dazu dient die Stufenleiter der Datenintegration (Bild 5-1).

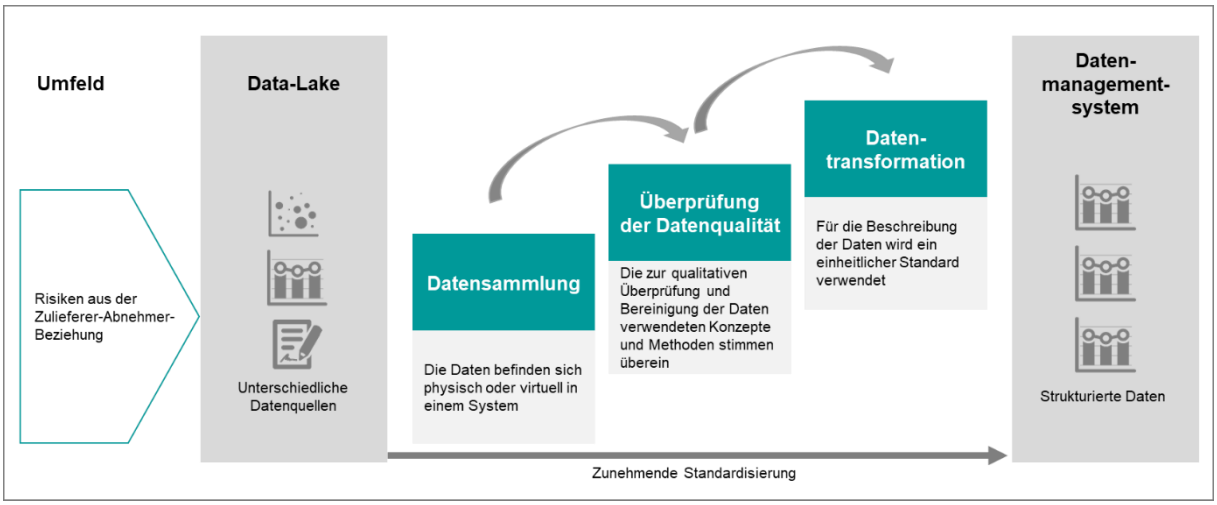


Bild 5-1: Stufenleiter der Datenintegration im Lieferantenmanagement
Quelle: Eigene Darstellung in Anlehnung an [STA17]

Die Risiken, welche im Rahmen der Zulieferer-Abnehmer-Beziehung entstehen, werden mit Hilfe von Kennzahlen überwacht [DUS15]. Daraus resultiert eine Datenbasis aus unternehmensinternen (z.B. bei operativen Risiken) und -externen Datenquellen (z.B. bei Risikoereignissen). Diese gilt es über ein Stufensystem in strukturierte Daten innerhalb eines Datenmanagementsystems zu überführen. Somit werden die Daten für weitere Analysen im Rahmen der Lieferantenbewertung auf Basis des Wissensmanagements nutzbar.

Supplier Risk Monitoring

Die Stufenleiter der Datenintegration gliedert sich in drei Stufen. Diese Stufen werden im Folgenden kurz beschrieben:

Datensammlung

Die Daten werden zentral in einem Datenmanagementsystem gesammelt und gespeichert. Da diese Daten ihren Ursprung in verschiedenen Datenquellen haben, gibt es zunächst keine Einschränkung innerhalb des Datenformats. Die Datenquellen können unternehmensintern (z.B. ERP-System) sowie unternehmensextern (z.B. Internet) sein. Die so entstandene Datenbasis ist zunächst unstrukturiert. Die unstrukturierte Datenbasis ist nun auf ihre Datenqualität hin zu überprüfen.

Überprüfung der Datenqualität

Die Datenqualität wird anhand von verschiedenen Methoden überprüft. Der Schritt der Datenüberprüfung wird als Teil des Wissensmanagements [APE15, CLE16] im Rahmen der vorliegenden Arbeit angewendet. Diese Methoden werden Data Checker genannt. Data Checker analysieren die Datenbasis, wodurch Unregelmäßigkeiten in der Datenqualität erkannt werden (Kapitel 5.2). Dabei gilt die Datenqualität als „Basis für die Wissensgenerierung im gesamten Lieferantenmanagement“ [DUS18].

Datentransformation

Die Daten werden für die weitere Verwendung je nach Analyseverfahren aufbereitet. Dazu muss ein einheitlicher Standard erarbeitet werden. Ein einheitlicher Standard kann beispielsweise eine strukturierte Speicherung der gesammelten Daten zur Lieferantenbasis in einer Datenbank sein. Diese Datenbank dient somit der Wissensbewahrung im Rahmen des Wissensmanagements im TSM (Kapitel 4.1).

Durch diese drei Stufen findet somit eine zunehmende Standardisierung der Datenbasis von unstrukturierten in strukturierte Daten statt. Dieser Prozess wird im Rahmen des Data Mining durchlaufen (Bild 5-2).

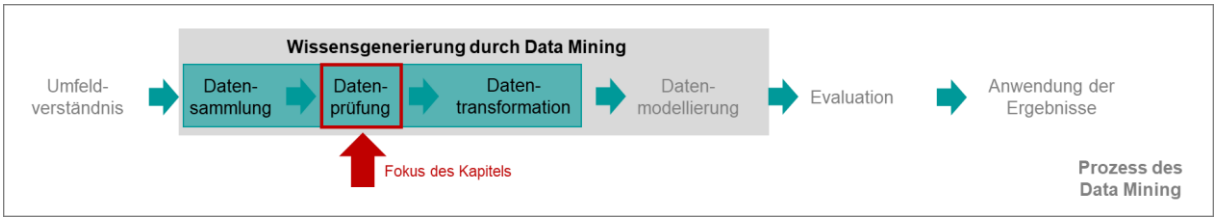


Bild 5-2: Einordnung der Stufenleiter der Datenintegration im Data Mining
Quelle: Eigene Darstellung

Da die Datensammlung und die Datentransformation bereits anhand von Beispielen im Rahmen des Kapitels 4.6 beschrieben worden ist, liegt der Fokus in diesem Kapitel auf dem Prozessschritt der Datenprüfung im Sinne einer hohen Datenqualität. Um die Datenqualität zu verbessern, werden verschiedene Data Checker erörtert (Kapitel 5.2). Damit wird im Rahmen der Aufgabenstellung die Nutzung der Data Checker im Gesamtmodell des Data Mining bzw. TSM (Kapitel 4.6.3) verdeutlicht.

5.1 Ziele und Nutzen einer hohen Datenqualität

Der Wirtschaftswert von Daten für die Unternehmensprozesse wird auf durchschnittlich drei Billionen Dollar pro Jahr über die verschiedenen Branchen geschätzt [MCK13]. Doch die Daten aus den unterschiedlichen Datenquellen haben nicht immer die gewünschte Datenqualität für die Weiterverarbeitung.

Data Mining ist ein automatisierter Prozess. Somit ist es bedeutend, dass die genutzte Datenbasis eine hohe Qualität aufweist [APE15]. Dabei ist die Quantität der vorliegenden Datenbasis entscheidend [FEI14]. Liegt nur eine geringe Datenqualität vor, kann dies zu Fehlinterpretationen der Data Mining-Ergebnisse führen [APE15]. Oftmals verlassen sich Unternehmen auf die Abläufe in ERP-Systemen, ohne dessen Informationsinhalte zu hinterfragen. Werden diese notwendigen Voraussetzungen nicht geschaffen, können Fehlentscheidungen zu einem ineffizienten Ressourceneinsatz bei der Umsetzung von Maßnahmen führen oder bewirken im ungünstigsten Fall sogar das Unterlassen notwendiger Aktivitäten [DUS10c]. Somit kann eine schlechte Datenqualität zu einer falschen Einschätzung der Risikosituation führen.

Durch die hohe Datenvielfalt benötigen die Unternehmen neue Modelle zur Absicherung einer validen Datengrundlage. Die Realität wird oftmals nur unvollständig abgebildet. Die Ursachen schlechter Datenqualität sind in diesem Zusammenhang vielfältig [APE15]. Fehlerquellen im Zieldatenbestand können fehlende Werte oder aber auch Redundanzen sein. Diese fehlerhaften Datensätze sind für eine Weiterverarbeitung im Rahmen einer präventiven Lieferantenbewertung mit Hilfe des Data Mining möglichst frühzeitig herauszufiltern [BEN01].

Eine robuste Qualität der Datenbasis ist für die Analyse relevanter Datenmengen im Rahmen des Data Mining von hoher Bedeutung [DUS15]. Die Daten sollten vor der Analyse auf Fehler, Ausreißer oder Rauschen untersucht und bereinigt werden [WIN11]. Die spezifischen Definitionen des Begriffes der Datenqualität sind stark subjektiv geprägt [APE15]. HELFERT [HEL02] diskutiert dazu spezifische Ansätze in seiner Forschungsarbeit. Eine allgemeine Formulierung finden HEINRICH ET AL. [HEI14]. Dabei wird die Datenqualität als „Gesamtheit der Merkmale von Daten[, die] bezüglich ihrer Eignung, festgelegte und vorausgesetzte Erfordernisse […] erfüllen“ [HEI14] definiert. „Diese Eignung kann sich über die Zeit ändern, wenn sich Bedürfnisse ändern“ [WÜR03]. Diese Erfordernisse, d.h. die Qualitätsmerkmale, müssen festgelegt werden.

Auch die Definitionen von Qualitätsmerkmalen sind in der Literatur vielfältig [HEL02, APE15]. HEINRICH ET AL. [[HEI14] mit Verweis auf [NAU07] und [WAN96]] postulieren beispielsweise Richtigkeit, Vollständigkeit, Genauigkeit, Relevanz und Nutzen. APEL ET AL. [APE15] fügen dazu die Schlüsseleindeutigkeit über den Primärschlüssel sowie die referenzielle Integrität hinzu. SCHENDERA [SCH07] weißt der Datenqualität hingegen unter anderem Missings, Einheitlichkeit sowie Plausibilität zu. HELFERT [HEL02] fasst in seiner Abhandlung weitere ausgewählte Ansätze, welche bis 2001 publiziert worden sind, in Bezug auf die Datenqualität zusammen.

Aus verschiedenen Studien zum Thema Datenqualität entwickelte die DEUTSCHE GESELLSCHAFT FÜR INFORMATIONS- UND DATENQUALITÄT (DGIQ) [DGI07] folgendes Qualitätsmodell:

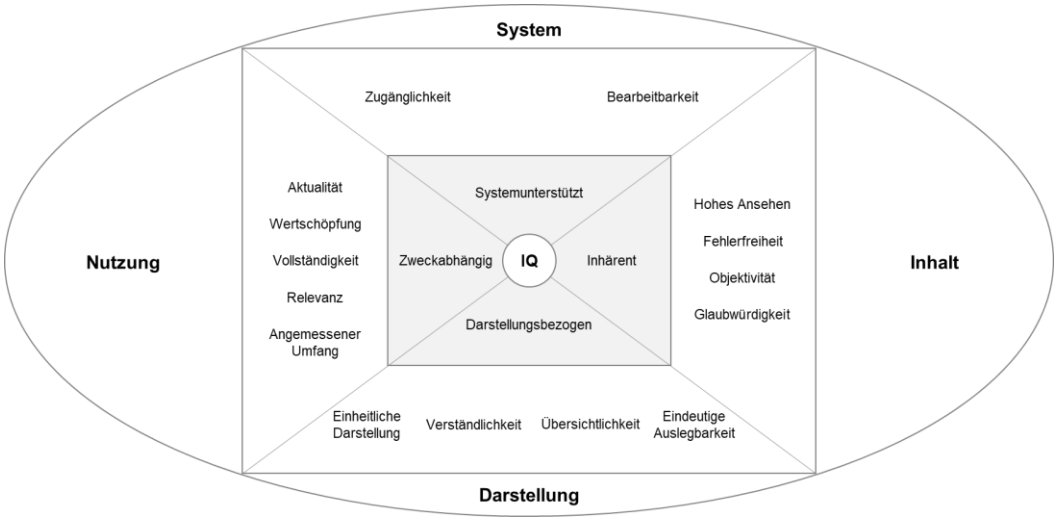


Bild 5-3: Datenqualitätsmerkmale der DGIQ
Quelle: Eigene Darstellung in Anlehnung an [DGI07]

Wie beschrieben, sind die Modelle der Darstellung von Datenqualitätsmerkmalen in der Literatur vielfältig. Drei Kriterien haben sie jedoch gemeinsam [HEL02, DGI07, HEI14, APE15]:

- Vollständigkeit
- Aktualität, Zeitnähe, Zeitbezug
- Relevanz

Durch die fortschreitende Digitalisierung ist es notwendig, die Daten je nach geforderter Aktualität zu empfangen und zu analysieren [FIE16]. Diese sollten auch vollständig sein und über die entsprechende Relevanz verfügen. Die Datensammlung kann dabei durch IT-Systeme automatisiert und unterstützt werden. Doch IT-Systeme prüfen die Daten oft nicht hinreichend auf die Datenqualität [SCH07]. Sind die spezifischen Datenqualitätsmerkmale, je nach Anwendung, nicht erfüllt, wird von einer schlechten Datenqualität gesprochen. APEL ET AL. [APE15] haben dazu die möglichen Ursachen einer schlechten Datenqualität zusammengetragen. Unterteilt werden diese in sechs Hauptkategorien (Bild 5-4).

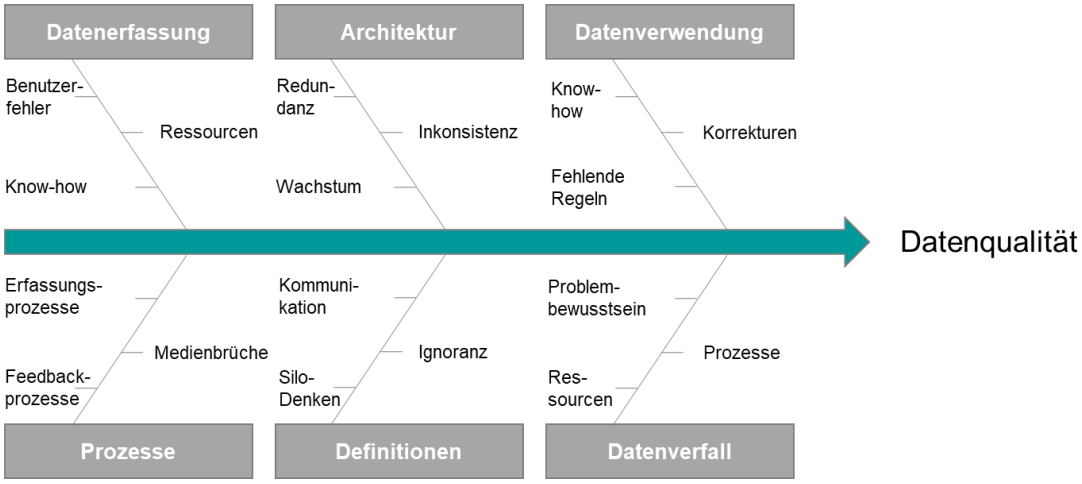


Bild 5-4: Ursachen schlechter Datenqualität
Quelle: Eigene Darstellung in Anlehnung an [APE15]

Diese Ursachen können teilweise frühzeitig verhindert werden. Beispielsweise können die Prozesse zur Datensammlung so gestaltet werden, dass es keine Systembrüche gibt. Manuelle Eingabefehler werden somit ausgeschlossen. Dies kann durch Schnittstellen zwischen den verschiedenen Medien oder Systemen gewährleistet werden.

Weißt die Datenbasis eine schlechte Datenqualität auf, kann dies verschiedene Konsequenzen haben. Diese Konsequenzen einer schlechten Datenqualität beschreibt SCHENDERA [SCH07] wie folgt:

- „Jede Abweichung von einer perfekten Datenqualität ist immer eine suboptimale Datenqualität."
- „Eine suboptimale Datenqualität ist dabei immer mittels der vorgebrachten subjektiven Gründe, Kriterien oder Ursachen seitens der Anwender zu erklären bzw. zu verantworten."
- „Eine (sub)optimale Datenqualität ist kein Selbstzweck, sondern eine Eigenschaft mit Folgen."

Um diese Konsequenzen einer schlechten Datenqualität zu verhindern, ist es notwendig, die Datenqualität sicherzustellen. Wenn frühzeitige Maßnahmen zur Datenqualitätssicherung nicht ausreichen, muss ein Prozess zur Datenprüfung (Kapitel 4.6.3) und -bereinigung definiert werden. Die spezifische Strategie zur Bereinigung der Datenbasis ist je nach Anwendung verschieden. Allgemein kann jedoch der Prozess des Data Profiling und des Data Cleaning zur Sicherung der Datenqualität festgehalten werden [GOM06, APE15].

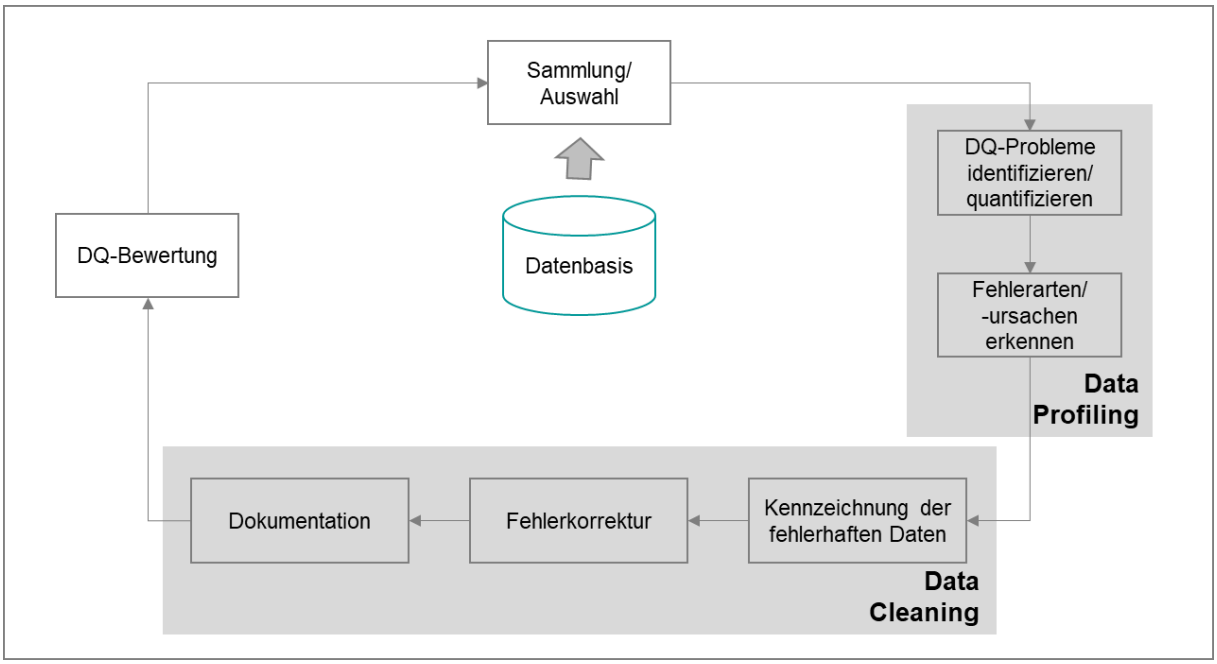


Bild 5-5: Data Profiling und Data Cleaning Prozess
Quelle: Eigene Darstellung in Anlehnung an [GOM06]

Zur Bereinigung der Daten und somit zur Sicherung der Datenqualität werden zunächst die zu verwendenden Daten aus der Datenbasis ausgewählt. Danach beginnt der Prozess des *Data Profiling*. Wird nur dieser Prozess separiert, gliedert er sich nach APEL ET AL. [APE15] in folgende Schritte:

- *Schritt 1: Integration der Daten*
  Sammlung und Auswahl der relevanten Daten, die für den Data Profiling-Prozess genutzt werden sollen.
- *Schritt 2: Analyse der integrierten Daten*
  Fehlerarten und -ursachen werden durch verschiedene konzeptionelle, formale, statistische und logische Analyseverfahren erkannt (Kapitel 5.2).
- *Schritt 3: Ergebnisdarstellung*
  Die Ergebnisse, die Fehlerarten und -ursachen, werden anhand der Analyse erkannt und aufbereitet.
- Schritt 4: *Bewertung der Ergebnisse*
  Die Ergebnisse werden durch ein Data Profiling-Team bewertet.

Durch den reinen Prozess des Data Profiling werden die Daten mit einer niedrigen Datenqualität jedoch noch nicht bereinigt. Dafür ist der Prozess des *Data Cleaning* zuständig. Fehlerhafte Daten werden zunächst gekennzeichnet. Die gekennzeichneten Daten werden daraufhin korrigiert und die Ergebnisse dokumentiert. Unter dem Prozess der Fehlerkorrektur verstehen APEL ET AL. [APE15] die Bereinigung der fehlerhaften Daten. Die Bereinigung der fehlerhaften Daten findet je nach Fehler beispielsweise durch Zurückhaltung, Abweisung oder Bereinigung der Daten statt (Kapitel 5.3). Die Gesamtergebnisse aus Data Profiling und Data Cleaning werden wiederum bewertet. Die korrigierten Daten gehen dann in die Datenbasis ein oder werden für weitere Analysen im Rahmen des Data Mining genutzt.

Wie bereits beschrieben, sind die Anforderungen an die geforderte Datenqualität je nach Anwender und Ziel verschieden. „Eine allgemeine Festlegung, was eine gute Datenqualität im Rahmen von Business-Intelligence-Lösungen ausmacht, gibt es nicht“ [APE15]. Somit ist die geforderte Datenqualität von der Aufgabenstellung und dem Umfeldverständnis (Kapitel 4.5.1), abhängig. Innerhalb der vorliegenden Arbeit wird mit Data Mining-Verfahren (Trenderechnung auf Basis des Trend- und Prognosemodells, Clustering und Assoziationsanalyse) gearbeitet, bei denen spezifische Daten genutzt werden. Da es sich bei diesen Daten um Smart Data (Kapitel 4.5.4) und damit um relevante Daten zur Suche von Datenmustern handelt, müssen diese einer Datenqualitätsprüfung unterzogen werden. Die folgenden Kapitel zeigen, wie diese Daten auf verschiedene Qualitätsmerkmale überprüft werden können. Dabei werden Data Checker verwendet, welche die Daten auf Konzeption, Plausibilität, Validität und Verfügbarkeit prüfen.

5.2 Data Profiling durch Data Checker

Daten sind die Basis zur Generierung von Wissen. Dieses Wissen dient als Grundlage und Voraussetzung zur Steuerung von Unternehmensprozessen und ist somit unverzichtbar für belastbare Managemententscheidungen. Doch „Daten von niedriger Qualität sind […] allgegenwärtig“ [NAU07]. Unzählige unterschiedliche IT-Systeme [HAß17] und das Silodenken der Fachbereiche verursachen eine Datenflut, die unternehmensweit nicht einheitlich ist [SAI13]. Somit bleibt bislang „wertvolles Potenzial, um die Qualität und Konsistenz von Daten zu verbessern […] ungenutzt“ [HAß17]. Nach einer Umfrage des BUNDESVERBAND MATERIALWIRTSCHAFT, EINKAUF UND LOGISTIK (BME) nutzen über 30 Prozent der Studienteilnehmer Excel-Anwendungen zur Wissensgenerierung im Bereich Supply Chain Management [HAß17]. Diese Anwendungen überprüfen jedoch weder die Datenqualität vor einer Datenanalyse, noch ist die zunehmende Datenvielfalt manuell zu bewältigen [HAß16].

Eine hohe Datenqualität ist für die Analyseverfahren des Data Mining in der vorliegenden Arbeit enorm wichtig (Kapitel 4). Zur Überprüfung der Datenqualität mittels Data Profiling dienen verschiedene Data Checker mit Fokus auf Konzeption, Verfügbarkeit, Validität und Plausibilität. Diese weisen eine unterschiedliche Komplexität auf. Die geringste Komplexität weißt der Konzeptionelle Checker auf. Die einmalige Analyse bezieht sich auf die Berechnung einer Kennzahl. Erstmals innerhalb der Komplexitätssteigerung findet beim Formalen Data Checker eine regelmäßige Überprüfung der Datenqualität statt. Zusätzlich zur formalen Überprüfung bezieht sich der Statistischen Data Checker auf die Analyse von Daten innerhalb eines Datensatzes, um beispielsweise Häufigkeiten oder statistische Abweichungen zu erkennen. Dahingegen ist die Komplexität beim Logischen Data Checker am höchsten. Beim Logischen Data Checker werden IT-Systeme, Datensätze sowie auch KPIs miteinander vernetzt (Bild 5-6). Diese Vernetzung über Schnittstellen kann zusätzlich inhaltlich und technisch eine beliebig hohe Komplexität annehmen [SEI06].

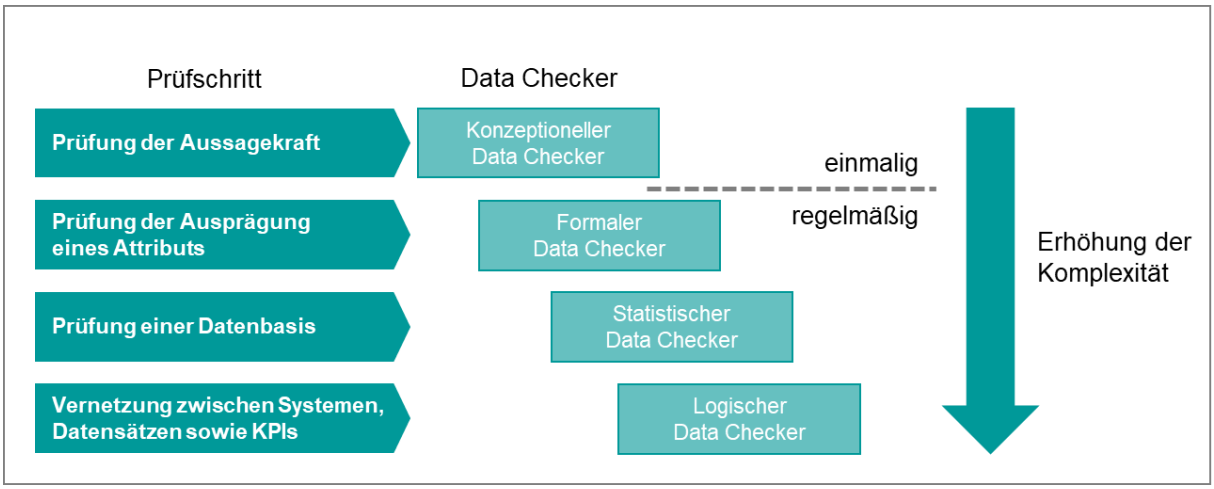


Bild 5-6: Steigerung der Komplexität bei der Anwendung der Data Checker
Quelle: Eigene Darstellung

Ist durch die Data Checker eine schlechte Datenqualität ermittelt worden, muss diese verbessert werden. Dabei unterstützen die Prozesse des Data Cleaning mit den Prozessen Zurückhaltung, Abweisung und Bereinigung. Die Verfahren und Prozesse der Data Profiling und des Data Cleaning sind in diesem Kapitel dargestellt worden.

5.2.1 Konzeptioneller Data Checker

Kennzahlen sind im Fall der vorliegenden Arbeit Steuerungsgrößen, um Risiken im externen Wertschöpfungsnetzwerk zu beherrschen, zu minimieren oder zu vermeiden. Die Kennzahlen generieren sich aus den Risiken innerhalb der Zusammenarbeit zwischen Zulieferer und Abnehmer (Kapitel 3.3.5). Das Ziel im Umgang mit Kennzahlen ist „das Planen und Steuern der unternehmerischen Tätigkeit mit Hilfe betriebswirtschaftlicher Daten und Analysen“ [JUN14]. Doch diese Kennzahlen müssen in ihrer Konzeption und Berechnung so robust sein, dass eine bereichsübergreifend einheitliche Aussage zum potenziellen Risiko gewährleistet ist [DUS16b]. Die Aufgaben einer Kennzahl sind dabei folgende [REI06, JUN14]:

- Regelmäßige Kontrolle der Unternehmensstrategie und Erreichung der Unternehmensziele
- Abstimmung von fachbereichsübergreifenden Planungs- und Steuerungsprozessen
- Gewährleistung einer hohen Reaktionsgeschwindigkeit bei veränderten Anforderungen und Entscheidung über frühzeitige Maßnahmen
- Generierung und Verteilung von bedarfsgerechtem Wissen

In der Praxis werden jedoch immer wieder Kennzahlen eingesetzt, die nicht für die Kontrolle der Unternehmensziele geeignet sind. Durch den Konzeptionellen Data Checker werden kennzahlenspezifisch diese ungeeigneten Kennzahlen analysiert und erkannt. Bild 5-7 visualisiert ein Fallbeispiel der Kennzahl „Reklamationsquote“ bei einem mittelständischen Unternehmen im Automotive-Bereich.

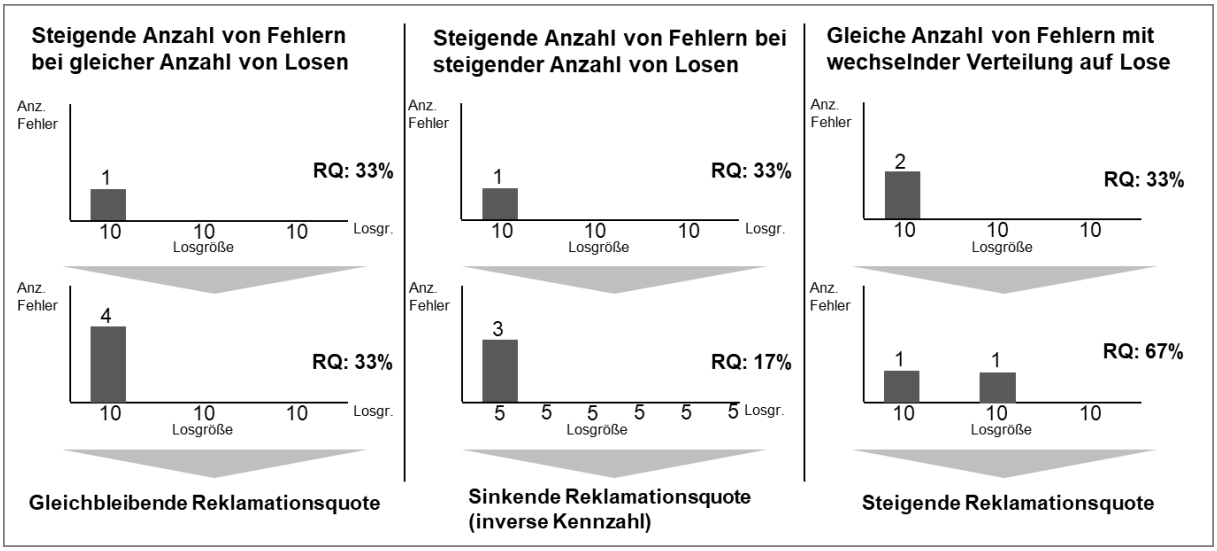


Bild 5-7: Konzeptioneller Data Checker am Fallbeispiel der Kennzahl „Reklamationsquote“
Quelle: Eigene Darstellung in Anlehnung an [DUS18]

In dem vorliegenden Fall wird die „Reklamationsquote“ als Verhältniskennzahl berechnet. Dabei gilt:

$$Reklamationsquote = \frac{Anzahl\ der\ fehlerhaften\ Losen}{Gesamtanzahl\ der\ gelieferten\ Lose} \cdot 100 \quad (15)$$

Durch diese Berechnung sollen Zusammenhänge zwischen den gelieferten Losen mit fehlerhaften Teilen und der Gesamtanzahl der Anlieferlose in einem bestimmten Zeitraum in Bezug zu einem Lieferanten beschrieben werden. Bei der Ergebnisinterpretation der Lieferantenleistung können unter anderem beispielsweise drei Fälle auftreten:

1. *Gleichbleibende Reklamationsquote durch die Steigerung der Fehleranzahl bei einem Los*

In diesem Fall erhöht sich bei einem Los die Anzahl der Fehler. Dennoch verändert sich durch die Art der Berechnung der Kennzahl RQ der Wert nicht. Somit suggeriert die RQ, dass keine Veränderung stattgefunden hat.

2. *Sinkende Reklamationsquote durch die Steigerung der Los- und Fehleranzahl*

Ein weiteres Fallbeispiel entsteht, wenn sich die Anzahl der Lose erhöht, wobei sich die Losgröße verringert. Erhöht sich dann bei einem Los die Anzahl der Fehler, sinkt die RQ. Die Kennzahl suggeriert eine positive Entwicklung, obwohl sich die Reklamationen erhöht haben.

3. *Steigende Reklamationsquote bei gleicher Anzahl von Fehlern in Bezug auf unterschiedliche Lose*

Die Anzahl der Lose sowie die Losgröße und die Anzahl der Fehler bleiben in diesem Fall gleich. Änderungen finden aber in der Verteilung der Fehler in Bezug auf die Lose statt. Werden die Fehler von einem Los auf unterschiedliche Lose verteilt, steigt die RQ.

Durch die drei Beispiele werden Zustände suggeriert, die zwar der tatsächlichen Lieferantenleistung entsprechen, dennoch ist die Kennzahl durch die Zusammensetzung nicht für eine Weiterverwendung im zur Trendberechnung im Trend- und Prognosemodell geeignet. Diese beispielhaft beschriebenen Zustände kommen lediglich durch die zufällige Verteilung der fehlerhaften Ware auf die verschiedenen Lose zustande. In Bezug auf das Beispiel der RQ ist somit eine Generierung von Wissen „in konzentrierter, zusammengefasster Form über betriebliche Sachverhalte“ [JUN14] unter diesen Umständen nicht möglich. Somit ist die RQ keine zielführende Kennzahl, auf deren Basis wichtige Managemententscheidungen getroffen werden sollten. Vielmehr muss diese Kennzahl gegen eine nicht inverse Steuerungsgröße ersetzt werden, welche die allgemein beschriebenen Aufgaben einer Kennzahl erfüllt.

Bestehende und neue Kennzahlen werden durch die Überprüfung unterschiedlicher Fallbeispiele durch den konzeptionellen Data Checker auf ihre Aussagekraft hin überprüft. Dabei wird auch die Berechnung der jeweiligen Kennzahl erörtert. Erfüllt eine Kennzahl die Anforderungen, kann sie für weitere Analysen im Rahmen des Data Mining genutzt werden. Werden die Anforderungen nicht erfüllt, muss sie durch eine andere Steuerungsgröße ersetzt werden.

Nach der Betrachtung des konzeptionellen Data Checkers werden im weiteren Verlauf der Arbeit nun die Data Checker betrachtet, die im Data Profiling regelmäßig Anwendung finden. Begonnen wird dabei mit dem Formalen Data Checker.

5.2.2 Formaler Data Checker

Eine formale Kontrolle erlaubt die Bereinigung von Inhalten, die nicht dem gewünschten Datenformat entsprechen [APE15] und somit eine schlechte Datenqualität aufweisen. Das Ziel eines formalen Data Checkers ist, möglichst fehlerhafte Formate zu bereinigen, damit die Daten für weitere Analysen genutzt werden können. Formale Datenregeln werden vor allem bei der Überprüfung einzelner Merkmale angewendet. Dabei können Merkmale sowie die Merkmalsausprägungen durch verschiedene Verfahren analysiert werden. Einen Überblick der Verfahren sowie der entsprechenden Zielstellung gibt Tabelle 5-1. Diese dargestellten Verfahren werden nachfolgend kurz beschrieben.

Tabelle 5-1: Überblick formaler Analyseverfahren
Quelle: [SCH07, APE15]

Analyseverfahren	Ziel
Datentypanalyse	• Überprüfung des Datenformates • Überprüfung der Länge der Merkmalsausprägung • Überprüfung der Abweichung zwischen dokumentierter und vorhandener Genauigkeit
NULL-Wert-Analyse	• Finden fehlender Werte

Datentypanalyse

Eine Überprüfung des Datenformates findet bei der Datentypanalyse statt. Bei dieser Analyse werden folgende Eigenschaften untersucht:

- Zulässige Datenformate (z.B. ENDDATUM ist nicht 99.99.9999 für einen offenen Zeitraum)
- Datentyp der Merkmale (z.B. NUMBER oder String)
- Länge und Genauigkeit der Merkmalsausprägungen (z.B. die Stellen hinter dem Komma oder Rundungsfehler)

Zusätzlich kann analysiert werden, ob die Merkmalsausprägungen im vorgegebenen Wertebereich liegen. Eine Überprüfung nach statistischen Methoden mittels einer detaillierten Wertebereichsanalyse findet jedoch nicht statt. Es wird lediglich die Wertebereichsbedingung betrachtet.

NULL-Wert-Analyse

Fehlt eine Merkmalsausprägung kann dies über die NULL-Wert-Analyse erkannt werden. Dabei ist jedoch zu unterscheiden, ob die Merkmalsausprägung tatsächlich fehlt. Dies kann über eine formale Analyse untersucht werden. Werden jedoch für die fehlenden Werte Ersatzwerte, wie die „0“ oder ein Leerzeichen genutzt, können diese fehlenden Merkmalsausprägungen über eine Wertebereichsanalyse im Rahmen der Statistik identifiziert werden [APE15] (siehe Kapitel 5.2.3).

HELFERT [HEL02] fasst in seiner Publikation verschiedene Beispiele einer formalen Überprüfung der Wertebereichs- und Merkmalsbedingungen in Bezug zur Datenbasis zusammen. Nachfolgend sind diese Beispiele von Helfert in Bezug zu einer Lieferanten-Abnehmer-Beziehung gesetzt worden (Tabelle 5-2).

Tabelle 5-2: Beispiele zur Prüfung der formalen Datenqualität
Quelle: Eigene Darstellung in Anlehnung an *HELFERT* [HEL02]

Ansatz zur Datenqualitätsprüfung	Beispiel in Bezug auf die Lieferanten-Abnehmer-Beziehung
Merkmalsausprägung entspricht dem festgelegten Datentyp/Datenformat	`Lieferdatum IS Date`
Merkmalsausprägung befindet sich in den angegebenen Wertebereichen	`´01.01.2018´ ≤ Lieferdatum ≤ Datum des heutigen Tages`
Für Pflichtfelder sind keine NULL-Werte eingetragen	`Lieferdatum NOT NULL`

Diese Beispiele verdeutlichen die Anwendung des formalen Checkers auf eine Datenbasis. HELFERT [HEL02] beschreibt, dass damit das Qualitätsmerkmal der Glaubwürdigkeit der Daten verbessert wird.

Generell werden formale Prüfungen meist vor einer weiteren Analyse der Daten durchgeführt. Die formale Datenqualität der Datenbasis lässt sich zusammenfassend auf folgenden Wegen prüfen:

- Durch die Anzahl der Merkmalsausprägungen innerhalb eines Merkmals, die für weitere Analysen verwendet werden
- Durch die Anzahl der Merkmalsausprägungen, die einem Objekt zugehörig sind

Zusätzlich nennen APEL ET AL. [APE15] und SCHENDERA [SCH07] die Möglichkeit die Datenbasis über statistische Verfahren, z.B. auf fehlende Merkmalsausprägungen hin zu überprüfen. Diese Betrachtung ist Gegenstand des folgenden Kapitels.

5.2.3 Statistischer Data Checker

Die Statistik ermöglicht eine Datenanalyse in Bezug auf die Validität. Die Gesamtheit der statistischen Verfahren wird in der vorliegenden Arbeit als Statistischer Data Checker bezeichnet. Das Ziel des Statistischen Data Checkers ist dabei Unregelmäßigkeiten bei der Häufigkeit oder auch bei der statistischen Verteilung von Merkmalsausprägungen über die gesamte Datenbasis zu erkennen. Die Datenbasis wird somit auf ihre Validität untersucht. Tabelle 5-3 gibt einen Überblick über statistische Analyseverfahren, auf deren Basis die Datenqualität erhöht werden kann. Diese dargestellten Verfahren werden nachfolgend kurz beschrieben.

Tabelle 5-3: Überblick statistischer Analyseverfahren
Quelle: Eigene Darstellung

Analyseverfahren	Ziel
Wertebereichsanalyse	• Aussage über die statistische Verteilung der Merkmale und ihrer Ausprägungen
Musteranalyse	• Suche nach formalen Mustern in den Merkmalsprägungen • Erkennen von Duplikaten
Domänenanalyse	• Identifikation unzulässiger Werte innerhalb der Merkmalsprägungen

Wertebereichsanalyse

Die Wertebereichsanalyse ermittelt folgende Werte bzw. Informationen von Ausprägungen spezifischer Merkmale über die gesamte Datenbasis:

- Minimaler Wert
- Maximaler Wert
- Durchschnittlicher Wert
- Art der statistischen Verteilung
- Standardabweichung

Dabei wird geprüft, ob die Ergebnisse mit den Erwartungen übereinstimmen. Diese Prüfung wird mit Hilfe von Experten durchgeführt. Im vorliegenden Beispiel zu einer Wertebereichsanalyse ist die Kennzahl ppm in einem Monat über die gesamte Datenbasis aller Lieferanten analysiert worden (Bild 5-8).

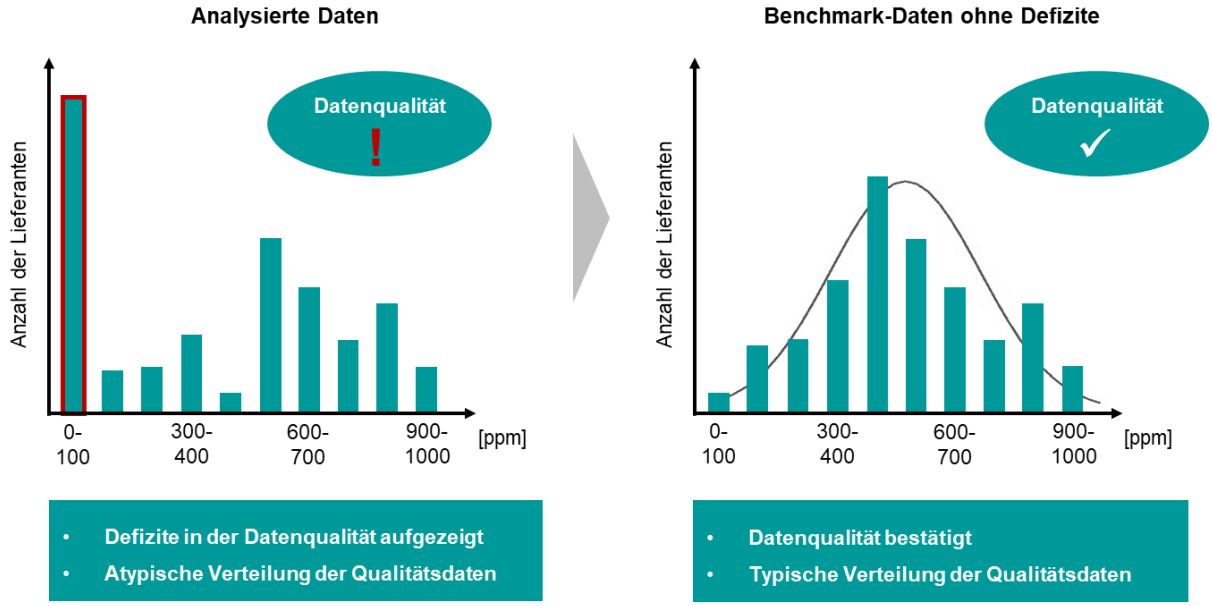


Bild 5-8: statistische Verteilung der Kennzahl ppm pro Lieferant innerhalb eines Monats
Quelle: [DUS18]

Es ist auffällig, dass keine Normalverteilung der ppm-Kennzahlenwerte im linken Teil des Bild 5-8 als IST-Zustand vorliegt, was zu erwarten gewesen wäre [DUS15]. Das erwartete Zielbild mit einer annähernden Normalverteilung ist rechts im Bild 5-8 als SOLL-Zustand dargestellt. Im Fall einer Normalverteilung hätte es eine Häufung zwischen null und 1 Mio ppm als definierten Wertebereich geben müssen. Auffällig viele Werte sind im IST-Zustand mit null angegeben, was auf einen menschlichen oder auch systematischen Fehler schließen lässt. Menschliche Fehler können beispielsweise das Nicht-Hinterlegen der entsprechenden Fehlerquote in der Datenbank sein. Durch die Lieferung wäre zwar ein ppm-Wert bei dem entsprechenden Lieferanten hinterlegt worden, dieser bleibt aber durch die fehlende qualitative Bewertung bei null. Als systematische Fehler werden hingegen reproduzierbare und dadurch schwer erkennbare Fehler bezeichnet [DIN1319-1]. „Systematische Fehler können nicht durch eine bessere statistische Genauigkeit reduziert werden“ [BLO98]. Eine Ursachenanalyse ist bei dieser Fehlerart somit unerlässlich, um diese Fehler abzustellen. Beispielsweise muss ein Datensatz, der einem systematischen Fehler unterliegt, erörtert werden und Maßnahmen zur Fehlervermeidung sollten festgelegt werden [MAI09]. Allgemein gibt es keine standardisierte Vorgehensweise für einen systematischen Fehler [BLO98].

Musteranalyse

Nach statistischen Datenmustern wird die Datenbasis bei der Musteranalyse untersucht. Dabei wird die Datenbasis mit standardisierten Werten verglichen. Die Ergebnisse der Musteranalyse in Bezug zur vorliegenden Datenbasis sind folgende:

- Erkennen der häufigsten Zeichenmuster
- Statistische Verteilung der einzelnen Zeichenmuster
- Errechnung der Standardabweichungen

Werden in ihrem Format standardisierte Merkmale untersucht, können auch schnell Duplikate erkannt werden. Beispielsweise hat die internationale Kontakttelefonnummer eines Lieferanten ein definiertes Datenformat. Dieses kann jedoch variieren (Tabelle 5-4):

Tabelle 5-4: Überblick statistischer Analyseverfahren
Quelle: Eigene Darstellung in Anlehnung an [APE15]

Kontakttelefonnummer eines Lieferanten	Standardisiertes Datenformat der Kontakttelefonnummer eines Lieferanten
(01234) 56789	+49 1234 56789
0049 (0)1234/56789	+49 1234 56789
+49123456789	+49 1234 56789

Wird die Kontakttelefonnummer nun in ein standardisiertes Format überführt, können doppelte Telefonnummern erkannt werden.

Domänenanalyse

Als Domänen werden häufig Merkmale eines Datensatzes bezeichnet. Mit Hilfe der Domänenanalyse werden unzulässige Merkmalsausprägungen abgegrenzt. Dabei werden jedoch nur mehrfach (mindestens zwei Mal) vorkommende Ausprägungen beachtet. Unzulässige Ausprägungen, z.B. Duplikate, werden abgewiesen [APE15].

Zusammenfassend sind nach HELFERT und APEL ET AL. [HEL02, APE15] verschiedene Beispiele einer statistischen Datenanalyse in Bezug zur Datenbasis zusammengetragen (Tabelle 5-5). Diese Beispiele sind wieder in Bezug zu einer Lieferanten-Abnehmer-Beziehung gesetzt worden.

Tabelle 5-5: Beispiele zur Prüfung der statistischen Datenqualität
Quelle: Eigene Darstellung in Anlehnung an *HELFERT und APEL ET AL.* [HEL02, APE15]

Ansatz zur Datenqualitätsprüfung	Beispiel in Bezug auf die Lieferanten-Abnehmer-Beziehung
Merkmalsausprägungen entsprechen einer erwarteten Verteilung	`ppm-Wert über Anzahl aller Lieferanten IS Normalverteilung` `99% aller Lieferanten NOT ppm-Wert = 0`
Merkmalsausprägungen hat ein bestimmtes Muster des Datenformates	`Lieferdatum IS tt.mm.jjjj`
Merkmalsausprägungen ist zulässig	`Anrede des Lieferantenkontaktes IS Mann OR Frau`

Diese Beispiele verdeutlichen die Anwendung des Statistischen Checkers auf eine Datenbasis. HELFERT [HEL02] beschreibt, dass damit, wie beim Formalen Checker das Qualitätsmerk-

mal der Glaubwürdigkeit der Daten verbessert wird. Beim Erkennen der statistischen Datenfehler wird häufig IT-Unterstützung genutzt. Beispielsweise können Statistikprogramme, wie SPSS [SCH07], oder auch Programme zur Datenanalyse, wie RapidMiner [KOT15], eingesetzt werden. Dabei werden einzelne Dateien mit einer entsprechenden Datenbasis ausgewertet. Eine Vernetzung der unterschiedlichen Merkmalsausprägungen findet bei dem Statistischen Data Checker nicht statt. Für eben diese Vernetzung eignet sich der Logische Data Checker.

5.2.4 Logischer Data Checker

Die Datenqualität ist in den IT-Systemen häufig unzureichend [DUS18]. Laut HELFERT [HEL02] können inkonsistente Daten zwischen verschiedenen Systemen ein möglicher Grund dafür sein. Mit dem Logischen Data Checker wird die Datenbasis zusätzlich zu den bisherigen Verfahren des Data Profiling auf Plausibilität überprüft. Tabelle 5-6 gibt einen Überblick in Bezug auf alternative Analyseverfahren des Logischen Checkers. Diese dargestellten Verfahren werden nachfolgend kurz beschrieben.

Tabelle 5-6: Überblick logischer Analyseverfahren
Quelle: [HEL02, APE15]

Analyseverfahren	Ziel
Eindeutigkeitsanalyse	• Nutzung von eindeutigen Merkmalen zur Vernetzung unterschiedlicher Tabellen oder Systeme
Tabellenanalyse	• Abhängigkeiten zwischen Tabellen auf Basis von Referenzen • Ermittlung von Kardinalitäten

Eindeutigkeitsanalyse

Das Ziel der Eindeutigkeitsanalyse ist es, zwischen verschiedenen Dateien, z.B. Tabellen (je Tabelle ein Datensatz), eine Verbindung über bestimmte Merkmale herzustellen. Diese Merkmale, über die diese Verbindung hergestellt wird, werden Schlüsselattribute genannt. Ein Schlüsselattribut ist ein spezielles Merkmal, was immer eindeutig identifizierbar ist [ELM11]. Durch diese Vernetzung der Dateien erweitert sich die Datenbasis. In Bezug auf die vorliegende Arbeit, kann dieses Schlüsselattribut beispielsweise durch die Lieferantennummer repräsentiert werden. Die Lieferantennummer wird einmalig vergeben und ist in allen Datenquellen gleich. Somit können zugehörige Daten zu derselben Lieferantennummer aus verschiedenen Datenquellen zusammengetragen werden.

Im folgenden Beispiel wird demnach in verschiedenen Tabellen auf Schlüsselattribute referenziert. Eine Referenz ist im vorliegenden Fall ein Verweis auf eine Zeichenfolge [DAN04] des Merkmals. Werden darüber hinaus zwei Tabellen über das Schlüsselattribut miteinander vernetzt, entsteht ein neuer Datensatz. Dies ist, wie in Bild 5-9 visualisiert, anhand des Programms RapidMiner durchgeführt worden.

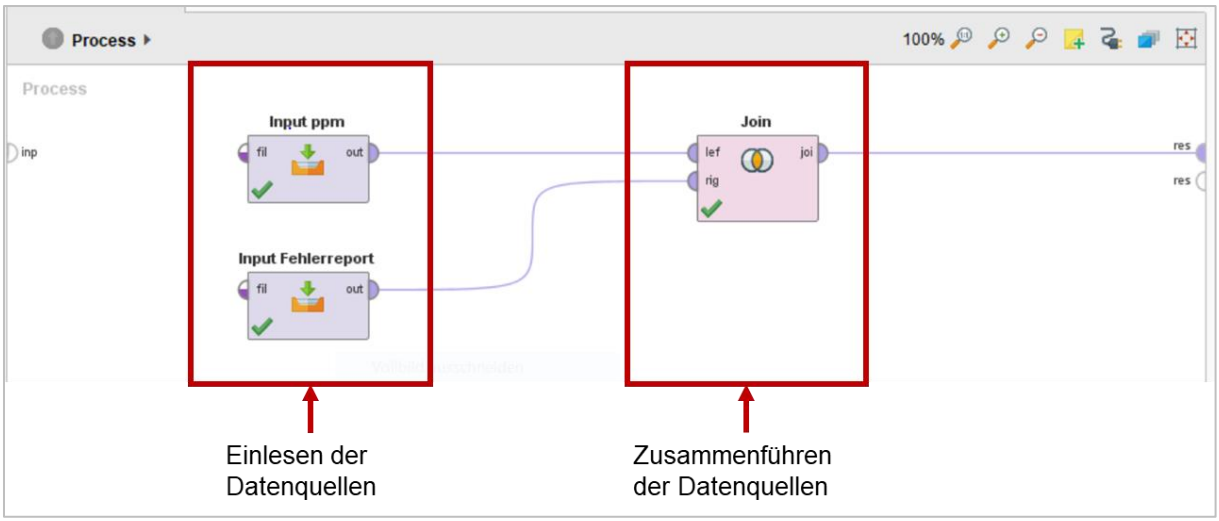


Bild 5-9: Vernetzung von zwei Tabellen mit RapidMiner
Quelle: Eigene Darstellung

Im vorliegenden Fall stellt Datenquelle 1 im Bild 5-9 eine Datenquelle mit ppm-Kennzahlwerten dar. Datenquelle 2 enthält Daten über die Anzahl von Fehlerreports, die in Folge fehlerhaft angelieferter Teile zu erstellen sind. Beide Tabellen enthalten Daten zu denselben Lieferanten. Die Kennzahldaten der ppm und die Anzahl von Fehlerreports sind über den gleichen Zeitraum erhoben worden.

Bild 5-10 stellt das Ergebnis der Tabellenvernetzung dar. Zu erkennen ist einerseits, dass zu bestimmten Lieferanten Fehlerreports zugeordnet werden können, obwohl die ppm-Kennzahl mit null ausgewiesen wird. Andererseits gibt es Werte der ppm-Kennzahl größer null, ohne dass Fehlerreports hinterlegt worden sind. Diese beschriebenen Analyseergebnisse sind unplausibel, da die Fehlerreports mit der ppm-Kennzahl korrelieren sollten. Die Korrelation aus ppm und Fehlerreports ergibt sich dabei aus der Berechnung der Kennzahl ppm:

$$ppm = \frac{x\ defekte\ Einheiten}{y\ geprüfte\ Einheiten} \cdot 1.000.000 \qquad (16)$$

Zu jeder defekten Einheit x wird ein Fehlerreport erstellt. Somit liegt zwischen einer defekten Einheit x und der Anzahl eines Fehlerreports eine positive Korrelation vor. Schlussfolgernd liegt auf dieser Basis ebenfalls eine positive Korrelation zwischen der Kennzahl ppm und der Anzahl der Fehlerreports vor.

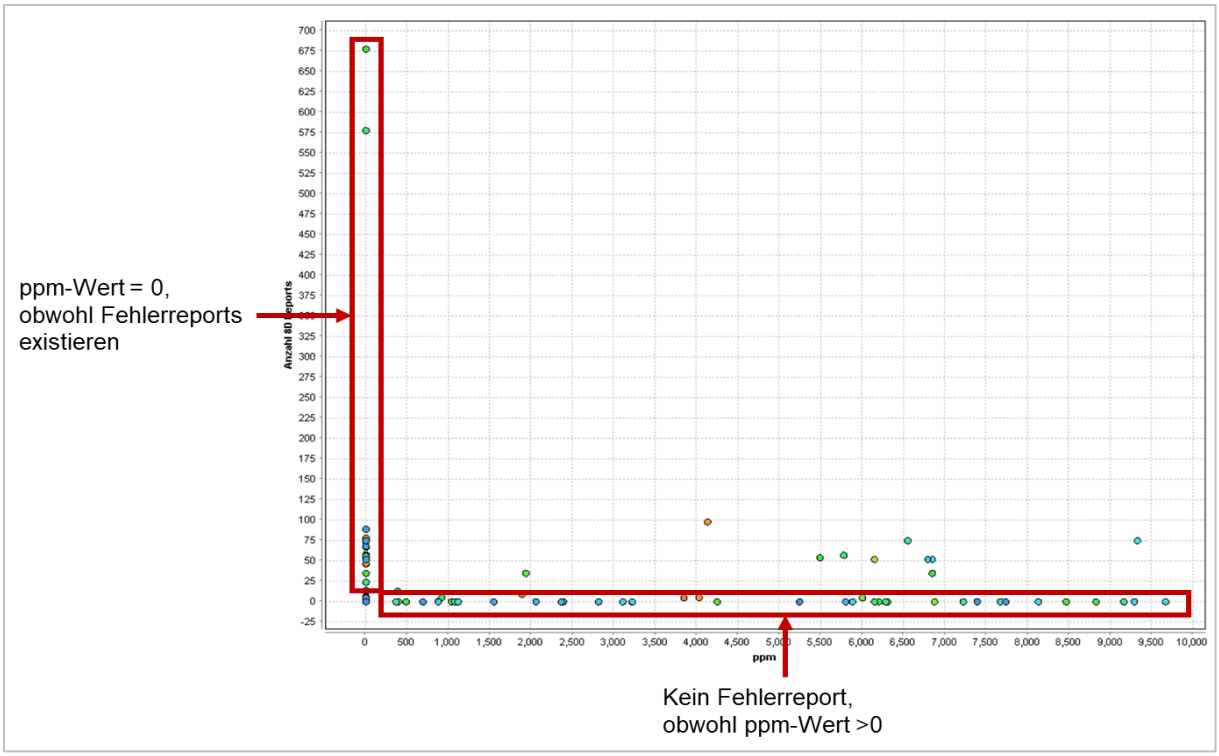


Bild 5-10: Ergebnis des logischen Data Checkers
Quelle: Eigene Darstellung

Das Ergebnis der Datenanalyse mit Hilfe des Logischen Data Checkers lässt im Rahmen der vorliegenden Datenbasis keinen Rückschluss auf die Ursache dieser schlechten Datenqualität zu. Eine weitere Untersuchung der Ursache dieser Datenqualität ist nur in Verbindung mit einer Prozess- und IT-Systemanalyse möglich. Im Rahmen der vorliegenden Arbeit fehlen jedoch die Informationen zur Durchführung dieser Untersuchungen. Folglich werden im Rahmen dieser Arbeit Annahmen in Bezug auf die Ursache der schlechten Datenqualität getroffen. Diese Annahmen sind in den Varianten eins bis drei formuliert:

Variante 1: Die Systeme, in denen die Daten enthalten sind, haben keine gemeinsame IT-Schnittstelle und somit ist kein automatisiertes Matching, also keine Datenqualitätskontrolle, möglich.

Variante 2: Die ppm-Kennzahl wurde bei der Generierung des Fehlerreports nicht angepasst.

Variante 3: Weitere Fakten neben den Fehlerreports haben Einfluss auf die ppm-Kennzahl.

Tabellenanalyse

Die Ermittlung referenzieller Anhängigkeiten steht bei der Tabellenanalyse im Vordergrund. Als referenzielle Abhängigkeit wird dabei die „Beziehung zwischen Attributen [(Merkmalen)] in verschiedenen […] Datensätzen“ [APE15] bezeichnet. Dabei werden folgende Informationen, wie Abhängigkeiten zwischen den Merkmalen und Kardinalitäten, ermittelt. „Die Kardinalität kann zur Einschätzung des Datenqualitätsmerkmals der Eindeutigkeit verwendet werden“ [COR12]. Die minimale Kardinalität gibt die kleinste Anzahl und die maximale Kardinalität die größte Anzahl an, mit der eine Merkmalsausprägung in einer Beziehung vertreten sein kann

[BOD03]. Beispielsweise können zu einem Lieferanten mehrere Bestellungen seitens des Kunden zugeordnet werden.

Zusammenfassens sind in der nachfolgenden Tabelle 5-7 Beispiele zur Prüfung der logischen Datenqualität genannt. Diese Beispiele sind in Bezug zu einer Lieferanten-Abnehmer-Beziehung gesetzt worden.

Tabelle 5-7: Beispiele zur Prüfung der logischen Datenqualität
Quelle: Eigene Darstellung in Anlehnung an [HEL02, BOD03]

Ansatz zur Datenqualitätsprüfung	Beispiel in Bezug auf die Lieferanten-Abnehmer-Beziehung
Schlüsselwerte sind einmalig	`Lieferantennummer NOT NULL AND UNIQUE`
Beziehungen zwischen den Merkmalen und Strukturen in den Datenbeständen	Fehlermeldungen zur Berechnung der ppm in System A entspricht Summe der Fehlerreporte aus System B
Kardinalität	`Lieferant =1 (min=1, max=1)`

Sind mit Hilfe der Data Checker fehlerhafte Datensätzen identifiziert worden, werden Maßnahmen ergriffen, um die Datenqualität sicher- und wiederherzustellen. Diese Prozesse zur Absicherung und Wiederherstellung der Datenqualität werden in Kapitel 5.3 näher betrachtet.

5.3 Absicherung der Datenqualität durch Data Cleaning

Nachdem verschiedene Daten durch das Data Profiling analysiert und fehlerhafte Daten erkannt worden sind, werden in der Literatur verschiedene Möglichkeiten postuliert, wie ein weiterer Umgang mit der fehlerhaften Datenbasis gestaltet werden kann. HELFERT [HEL02] beschreibt die Möglichkeiten der Sicherstellung der Datenqualität als vielfältig. Je nach Abhängigkeit von der Problemursache nennt der Autor folgende mögliche Vorgehensweisen:

- Kennzeichnung der fehlerhaften Daten
- Konzeption einer bereinigten Datenbasis für weitere Auswertungen
- Automatisierte oder manuelle Korrektur der fehlerhaften Daten
- Ausgabe der Prüfergebnisse mit anschließender Korrektur der Daten
- Unternehmensspezifische Regeln

Um einen standardisierten Prozess im Umgang mit Datensätze zu gewährleisten, die eine unzureichende Datenqualität aufweisen, schlagen APEL ET AL. [APE15] drei Prozesse vor. Diese drei Prozesse fassen die Vorgehensweisen von HELFERT [HEL02] zusammen:

- Prozess der Zurückhaltung
- Prozess der Abweisung
- Prozess der Verarbeitung und Bereinigung

Diese Prozesse können auf der Ebene des Merkmals (z.B. fehlende Werte), der Datenbasis (z.B. Verknüpfung von Merkmalen), des Datenobjektes (z.B. einer Tabelle), oder auch der Bestandsebene (z.B. gesamte Datenbasis einer Datei) durchgeführt werden [APE15]. In Bild 5-11 werden diese drei Prozesse visualisiert.

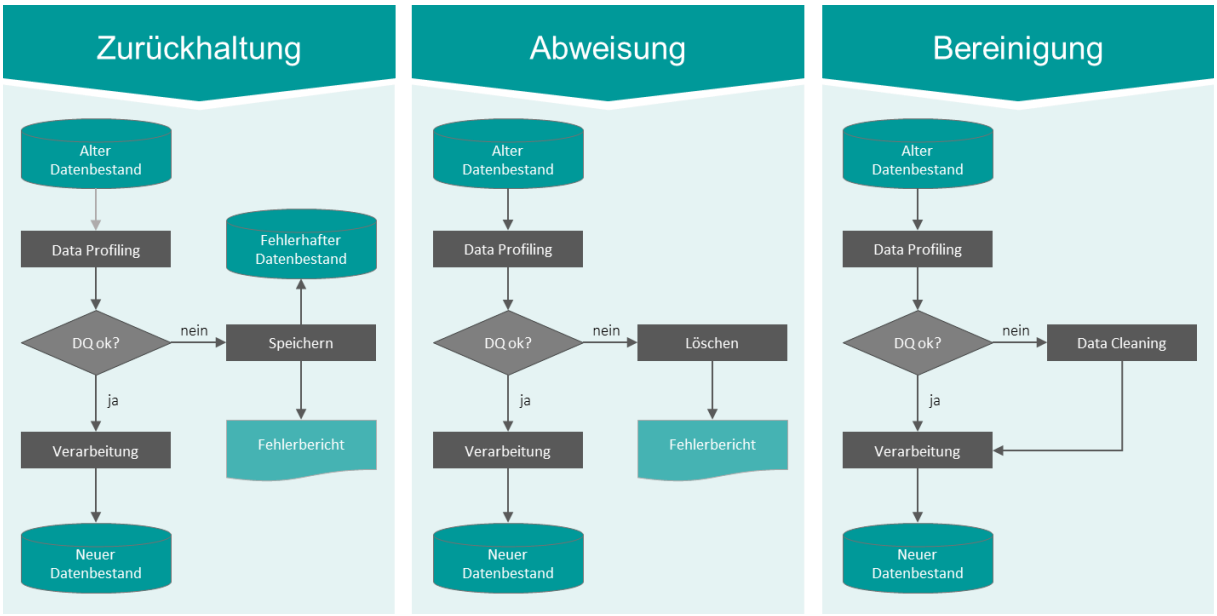


Bild 5-11: Prozesse des Data Cleaning bei fehlerhaften Daten
Quelle: Eigene Darstellung in Anlehnung an [APE15]

Bei allen drei Prozessen wird zunächst ein Data Profiling mit Hilfe der Data Checker durchgeführt (Kapitel 5.2). Je nach Strategie werden dann die Daten gesondert bearbeitet. Die weiteren Ausführungen zu den Prozessen der Zurückhaltung, der Abweisung sowie der Bereinigung werden nach APEL ET AL. [APE15] beschrieben.

Bei der *Zurückhaltung* fehlerhafter Daten werden diese in einem Datenspeicher abgelegt. Dort können die Daten durch weitere Analyseverfahren und manuelle Korrekturen überarbeitet werden. Bei diesem Verfahren sind Inkonsistenzen zwischen Quelldatenbestand und Zieldatenbestand möglich, die aber durch den separaten Datenspeicher zurück zu verfolgen und damit auch nachvollziehbar sind. Mit der Integration des Datenspeichers und der separaten Bearbeitung ist ein hoher Ressourceneinsatz in Bezug auf Hardware und Arbeitskraft durch manuelle Korrekturen verbunden.

Eine *Abweisung* fehlerhafter Daten erfolgt, wenn diese gelöscht und im Prozess nicht weiterverarbeitet werden. Das Löschen wird nicht protokolliert. „In der Praxis kommt dieses Verfahren selten zum Einsatz, weil es gravierende Nachteile hat“ [APE15]. Beispielsweise ist weder Menge noch Inhalt der abgewiesenen Daten nachzuvollziehen. Zusätzlich ist zu bedenken, dass durch das Löschen der nicht validen Daten Inkonsistenzen zwischen den Daten unterschiedlicher Datenquellen entstehen können. Zusätzlich kann es durch das Löschen zu einer Beeinträchtigung der Rückverfolgbarkeit und Transparenz der Daten kommen.

Im Rahmen der *Bereinigun*g fehlerhafter Datenbestände wird der Prozess des Data Cleanings angewendet. Durch einen standardisierten Prozess wird die Datenqualität wiederhergestellt. Beispielsweise werden durch die Duplikaterkennung doppelte Werte herausgefiltert. Mehrere Datensätze werden „nur mit einer bestimmten Wahrscheinlichkeit als Duplikate identifiziert“ [SCH10b]. Zusätzlich wird eine Auswahl dieser doppelten Werte zusammengeführt. Eine vertiefte Darstellung der Verfahren zur Datenbereinigung ist in weiterführender Literatur, beispielsweise von CORDTS [COR12], KÖPPEN ET AL. [KÖP14] und HILDEBRAND ET AL. [HIL15], zu finden.

Wird eine schlechte Datenqualität durch die Data Checker oder durch eine Kennzahl erkannt, können die durch APEL ET AL. [APE15] publizierten Prozesse der Zurückhaltung, Abweisung und Bereinigung durchgeführt werden. Im Rahmen der Verbesserung der Datenqualität sollten jedoch zusätzlich ganzheitliche Maßnahmen definiert werden, damit es nicht wieder zu einer schlechten Datenqualität kommt. Dies könnte beispielsweise eine systemische Warnung an den Anwender sein, dass in einem definierten Betrachtungszeitraum Fehlerreports bei einem bestimmten Lieferanten erkannt worden sind, die ppm aber mit null definiert ist.

5.4 Zusammenfassung und Fazit

Immer häufiger werden große Datenmengen für die Analyse von Geschäftsprozessen genutzt. Auch innerhalb des Data Mining kommen diese zur Anwendung. Dies hat zur Folge, dass auf eine hohe Datenqualität geachtet werden muss. Im Folgenden wird nun dieser Bereich weiter vertieft. Dabei wird das Wesen einer guten Datenqualität untersucht.

Zur Verbesserung der Datenqualität dienen Data Checker. Unter einem Data Checker werden Prozessabfolgen zur Verbesserung der Datenqualität verstanden. Dabei gibt es unterschiedliche Methoden, die in Bild 5-12 dargestellt sind. Diese Methoden stellen gegenseitig keine Alternativen dar.

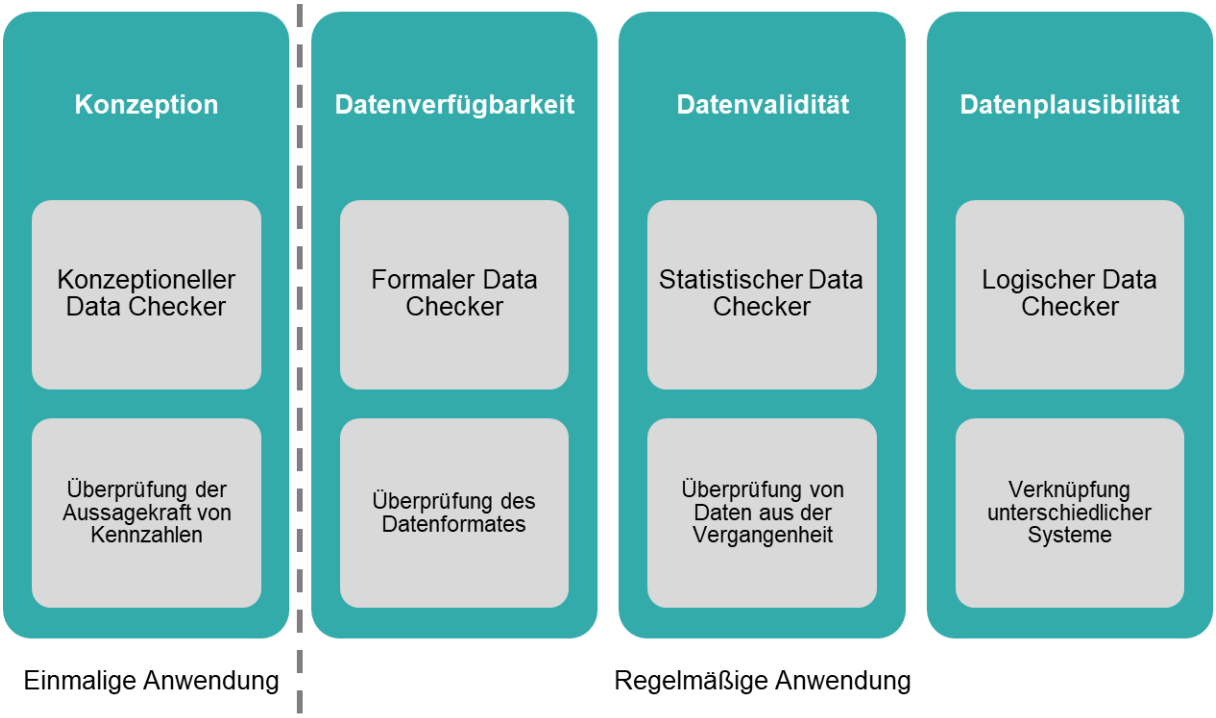


Bild 5-12: Übersicht der Data Checker
Quelle: Eigene Darstellung in Anlehnung an [DUS15]

Eine konzeptionelle Überprüfung der Aussagekraft von genutzten Kennzahlen findet durch den Konzeptionellen Data Checker statt. Dabei wird die Berechnung von Kennzahlen untersucht. Dieses Vorgehen findet bei der Einführung eines Data Profiling Prozesses einmalig Anwendung. Regelmäßige Anwendung finden hingegen die Data Checker zur Überprüfung der Datenverfügbarkeit (Formaler Data Checker), Datenvalidität (Statistischer Data Checker) und Datenplausibilität (Logischer Data Checker). Diese Methoden zur Absicherung der Datenqualität werden regelmäßig vor jeder Datentransformation und Datenmodellierung im Data Mining durchlaufen. Somit wird ein hinreichend genaues Analyseergebnis gewährleistet [BUS14].

Eine Kosten-Nutzen-Überlegung zum Thema Datenqualität strengt SCHENDERA [SCH07] an. Das Ergebnis dieser Erörterung sind folgende Aussagen des Autors:

- Der Aufwand zur Steigerung der Datenqualität lohnt sich, da „Daten mit höherer Qualität […] genauer und interpretierbarer [sind]“ [SCH07].
- „Jede Ungenauigkeit [innerhalb der Daten] kostet bares Geld“ [SCH07], wenn Managemententscheidungen und Strategien auf Basis falschen Wissens beschlossen werden.
- „Datenqualität schützt somit auch vor Fehlverhalten und Fehlinvestitionen.“ [SCH07]

Somit kann eine schlechte Datenqualität Kosten bei darauf basierenden Fehlentscheidungen verursachen. Doch auch die Steigerung der Datenqualität ist mit einem Aufwand verbunden. HARRACH [HAR10a] publiziert in diesem Zusammenhang den Kosten-Nutzen-Faktor der Datenqualität (Bild 5-13).

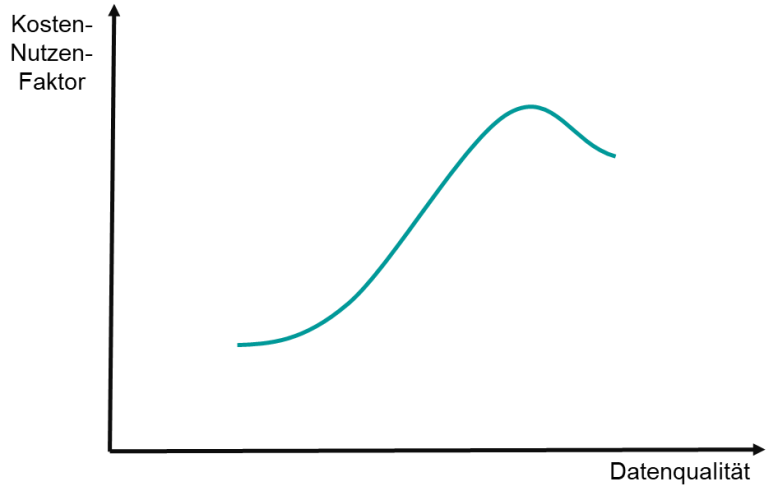


Bild 5-13: Kosten-Nutzen-Faktor der Datenqualität
Quelle: Eigene Darstellung in Anlehnung an HARRACH [HAR10a]

Der Gesamtwert einer guten Datenqualität ist in Abhängigkeit zu den dafür verursachenden Kosten dargestellt. Um alle Mängel der Datenqualität zu beseitigen, werden systematische und unsystematische Fehler betrachtet und bereinigt. Doch auch HARRACH [HAR10a] konstatiert, dass sich der direkte monetäre Nutzen der Datenqualität nur schwer nachweisen lässt. Diese Aussage ist jedoch sehr pauschal und nicht auf einen speziellen Anwendungsfall bezogen. APEL ET AL. postulieren, dass für das Data Mining eine besonders hohe Datenqualität notwendig ist, „damit es nicht zu Fehlinterpretationen [der Ergebnisse] kommt“ [APE15]. Wissenschaftliche Untersuchungen zu einer Kosten-Qualitätsbetrachtung im Rahmen der Datenqualität stehen bisher jedoch noch aus. APEL ET AL. [APE15] sprechen in dem Zusammenhang von Szenarien, die entsprechend priorisiert werden sollen, ohne jedoch auf die Art der Szenarien noch auf die Aussage der Priorität einzugehen. Auch CORDTS [COR12] behandelt die Analyseverfahren, die zu einer hohen Datenqualität führen und QUATEMBERGER [QUA14] betrachtet die Datenqualität bei der Erhebung von Stichproben. Beide Autoren analysieren und beurteilen den Kosten-Nutzen-Vergleich einer hohen Datenqualität nicht. Lediglich BLOCK [BLO18] beschreibt einen Ansatz zur Messung des Einflusses der Datenqualität auf einzelne Kennzahlen über „Gewichts- und Messmatrizen“. Der Einflussfaktor der Datenqualität auf die jeweilige Kennzahl wird subjektiv nach „hoch, mittel und niedrig“ gewählt. Zusätzlich zu

den Matrizen werden Korrekturmaßnahmen für eine unzureichende Datenqualität erörtert (siehe auch Kapitel 5.3). Wie hoch jedoch die ideale Datenqualität sein soll, um einen kennzahlenspezifischen Kosten-Nutzen-Faktor zu ermitteln, bleibt auch in dieser Publikation offen.

Die Überprüfung und Steigerung der Datenqualität ist ein wesentlicher Bestandteil des Data Mining-Prozesses (Kapitel 4). Für die vorliegende Arbeit sollte es das Ziel sein, dass die Datenqualität so hoch wie möglich ist. Liegt keine hohe Datenqualität vor, sind die Ergebnisse der Trendberechnung auf Basis des Trend- und Prognosemodells sowie der quantitativen Assoziationsanalyse nicht valide. Die Gefahr besteht, dass die Ergebnisse der Analysen nicht plausibel sind. Durch diese nicht plausiblen Ergebnisse wird folglich ein Wissen in Form von relevanten, quantitativen Assoziationsregeln generiert, was nicht korrekt und somit nicht anwendbar ist. Möglich ist auch, dass die als relevant bezeichneten, quantitativen Assoziationsregeln auf Grund der unzureichenden Datenqualität doch keine Relevanz aufweisen. In diesen Fällen ist die Konsequenz, dass die Analyseergebnisse nicht valide bzw. plausibel sind. Somit ist das generierte Wissen nicht unbedenklich zu verwenden.

Innerhalb des Kapitel 5 ist nun der in Kapitel 4 unerörterte Data Mining-Prozessschritt der Datenprüfung näher betrachtet worden. Im nächsten Kapitel wird nun ganzheitlich das Data Mining in Bezug auf die vorliegende Aufgabenstellung geprüft und kritisch gewürdigt.

6 Konzeptionsprüfung

Der Fokus der vorliegenden Arbeit bezieht sich auf die Wissensgenerierung im Kontext des TSM-Workflows (Bild 4-3). Bisher sind für eine frühzeitige Risikoidentifikation in externen Wertschöpfungsnetzwerken durch die Kombination verschiedener Data Mining-Prozesse sowie Lieferantenbewertungsverfahren neue Vorgehensweisen erarbeitet worden. In diesem Kapitel werden die Erkenntnisse der vorliegenden Arbeit geprüft. Die Konzeptionsprüfung bezieht sich dabei auf den Fokus dieser Arbeit, die Wissensgenerierung (Bild 4-3 und Bild 4-26), und damit auf das generische Vorgehen, welches in der vorliegenden Arbeit beschrieben worden ist. Schwerpunkt dabei ist die Konzeptionsprüfung in Bezug auf die Ergebnisse der Verfahren Trendberechnung auf Basis des Trend- und Prognosemodells, Clusteranalyse, Assoziationsanalyse und Relevanzprüfung im Rahmen der Datenmodellierung (Kapitel 4.6.5). Ziel ist es, interessante und relevante Assoziationsregeln mit entsprechend zugehörigen Datenmustern zu filtern, auf deren Basis unternehmensspezifisch entschieden wird, ob frühzeitig potenziell kritische Lieferanten erkannt werden können. Um dieses Ziel zu erreichen, wird in der Konzeptionsprüfung besonderer Wert auf die in dieser Arbeit erörterte Relevanzprüfung der Assoziationsregeln (Kapitel 4.3.4) gelegt. Diese stellt einen wesentlichen Schritt zur Wissensgenerierung durch das Finden relevanter, quantitativer Assoziationsregel dar. In der Konzeptionsprüfung wird somit analysiert, welchen Vorteil eine Lieferantenbewertung auf Basis des Data Mining sowie der in der vorliegenden Arbeit erörterten Verfahren zur Wissensgenerierung hat. Zusammenfassend gelten zunächst folgende Annahmen:

- Der Prozess des Data Mining (Kapitel 4.6) wird unter dem Schwerpunkt der Datenmodellierung, wie in Kapitel 4.6.5 beschrieben, angewendet.
- Das Umfeldverständnis bezieht sich auf Risiken im Rahmen der Lieferanten-Abnehmer-Beziehung der externen Wertschöpfungsnetzwerke (Kapitel 3.3).
- Die Datensammlung ist mit anonymisierten Unternehmensdaten aus verschiedenen Forschungsprojekten der Jahre 2014 bis 2017 durchgeführt worden. Die Forschungsprojekte sind in deutschen Konzernen sowie Unternehmen des deutschen Mittelstands im Bereich des Einkaufs und Lieferantenmanagements umgesetzt worden. In der vorliegenden Datenbasis werden leistungsbeschreibende und nicht leistungsbeschreibende Merkmale aus den verschiedenen Forschungsprojekten konsolidiert und einer Lieferantennummer zugeordnet, so dass die Datenbasis zunächst möglichst viele verschiedene Merkmale aufweist. Fehlende Merkmalsausprägungen sind mit einem Zufallsgenerator aufgefüllt worden. Die vorhandenen Merkmale und die zugehörigen Merkmalsausprägungen stellen somit keine Repräsentanz aktueller Daten eines spezifischen Unternehmens oder eines spezifischen Lieferanten dar. Die in Tabelle 6-1 dargestellten Merkmale sind für die beispielhafte Konzeptionsprüfung anhand der zur Verfügung stehenden Daten gewählt worden. Die Ausgangsbasis für leistungsbeschreibende und nicht leistungsbeschreibende Merkmale wird in der folgenden Übersicht dargestellt.

Tabelle 6-1: Importierte Datenbasis
Quelle: Eigene Darstellung

Attribute	Relevante Prozesse	Relevante Daten
Leistungsbeschreibende Merkmale	Logistik	Termintreue Liefertreue
		Trend Termintreue Liefertreue
		Termintreue Angebotsabgabe
		Anzahl Bandstillstände
	Qualität	Termintreue Reklamationsbearbeitung
		ppm
		Anzahl Fehlerreports
		ISO 9001 Zertifikat
		VDA 6.3 Zertifikat
		IATF Zertifikat
	Innovationskraft	Patente pro Jahr
Nicht leistungsbeschreibende Merkmale	Beschaffungsvolumen	Transaktionen pro Jahr
		Umsatz pro Jahr
	Wirtschaftliche Konjunktur	Währung
	(Produktions-)Standort	Produktionsland
		Land der Muttergesellschaft
	Unternehmensspezifische Informationen	Eigenkapitel
		Anzahl der Mitarbeiter
		Unternehmensalter

- Die Datenbasis ist mit Hilfe der Data Checker überprüft worden. Es liegt eine hohe Datenqualität vor. Tabelle 6-2 dient der Übersicht.

Tabelle 6-2: Datenqualität auf Basis der Data Checker
Quelle: Eigene Darstellung

Konzeptioneller Data Checker	Alle Kennzahlen haben als Ergebnis eine konkrete Aussage, die jederzeit reproduzierbar ist. Eine Inversion liegt nicht vor.
Formaler Data Checker	Die gesamte Datenbasis ist formal einheitlich und korrekt dargestellt.
Statistischer Data Checker	Es gibt keine statistischen Auffälligkeiten in der Datenbasis, die auf eine unzureichende Datenqualität hinweisen.
Logischer Data Checker	Es gibt keine logischen Ausfälligkeiten in der Datenbasis, die auf eine unzureichende Datenqualität hinweisen. Alle Daten liegen in einer Datenbasis vor.

- Die Datentransformation beinhaltet die Datenaufbereitung (Ordnung und Strukturierung der Daten) für das jeweilige verwendete Analyseverfahren. Somit wird die Datentransformation für die Trendberechnung auf Basis des Trend- und Prognosemodells, die Clusteranalyse sowie die Assoziationsanalyse und die Relevanzprüfung während der Datenmodellierung für das jeweilige Verfahren individuell und direkt vor dem jeweiligen Analyseverfahren vorgenommen.

Im Folgenden wird der Data Mining-Prozessschritt der Datenmodellierung beschrieben. Dabei werden, wie in Kapitel 4.3 beschrieben, vier Verfahren (Trendberechnung auf Basis des Trend- und Prognosemodells, Clusteranalyse, Assoziationsanalyse und Relevanzprüfung) angewendet. Da das Trend- und Prognosemodell bereits als Bestandteil des TSM in der Praxis verwendet wird, kann in der vorliegenden Arbeit von einer validen Ergebnisdarstellung ausgegangen werden. In Bezug auf die Trendberechnung auf Basis des Trend- und Prognosemodell wird mit Verweis auf das TSM von folgender Annahme ausgegangen:

Die Ergebnisse der Trendberechnung auf Basis des Trend- und Prognosemodells (Kapitel 4.3.1) liegen für die gesamte, zu bewertende Lieferantenbasis vor und sind Teil der zugrunde liegenden Datenbasis. Dazu wird das Analysetool *Watchlist*, wie in Anhang A beschrieben, verwendet. Die *Watchlist* wird bereits in der Praxis bei verschiedenen Unternehmen im Automobil- und Automotive-Bereich angewendet. Die Ergebnisdarstellung der Watchlist ist im Bild 6-1 beispielhaft dargestellt. Die Interpretationen der einzelnen Zeilen und Spalten sind in Kapitel 4.3.1 zu finden.

Watchlist - Indikator für kritische Lieferanten

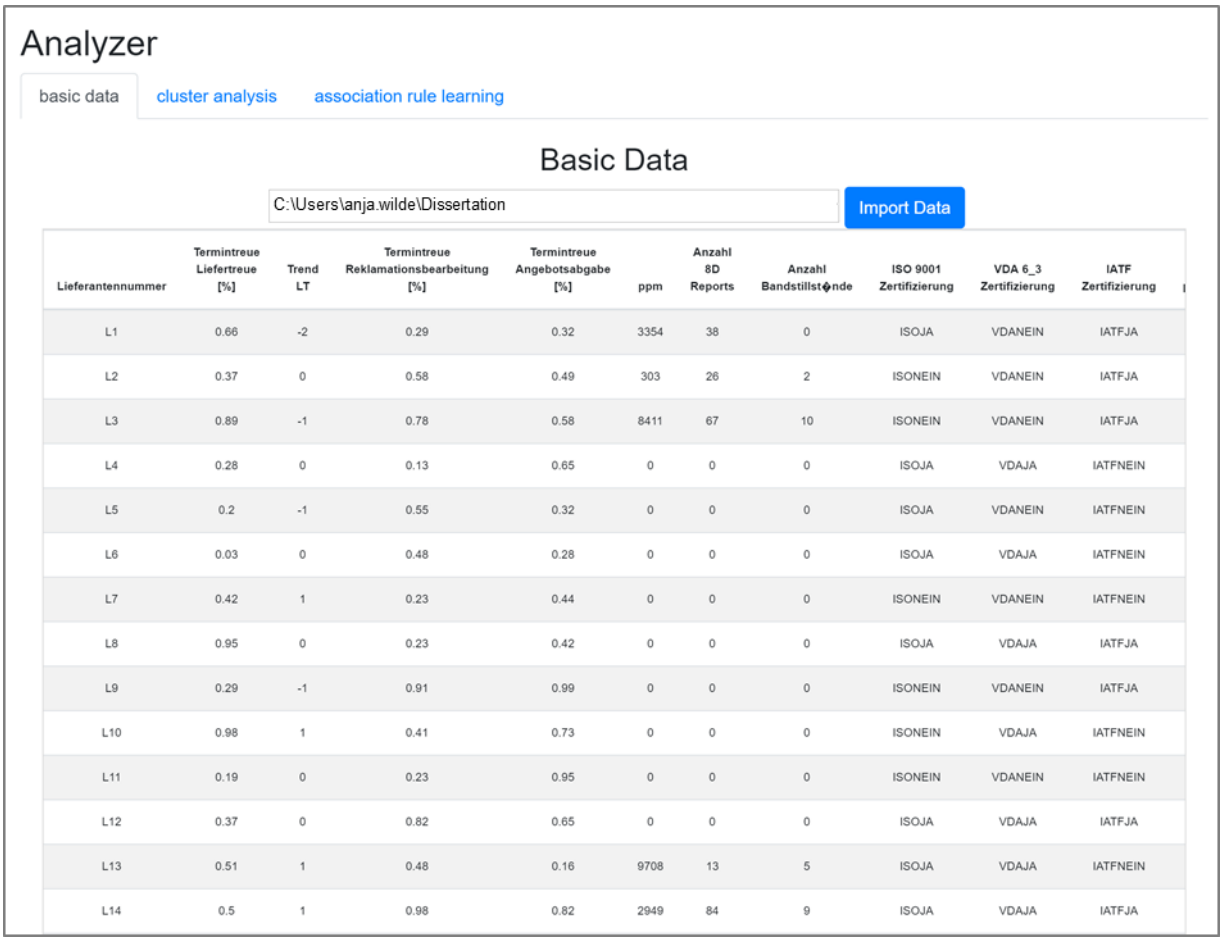
Datum: 2018

				PRÄVENTIV 12 Monate	PRÄVENTIV 3 Monate	REAKTIV Rang
		Leistungsbeschreibende Kriterien				
Information		Liefertreue				
Lieferanten-nummer	Auswahl für das Diagramm	aktueller Monat	Prognose t+1	12-Monats Trend	3-Monats Trend	Rang (aktuell)
L9		29%	16%	⇨	↓	347
L17		54%	44%	↗	↓	276
L21		88%	64%	⇨	↓	186
L1		66%	57%	↘	↓	246
L4		28%	20%	↗	↘	348
L3		89%	75%	⇨	↘	152
L8		95%	89%	↑	↘	67
L11		19%	26%	↓	⇨	354
L15		34%	40%	↓	⇨	320
L16		72%	68%	↘	⇨	237
L16		72%	69%	⇨	⇨	237
L20		74%	72%	⇨	⇨	240
L22		63%	60%	↑	⇨	253
L23		17%	21%	↓	⇨	367
L24		39%	44%	⇨	⇨	311
L25		77%	73%	⇨	⇨	226
L26		4%	0%	⇨	⇨	398
L27		9%	5%	⇨	⇨	395
L28		36%	41%	⇨	⇨	316
L2		37%	39%	↘	⇨	315

Bild 6-1: Watchlist als Analysetool für das Trend- und Prognosemodell – Auszug der Ergebnisse
Quelle: Eigene Darstellung

Im Weiteren wird das in dieser Arbeit entwickelte Analysetool mit Namen *Analyzer* verwendet. Der *Analyzer* ist im Rahmen der vorliegenden Arbeit programmiert worden, da es keine bekannte Softwareunterstützung zur Generierung von quantitativen Assoziationsregeln gibt (Kapitel 4.4). Der *Analyzer* hat somit das Ziel, die quantitativen Assoziationsregeln zu generieren, die Interessantheitsmaße zu errechnen (Kapitel 4.3.3) sowie die Teilmenge an Lieferanten auszugeben, auf die die entsprechende Regel zutrifft. Der *Analyzer* wird im Rahmen der vorliegenden Arbeit als Sourcecode in Anhang D und E sowie als Anwendung in Anhang F auf Basis einer Anwendungsdatei durch eine CD zur Verfügung gestellt.

Zunächst wird die nun vollständig vorliegende und auf ihre Datenqualität überprüfte Datenbasis in den *Analyzer* als .csv-Datei importiert. Bild 6-2 visualisiert dazu einen Auszug aus der importierten Datenbasis. Wird nach rechts gescrollt, erscheinen weitere Merkmalsausprägungen zu den einzelnen Lieferanten mit den entsprechenden Lieferantennummern (linke Spalte).



Lieferantennummer	Termintreue Liefertreue [%]	Trend LT	Termintreue Reklamationsbearbeitung [%]	Termintreue Angebotsabgabe [%]	ppm	Anzahl 8D Reports	Anzahl Bandstillst◆nde	ISO 9001 Zertifizierung	VDA 6_3 Zertifizierung	IATF Zertifizierung
L1	0.66	-2	0.29	0.32	3354	38	0	ISOJA	VDANEIN	IATFJA
L2	0.37	0	0.58	0.49	303	26	2	ISONEIN	VDANEIN	IATFJA
L3	0.89	-1	0.78	0.58	8411	67	10	ISONEIN	VDANEIN	IATFJA
L4	0.28	0	0.13	0.65	0	0	0	ISOJA	VDAJA	IATFNEIN
L5	0.2	-1	0.55	0.32	0	0	0	ISOJA	VDANEIN	IATFNEIN
L6	0.03	0	0.48	0.28	0	0	0	ISOJA	VDAJA	IATFNEIN
L7	0.42	1	0.23	0.44	0	0	0	ISONEIN	VDANEIN	IATFNEIN
L8	0.95	0	0.23	0.42	0	0	0	ISOJA	VDAJA	IATFJA
L9	0.29	-1	0.91	0.99	0	0	0	ISONEIN	VDANEIN	IATFJA
L10	0.98	1	0.41	0.73	0	0	0	ISONEIN	VDAJA	IATFNEIN
L11	0.19	0	0.23	0.95	0	0	0	ISONEIN	VDANEIN	IATFNEIN
L12	0.37	0	0.82	0.65	0	0	0	ISOJA	VDAJA	IATFJA
L13	0.51	1	0.48	0.16	9708	13	5	ISOJA	VDAJA	IATFNEIN
L14	0.5	1	0.98	0.82	2949	84	9	ISOJA	VDAJA	IATFJA

Bild 6-2: Datenimport in den *Analyzer* als Analysetool für quantitative Assoziationsregeln – Auszug der Ergebnisse
Quelle: Eigene Darstellung

Ist die Datenbasis importiert, wird in Bezug auf die metrischen Merkmalsausprägungen (z.B. die Kennzahl Liefertreue) die Clusteranalyse angewendet (Kapitel 4.4.4). Alle Merkmalsausprägungen, die einen nominalen Datentyp darstellen (z.B. ISO 9001 Zertifizierung oder Währung), werden entsprechend des nominalen Datentyps zusammengefasst und bilden je nach Ausprägung ein neues Attribut.

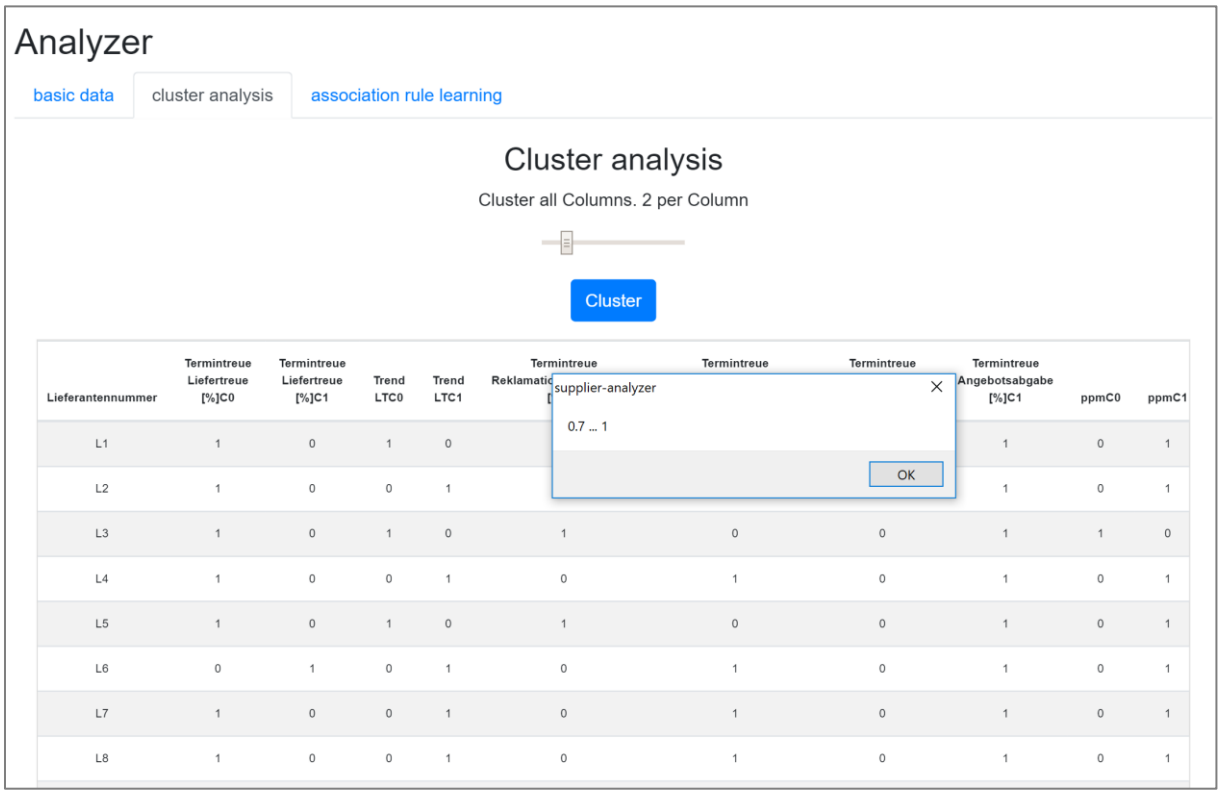
Dabei gibt es eine Beschränkung beim *Analyzer*, was im Gegensatz zu dem theoretisch erarbeiteten Modell eine Vereinfachung darstellt. Die Anzahl der Cluster sowie der Ausprägungen der nominalen Datentypen werden vorgegeben. Diese vorgegebene Anzahl, geht bei nominalen Merkmalen bereits aus der in den Analyzer importierten Datenstruktur hervor. Im konkreten Beispiel liegen so viele Gruppen vor, wie auch später im Analyzer als Cluster eingegeben worden sind. Eine Gruppe kann dabei beispielsweise beim nicht leistungsspezifischen Merkmal der Währung der Euro sein, eine andere Gruppe ist der Dollar.

Dieses Vorgehen verletzt die theoretische Darstellung der Lösung für die Clusteranzahl in Kapitel 4.3.2. Die entwickelte, vorliegende Programmierarbeit ist für eine erste Indikation der Konzeptionsprüfung mit dieser Vereinfachung dennoch anwendbar. Eine dynamische Anpassung der Cluster könnte in weiteren Untersuchungen thematisiert werden. Ob es durch die statische Festlegung der Clusteranzahl zu einer signifikanten Verschlechterung des Ergebnisses

kommt, ist bislang eine Hypothese und kann in der vorliegenden Arbeit nicht beurteilt werden. Somit wird im Weiteren auf Basis der festen Clusteranzahl gearbeitet.

Je Merkmal der importierten Datenbasis (Tabelle 6-1) werden für eine vereinfachte Darstellung im Rahmen eines ersten Machbarkeitsnachweises zwei Cluster gebildet bzw. es liegen im Testdatensatz zwei verschiedene Ausprägungen (Gruppen) der nominalen Datentypen vor. Würden mehr Cluster gewählt werden oder liegen viele verschiedene Ausprägungen der nominalen Datentypen vor, würde sich die Anzahl der durch die Analyse generierten Attribute für die Assoziationsanalyse ebenfalls erhöhen. Damit erhöht sich gleichzeitig der Komplexitätsgrad der Assoziationsanalyse, da eine Vielzahl zusätzlicher Regeln generiert wird. Mit der Steigerung des Komplexitätsgrades erhöht sich auch gleichzeitig der Rechenaufwand. Bei der Generierung von zwei Clustern beträgt die Rechenzeit des *Analyzers* ca. 10 Minuten. Bei einer steigenden Anzahl der Cluster, beispielsweise auf vier Cluster, steigert sich die Rechenzeit auf 30 Minuten.

Um jedoch das generelle Vorgehen in der Konzeptionsprüfung zu analysieren, wird auf eine vereinfachte Analyseform mit einer geringen Anzahl von jeweils 2 Clustern und zwei Ausprägungen bei nominalen Datentypen pro Merkmal im Rahmen des *Analyzers* zurückgegriffen. Die Clusterausprägung der einzelnen Cluster als Ergebnisse der Clusteranalyse lassen sich im *Analyzer* anzeigen. Bild 6-3 visualisiert die Clusterausprägung für das Cluster C1 des Attributs „Termintreue Angebotsabgabe [%]“.



Lieferantennummer	Termintreue Liefertreue [%]C0	Termintreue Liefertreue [%]C1	Trend LTC0	Trend LTC1	Termintreue Reklamatio	Termintreue	Termintreue	Termintreue Angebotsabgabe [%]C1	ppmC0	ppmC1
L1	1	0	1	0				1	0	1
L2	1	0	0	1				1	0	1
L3	1	0	1	0	1	0	0	1	1	0
L4	1	0	0	1	0	1	0	1	0	1
L5	1	0	1	0	1	0	0	1	0	1
L6	0	1	0	1	0	1	0	1	0	1
L7	1	0	0	1	0	1	0	1	0	1
L8	1	0	0	1	0	1	0	1	0	1

Bild 6-3: Ergebnisse der Clusteranalyse für die importierte Datenbasis auf Basis von 2 Clustern je Attribut – Auszug der Ergebnisse

Quelle: Eigene Darstellung

Die Prozentangabe der „Termintreue Angebotsabgabe“ bezieht sich dabei auf den Erfüllungsgrad dieser Kennzahl. Die Darstellung in Bild 6-3 verdeutlicht, dass die Datenbasis für das Merkmal „Termintreue Angebotsabgabe [%]“ folgende Clustereinteilung hat:

- Ausprägung des ersten Clusters: 0% bis 69%
- Ausprägung des zweiten Clusters: 70% bis 100%

Die Cluster sowie die Ausprägungen der nominalen Datentypen werden in einer boolschen Datenbank als Ergebnisse ausgegeben (Bild 6-3). Die Ergebnisse gehen als Attribute in die Assoziationsanalyse ein. Im vorliegenden Fall bedeutet das:

$$13\ numerische\ Merkmale \cdot 2\ Cluster + 6\ nominale\ Merkmale \cdot 2\ Ausprägungen\ = 38\ \ Attribute$$

Diese 38 Attribute dienen als Input für die Assoziationsanalyse. Auf Basis der Assoziationsanalyse werden die quantitativen Assoziationsregeln mit Hilfe des *Analyzers* generiert. Visualisiert werden die generierten, quantitativen Assoziationsregeln mit der Berechnung der zugehörigen Interessantheitsmaße Support, Konfidenz und Lift (Kapitel 4.3.3). Zusätzlich ist es möglich, sich die Teilmenge der Lieferanten anzeigen zu lassen, auf die eine entsprechende quantitative Assoziationsregel zutrifft. Dafür wird die gewünschte quantitative Assoziationsregel ausgewählt. Automatisch erscheint ein Fenster mit der entsprechenden Teilmenge der Lieferantenbasis (Bild 6-4).

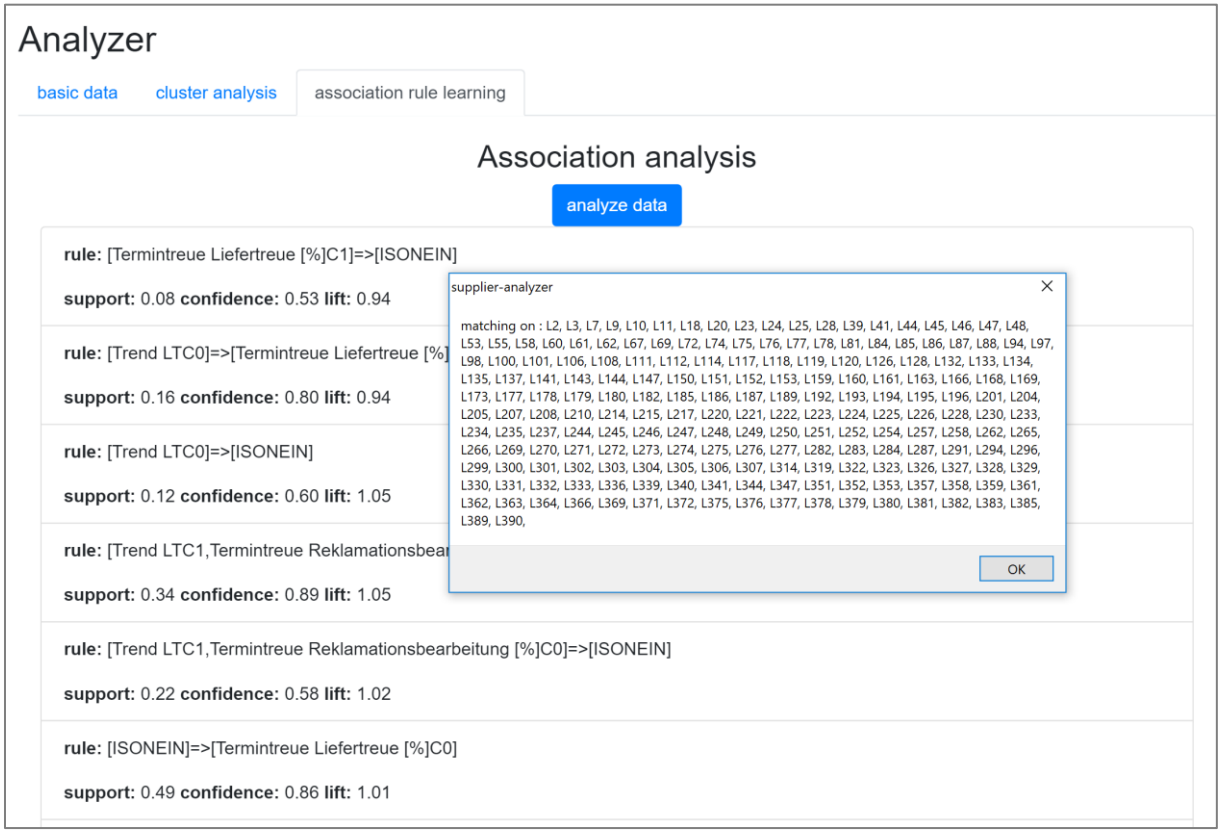


Bild 6-4: Ergebnisse der quantitativen Assoziationsanalyse für die importierte Datenbasis auf Basis von 2 Clustern oder 2 Ausprägungen nominaler Datentypen je Attribut – Auszug der Ergebnisse

Quelle: Eigene Darstellung

Aufgrund der Vielzahl möglicher, quantitativer Assoziationsregeln ist es mit dem *Analyzer* nicht möglich die Gesamtheit aller theoretisch möglicher, quantitativer Assoziationsregeln zu generieren. Es wird eine Teilmenge dieser Regeln ausgegeben, da im vorliegenden Fall der *Analyzer* nach sechs Stunden beendet worden ist. Die Ergebnisse sind für eine erste Konzeptionsprüfung dennoch ausreichend, da dargestellt werden kann, wie die mögliche Relevanzprüfung innerhalb eines Prozesses von sechs Schritten durchlaufen werden kann.

Die im Folgenden dargestellte Relevanzprüfung dient für die vorliegende Arbeit einer Verifikation des bisher erstellten Konzeptes zur Analyse von Datenmustern, um mögliche Risiken im externen Wertschöpfungsnetzwerk zu identifizieren. In einer praktischen Umsetzung werden die in Kapitel 4.3.3 beschriebenen Interessantheitsmaße Support, Konfidenz und Lift für eine erste Indikation in Bezug auf die Interessantheit einer Assoziationsregel betrachtet. Auf Basis der Interessantheitsmaße ist es somit möglich, die Generierung von Assoziationsregeln auf die als interessant definierten zu beschränken. Aufgrund fehlender Langzeitbeobachtungen des vorliegenden Konzeptes durch eine empirische Studie kann in der vorliegenden Arbeit keine Aussage über die optimalen Ausprägungen der Interessantheitsmaße getroffen werden. Somit beschränkt sich die Konzeptionsprüfung auf eine erste theoretische Machbarkeitsanalyse zur Identifikation interessanter quantitativer Assoziationsregeln im Rahmen der Relevanzprüfung. Für die Relevanzprüfung werden die bisherigen Ergebnisse des *Analyzers* genutzt.

Innerhalb der Laufzeit des *Analyzers* ist es möglich gewesen, bis zu 6590 Regeln zu generieren. Da dies nur eine Teilmenge aller theoretisch möglichen Regeln darstellt, ist durch den *Analyzer* keine Reihenfolge festgelegt, in der die quantitativen Assoziationsregeln generiert werden. Es ist also möglich, dass bei verschiedenen Anwendungen des *Analyzers* die Ausgabe der quantitativen Assoziationsregeln differiert.

Da bislang eine vollständige Datenbasis unterstellt worden ist, wird nachfolgend weiterhin davon ausgegangen. Somit werden im weiteren Verlauf die quantitativen Assoziationsregeln zunächst theoretisch generiert. Dabei ist wesentlich, wie viele quantitative Assoziationsregeln generiert werden können. Zur Errechnung der Anzahl von quantitativen Assoziationsregeln bietet, wie in Kapitel 4.3.4 beschrieben, die Formel auf der Basis *Ziehen mit Zurücklegen und ohne Berücksichtigung der Reihenfolge* eine Grundlage. Diese Formel wird nun auf 38 Attribute, die für die Assoziationsanalyse zur Verfügung stehen, angewendet (Kapitel 4.3.4):

$$\sum_{n=1}^{k-1}(2^n - 1) \cdot \binom{k}{k-n} \tag{13}$$

Da zunächst 38 Attribute zur Verfügung stehen, wird nicht von einem $k > 38$ ausgegangen. Mit $k = 38$ ergeben sich somit $1.350.851.167.917.180.000$ theoretisch mögliche, quantitative Assoziationsregeln im Rahmen der vorliegenden Arbeit.

Diese Summe aller möglichen quantitativen Assoziationsregeln gilt nun zunächst als Ausgangsbasis für die Relevanzprüfung. Die Relevanzprüfung wird nun, wie in Kapitel 4.3.4 beschrieben, anhand von sechs Stufen durchgeführt.

Stufe 1: keine gleichen Attribute differierender Cluster oder nominaler Datentypen

In der vorliegenden Relevanzprüfung werden auf Basis des *Analyzers* für jedes Attribut zwei Cluster bei metrischen Datentypen und zwei Ausprägungen bei nominalen Datentypen gene-

riert. Wird die Anzahl der Attribute in der ersten Stufe bei differierenden Clustern oder Ausprägungen nominaler Datentypen gleicher Attribute um diese Cluster oder Ausprägungen nominaler Datentypen reduziert, kann $k = 19$ gesetzt werden. Beispielsweise werden quantitative Assoziationsregeln, bei denen alle Cluster der Kennzahl „Liefertreue“ enthalten sind, verworfen. Diese quantitativen Assoziationsregeln weisen auf Grund der enthaltenen Grundgesamtheit aller Ausprägungen der Kennzahl „Liefertreue“ auf die gesamte Lieferantenbasis hin. Somit wird immer nur ein Cluster oder eine Gruppe eines Attributes innerhalb einer quantitativen Assoziationsregel betrachtet. Wird darauf wieder die Formel (13) angewendet, ergeben sich $1.161.212.892$ theoretisch mögliche, quantitative Assoziationsregeln im Rahmen der vorliegenden Arbeit.

Die Anzahl der generierbaren, quantitativen Assoziationsregeln ist in der ersten Stufe der Relevanzprüfung um ein Vielfaches reduziert worden. Es wird in dieser Stufe von der Möglichkeit ausgegangen, dass maximal 19 verschiedene Attribute durch die Ausprägung der entsprechenden Cluster oder Ausprägungen nominaler Datentypen in einer Assoziationsregel vertreten sind. Diese quantitativen Assoziationsregeln mit maximal $k = 19$ Attributen werden als relevante, quantitative Assoziationsregeln an Stufe 2 der Relevanzprüfung übergeben.

Stufe 2: Keine großen Regeln

Ausgehend von der Anzahl der in Stufe 1 als relevant definierten, quantitativen Assoziationsregeln werden diese nun weiter untersucht. Dabei werden in Stufe 2 weitere mögliche, quantitative Assoziationsregeln ausgeschlossen, auf die eine große Menge der Lieferanten zutrifft. In einer großen Teilmenge der Lieferantenbasis sind potenziell kritische Lieferanten nicht identifizierbar, da sie sich nicht von den nicht kritischen Lieferanten differenzieren. Je mehr Attribute in einer quantitativen Assoziationsregel enthalten sind, desto mehr Lieferanten sind betroffen. Der Fokus liegt somit auf quantitativen Assoziationsregeln, auf die eine Teilmenge der Lieferantenbasis zutrifft. Für diesen Ausschluss der quantitativen Assoziationsregeln wird wiederum eine Annahme getroffen:

Alle Regeln, die mehr als 4 Attribute in einer quantitativen Assoziationsregel haben, werden für das weitere Vorgehen nicht mehr betrachtet. Eine unternehmensspezifische Untersuchung dieser Attributsanzahl ist für eine generelle Aussage in der Praxis zwingend erforderlich. Da in dieser Arbeit auf theoretische Erkenntnisse zurückgegriffen wird, ist für das weitere Vorgehen der generellen Konzeptionsprüfung der Vorgehensweise diese Annahme zunächst ausreichend.

Mit der Annahme $k = 4$ ergeben sich insgesamt 65.455 relevante quantitative Assoziationsregeln in der 2. Stufe. Von den 65.455 relevanten, quantitativen Assoziationsregeln sind durch den *Analyzer* 6.590 Regeln generiert worden. Das macht eine Menge von 10,1 Prozent in Bezug auf die in Stufe 2 als relevant betrachteten quantitativen Assoziationsregeln aus. Durch den *Analyzer* werden die quantitativen Assoziationsregeln sowie die Interessantheitsmaße Support, Konfidenz und Lift, wie in Kapitel 4.3.3 beschrieben, errechnet und dargestellt. Diese Ergebnisse des *Analyzers* werden für die weitere Verarbeitung in eine Exceltabelle exportiert. Die weitere Relevanzanalyse findet nun aus Basis der durch den *Analyzer* generierten quantitativen Assoziationsregeln statt. Um die Ergebnisse in Bezug zur Gesamtmenge aus Stufe 2 zu setzen, werden die Ergebnisse jeweils wieder hochgerechnet.

Stufe 3: Keine Zuordnung zu einem Lieferanten

Ausgehend von 6.590 generierten quantitativen Assoziationsregeln werden nun alle quantitativen Assoziationsregeln, die folgende Eigenschaft des Interessantheitsmaßes Support aufweisen, von den weiteren Betrachtungen ausgeschlossen:

$sup(X \rightarrow Y) = 0$

Diese quantitativen Assoziationsregeln haben keine Zuordnung zu einem Lieferanten und können in der weiteren Betrachtung ignoriert werden. Die Anzahl der nun ausgeschlossenen quantitativen Assoziationsregeln beträgt 6.454 innerhalb der generierten 6.590 quantitativen Assoziationsregeln. Wird das Ergebnis auf das Gesamtvolumen von 65.455 möglichen quantitativen Assoziationsregeln hochgerechnet, ergibt das eine theoretische Reduktion um 64.095 quantitative Assoziationsregeln.

In Stufe 3 bleibt somit folgende Menge an quantitativen Assoziationsregeln relevant:

- Auf Basis der generierten 6.590 quantitativen Assoziationsregeln:

  136 relevante, quantitative Assoziationsregeln

- In Bezug zu den möglichen 65.455 quantitativen Assoziationsregeln (Hochrechnung):

  1.350 relevante, quantitative Assoziationsregeln

Die Hochrechnung erfolgt über eine prozentuale Berechnung:

$\frac{100}{6.590} \cdot 136 = 2{,}06\ \%$

2,06% relevante quantitative Assoziationsregeln sind in der generierten Masse von 6.590 quantitativen Assoziationsregeln enthalten.

$\frac{65.450}{100} \cdot 2{,}06 = 1.350$

Hochgerechnet auf die 65.455 relevanten, quantitativen Assoziationsregeln sind 1.350 quantitative Assoziationsregeln relevant, da sie einen Bezug zu Lieferanten haben. Diese Menge an bisher relevanten, quantitativen Assoziationsregeln wird für eine weitere Relevanzprüfung an die Stufe 4 übergeben.

Stufe 4: Ausschluss von großen Lieferantenmengen

Wie bereits in Kapitel 4.3.4 beschrieben, bieten quantitative Assoziationsregeln, denen eine große Menge der Lieferantenbasis zuzuordnen ist, keinen Mehrwert zum Auffinden potenziell kritischer Lieferanten. Im vorliegenden Beispiel ist die Annahme getroffen worden, dass die kritische Masse, die einen Mehrwert liefert, initial bei bis zu 50 Lieferanten pro quantitativer Assoziationsregel liegt. Diese Grenze ist jedoch unternehmensspezifisch zu eruieren und kann nicht pauschalisiert werden. Es ist ebenfalls möglich, dass sich diese Grenze je nach Lerneffekt mit der Zeit nochmals verschieben kann.

Die Anzahl der in Stufe 4 als relevant kategorisierten, quantitativen Assoziationsregeln mit einem Bezug zu maximal 50 Lieferanten beträgt nun:

- Auf Basis der generierten 136 quantitativen Assoziationsregeln:

  41 relevante, quantitative Assoziationsregeln

- In Bezug zu den möglichen 1.350 quantitativen Assoziationsregeln (Hochrechnung):

  406 relevante, quantitative Assoziationsregeln

Die Hochrechnung erfolgt über den bereits in Stufe 3 beschriebenen Weg. Diese Menge an bisher relevanten, quantitativen Assoziationsregeln wird für eine weitere Relevanzprüfung an die Stufe 5 übergeben.

Stufe 5: Mindestens ein leistungsbeschreibendes Attribut

In der Stufe 5 der Relevanzprüfung wird die Integration leistungsbeschreibender Attribute in den bisher relevanten, quantitativen Assoziationsregeln geprüft. In Bezug zu den 41 relevanten, quantitativen Assoziationsregeln werden 22 quantitative Assoziationsregeln ausgeschlossen, die kein leistungsbeschreibendes Attribut, wie beispielsweise die Kennzahlen Liefertreue, ppm oder auch Anzahl Bandstillstände enthalten. Diese quantitativen Assoziationsregeln haben auf Grund des fehlenden leistungsbeschreibenden Attributes keine Risikorelevanz (Kapitel 4.3.4).

Die Anzahl der in Stufe 5 als relevant kategorisierten, quantitativen Assoziationsregeln, die eine Risikorelevanz haben, beträgt:

- Auf Basis der generierten 41 quantitativen Assoziationsregeln:

  19 relevante, quantitative Assoziationsregeln

- In Bezug zu den möglichen 406 quantitativen Assoziationsregeln (Hochrechnung):

  188 relevante, quantitative Assoziationsregeln

Die Hochrechnung erfolgt über den bereits in Stufe 3 beschriebenen Weg. Diese Menge an bisher relevanten, quantitativen Assoziationsregeln wird für eine weitere Relevanzprüfung an die Stufe 6 übergeben.

Stufe 6: Keine Attribute, die in einem logischen Zusammenhang stehen

In der Stufe 6 der Relevanzprüfung werden korrelierende Attribute innerhalb einer quantitativen Assoziationsregel ausgeschlossen. Im vorliegenden Beispiel stehen folgende leistungsbeschreibender Attribute in einem logischen Zusammenhang:

Logischer Zusammenhang A:	ppm, Anzahl Fehlerreports
Logischer Zusammenhang B:	Termintreue Liefertreue, Trend Liefertreue, Anzahl Bandstillstände

Zusätzlich stehen auch folgende nicht leistungsbeschreibende Attribute in einem logischen Zusammenhang:

Logischer Zusammenhang C: Währung, Land der Muttergesellschaft

Bei dieser Relevanzprüfungsstufe konnten nun zusätzlich 3 quantitative Assoziationsregeln ausgeschlossen werden. Das Ergebnis der in Stufe 6 als relevant kategorisierten, quantitativen Assoziationsregeln ohne korrelierende Attribute beträgt:

- Auf Basis der generierten 19 quantitativen Assoziationsregeln:

  16 relevante, quantitative Assoziationsregeln

- In Bezug zu den möglichen 188 quantitativen Assoziationsregeln (Hochrechnung):

  158 relevante, quantitative Assoziationsregeln

Die Hochrechnung erfolgt über den bereits in Stufe 3 beschriebenen Weg. Die Menge der hochgerechneten 158 relevanten quantitativen Assoziationsregeln müssen nun über Erfahrungswerte des impliziten Wissens (Kapitel 4.2) auf weitere Relevanz geprüft werden. Dafür wird zunächst das Ergebnis der 16 über den Analyzer generierten, relevanten, quantitativen Assoziationsregeln in Tabelle 6-3 dargestellt:

Tabelle 6-3: Ergebnis der Relevanzprüfung
Quelle: Eigene Darstellung

Quantitative Assoziationsregel	Support	Konfidenz	Lift	Betreffende Lieferanten
[Termintreue Reklamationsbearbeitung [%] Cluster 2]=> [Termintreue Liefertreue [%] Cluster 1]	0,1	0,19	1,26	["L6","L19","L27","L29","L59","L64","L68","L71","L73","L80","L89","L91", "L121","L131","L140","L167","L176","L184","L229","L259","L279","L285", "L295","L297","L310","L312","L313","L315","L334","L342","L356","L360", "L370","L373","L374","L388","L391","L395"]
[Termintreue Angebotsabgabe [%] Cluster 1]=> [Termintreue Liefertreue [%] Cluster 1]	0,1	0,15	1	["L6","L19","L27","L29","L64","L68","L71","L73","L80","L91","L93","L99", "L140","L154","L156","L170","L176","L184","L213","L227","L229","L240", "L241","L259","L279","L285","L290","L295","L309","L310","L313","L315", "L342","L343","L356","L360","L370","L374","L391"]
[ISO_JA]=> [Termintreue Liefertreue [%] Cluster 1]	0,07	0,17	1,11	["L6","L19","L32","L64","L68","L71","L80","L89","L91","L93","L184","L212", "L229","L239","L285","L297","L310","L315","L338","L342","L343","L373", "L374","L386","L391","L395"]
[Termintreue Reklamationsbearbeitung [%] Cluster 2, Termintreue Angebotsabgabe [%] Cluster 1]=> [Termintreue Liefertreue [%] Cluster 1]	0,07	0,2	1,33	["L6","L19","L27","L29","L64","L68","L71","L73","L80","L91","L140","L176", "L184","L229","L259","L279","L285","L295","L310","L313","L315","L342", "L356","L360","L370","L374","L391"]
[Trend LT Cluster 2]=> [Termintreue Liefertreue [%] Cluster 2, Termintreue Reklamationsbearbeitung [%] Cluster 1]	0,06	0,4	6,67	["L25","L36","L44","L46","L77","L81","L87","L90","L108","L110","L123", "L127","L141","L152","L160","L162","L173","L175","L210","L277","L306","L 366","L385"]
[Trend LT Cluster 2]=> [ISO_JA]	0,06	0,4	0,95	["L1","L19","L21","L34","L36","L40","L50","L64","L71","L83","L90","L110", "L123","L127","L139","L162","L175","L219","L268","L286","L297","L400"]
[Termintreue Reklamationsbearbeitung [%] Cluster 1]=> [Termintreue Liefertreue [%] Cluster 1]	0,06	0,13	0,85	["L26","L32","L93","L99","L142","L154","L156","L170","L206","L212","L213", "L227","L239","L240","L241","L290","L309","L338","L343","L348","L386", "L392"]
[Trend LT Cluster 2]=> [Anzahl Bandstillstände Cluster 2, ISO_JA]	0,05	0,33	0,83	["L1","L19","L34","L36","L50","L64","L71","L83","L90","L123","L127","L139", "L162","L175","L219","L268","L286","L297","L400"]

Tabelle 6-4: Ergebnis der Relevanzprüfung (Fortsetzung)

Quantitative Assoziationsregel	Support	Konfidenz	Lift	Betreffende Lieferanten
[Anzahl Bandstillstände Cluster 2, ISO_JA]=> [Trend LT Cluster 2, ISO_JA]	0,05	0,13	2,5	["L1","L19","L34","L36","L50","L64","L71","L83","L90","L123","L127","L139", "L162","L175","L219","L268","L286","L297","L400"]
[Trend LT Cluster 2, Termintreue Reklamati-onsbearbeitung [%] Cluster 1]=> [ISO_JA]	0,02	0,29	0,68	["L36","L90","L110","L123","L127","L162","L175"]
[Trend LT Cluster 2, Termintreue Reklamati-onsbearbeitung [%] Cluster 1]=> [Termintreue Liefertreue [%] Cluster 1]	0,01	0,14	0,95	["L142","L154","L309","L348"]
[Trend LT Cluster 2, Termintreue Reklamati-onsbearbeitung [%] Cluster 2]=> [Anzahl Bandstillstände Cluster 2, ISO_JA]	0,01	0,14	0,36	["L36","L90","L123","L127","L162","L175"]
[Termintreue Angebotsabgabe [%] Cluster 2, ppm Cluster 1]=> [Termintreue Liefertreue [%] Cluster 1]	0,01	0,5	3,33	["L26","L59","L338"]
[Termintreue Angebotsabgabe [%] Cluster 2, ppm Cluster 1]=> [Termintreue Liefertreue [%] Cluster 2, Trend LT Cluster 1]	0,01	0,5	0,68	["L23","L41","L56","L88","L158"]
[Termintreue Angebotsabgabe [%] Cluster 2, ppm Cluster 1]=> [Anzahl Bandstillstände Cluster 2, ISO_JA]	0,01	0,5	1,25	["L56","L158","L338"]
[Termintreue Angebotsabgabe [%] Cluster 2, ppm Cluster 1]=> [ISO_JA]	0,01	0,5	1,19	["L56","L158","L338"]

Die türkis markierten, quantitativen Assoziationsregeln unterstützen keine Neuartigkeit des Wissens. In den quantitativen Assoziationsregeln ist das Attribut des Trends der Liefertreue enthalten. Bereits über die Trendberechnung auf Basis des Trend- und Prognosemodells werden kritische Lieferanten mit einem negativen Trend der Liefertreue priorisiert, so dass über diese quantitativen Assoziationsregeln kein neues Wissen generiert werden kann. Diese quantitativen Assoziationsregen können somit von einer weiteren Betrachtung ausgeschlossen werden. Die orange markierte Regel unterstützt als einzige der generierten, relevanten, quantitativen Assoziationsregeln die Neuartigkeit des Wissens, in dem diese das bisherige Wissen ergänzt. Diese Regel besagt:

Wenn die Termintreue Reklamationsbearbeitung zwischen 0 Prozent und 48 Prozent und die Termintreue der Angebotsabgabe zwischen 1 Prozent und 68 Prozent liegt, dann liegt die Liefertreue zwischen 0 Prozent und 14 Prozent.

Die Datenmuster der auf die Assoziationsregel zutreffenden Lieferanten enthalten eine hohe Menge an bereits durch die Trendberechnung aus Basis des Trend- und Prognosemodells als kritisch definierte Muster. Lieferanten mit einem als kritisch definierten Muster werden nach DUST [DUS18] als kritische Lieferanten bezeichnet (Kapitel 1.4 und Kapitel 4.3.1). Von den 27 Lieferanten, die als relevant markiert worden sind, haben 7 Lieferanten bereits einen negativen Trend der Liefertreue in ihrem Datenmuster. Sieben Lieferanten werden somit auf Basis der quantitativen Assoziationsregel als kritisch bezeichnet. Das macht einen Anteil von 26 Prozent in Bezug zur Gesamtheit der Lieferanten, auf die die quantitative Assoziationsregel zutrifft aus. Demnach ist es möglich, dass weitere Lieferanten, auf die diese quantitative Assoziationsregel ebenfalls zutrifft, kritisch werden können. Diese Lieferanten werden als potenziell kritische Lieferanten bezeichnet. Da potenziell kritische Lieferanten auf Basis der quantitativen Assoziationsregel erkannt worden sind, existiert ein Wissenszuwachs. Der Mehrwert der Assoziationsanalyse besteht somit aus einem Wissenszuwachs in Bezug auf potenziell kritische Lieferanten, die in einer Teilmenge das gleiche Datenmuster aufweisen, wie bereits als kritisch identifizierte Lieferanten.

Im vorliegenden Beispiel ist zunächst die Neuartigkeit der quantitativen Assoziationsregeln überprüft worden. Die weiteren Dimensionen der Interessantheit (Kapitel 4.6.5) Validität, Nützlichkeit und Verständlichkeit können nur in unternehmensspezifischen Praxistests geprüft werden. SCHOLL stellt in seinen Untersuchungen die ebenso These auf, „dass die Effektivität eines Vorhabens vom Ausmaß des Wissenszuwachses abhängt“. [SCH04] Für die vorliegende Arbeit bedeutet dies, dass der Wissenszuwachs anhand der im Lieferantensteuerkreis beschlossenen und danach erfolgreich durchgeführten Eskalationsmaßnahmen (Kapitel 4.6.6) gemessen werden kann.

Um die These von SCHOLL [SCH04] für die vorliegende Arbeit zu belegen, sind wiederum Langzeitstudien notwendig, um eine signifikante Menge an auswertbaren empirischen Daten zu erhalten. Eine einmalige, theoretische Analyse ohne einen iterativen Prozess, wie in der vorliegenden Arbeit ist nicht ausreichend. Möglich ist es ebenfalls, dass auf Basis der relevanten, quantitativen Assoziationsregeln sowie der empirischen Daten aus Langzeitstudien, wiederkehrende Muster für kritische Lieferanten definiert werden. Diese Muster werden mit den als relevant definierten, quantitativen Assoziationsregeln abgeglichen, um Übereinstimmungen zu erkennen. Trifft eine Regel mehrfach zu, wird unterstellt, dass der Wissenszuwachs besonders hoch ist.

Zum Finden von weiteren interessanten Datenmustern können auch Mindestwerte für die Interessantheitsmaße vorgegeben werden. VOSSEN [VOS08] nutzt beispielsweise in seinen Ausführungen einen geforderten Mindest-Support von 0,4 und eine Mindest-Konfidenz von 0,67. Eine abschließende Empfehlung für eine Grenze der Mindestmaße ist auf Basis weiterer praktischer Forschungsvorhaben noch ausstehend. Dies ist das Ergebnis von unternehmensspezifischen Langzeitstudien. Dabei kann über zwei Stufen vorgegangen werden:

1. Stufe: spezifische Einstellung der Interessantheitsmaße innerhalb eines Unternehmens
2. Stufe: Konsolidierung der Ergebnisse aus der 1. Stufe mehrerer Unternehmen

Erfolgt die Konsolidierung mehrerer unternehmensspezifischer Ergebnisse, kann möglicherweise eine generische Aussage über die Einstellung der Interessantheitsmaße der Dimensionen der Interessantheit im Bereich der Risikofrüherkennung in externen Wertschöpfungsnetzwerken getroffen werden.

Im Gegensatz zu bisher postulierten Lieferantenbewertungsverfahren (Kapitel 2.3) hat der in der vorliegenden Arbeit konzipierte und analysierte Prozess des Data Mining auf Basis der Verfahren Trendberechnung auf Basis des Trend- und Prognosemodells, Clusteranalyse, Assoziationsanalyse und Relevanzprüfung folgende Vorteile:

- Hypothesenfreiheit des Prozesses, womit der Fokus der Lieferantenbewertung nicht von vornherein auf kritische Lieferanten beschränkt ist
- Frühzeitiges Erkennen von potenziell kritischen Lieferanten, auf Grund der Zusammensetzung verschiedener Datenmuster in den interessanten Assoziationsregeln
- Skalierbarkeit der kombinierten Verfahren Trendberechnung auf Basis des Trend- und Prognosemodells, Cluster- und Assoziationsanalyse sowie Relevanzprüfung je nach Größe der Lieferantenbasis
- Gleichzeitige Verwendung von leistungsbeschreibenden und nicht-leistungsbeschreibenden Attributen innerhalb einer Lieferantenbewertung
- Verarbeitung von nicht-leistungsbeschreibenden Attributen, die in den Attributsausprägungen einen Text enthalten
- Verarbeitung einer unbegrenzten Menge an Attributen sowie lieferantenspezifischen Attributsausprägungen, da die Assoziationsanalyse nicht auf eine Attributsanzahl limitiert ist
- Automatisierbarkeit der Verfahren Trendberechnung auf Basis des Trend- und Prognosemodells, Cluster- und Assoziationsanalyse, da keine Softfacts verwendet werden
- Reproduzierbarkeit der Ergebnisse, auch nach einem langen Zeitraum

Auf dieser Basis wird ein bereichsübergreifendes und ganzheitliches Wissen über die Lieferantenbasis generiert, um frühzeitig potenzielle Risiken zu finden, was aber nicht heißt, dass diese identifizierten möglichen Risiken auch tatsächlich eintreffen werden. Doch das Wissen über die Möglichkeit des Eintretens von Risiken im externen Wertschöpfungsnetzwerk bietet einen Wettbewerbsvorteil gegenüber den bisher in der Praxis genutzten Verfahren.

7 Zusammenfassung und Ausblick

Der Einsatz der Ressource Wissen bestimmt zunehmend die unternehmerische Wettbewerbsfähigkeit [NOR11]. Dabei ist die Volatilität der Wissensbasis eines Unternehmens sehr hoch. Dieses Phänomen wird durch die kontinuierlich hohe Daten- und Informationsflut verstärkt [LEH12]. Es ist somit das Ziel, dieses Wissen zum einen effizient zu generieren und zum anderen durch den Nutzen des Wissens Wettbewerbsvorteile zu erhalten.

Wie das Wissen zur Steuerung der externen Wertschöpfungsnetzwerke in einem standardisierten Prozess effizient und automatisiert generiert wird, ist in der vorliegenden Arbeit bereits diskutiert worden. In diesem Kapitel werden nun die Forschungsergebnisse zusammengefasst. Weiterführende Forschungsvorschläge runden die vorliegende Arbeit ab.

7.1 Zentrale Forschungsergebnisse

Im Rahmen dieser Forschungsarbeit ist zunächst als Ausgangspunkt der Bedarf nach einer ganzheitlichen Wissensgenerierung im Bereich des Lieferantenmanagements im Kapitel 2 erörtert worden. Die Literaturrecherche bestätigt ein derzeitiges Methodendefizit, um Risiken innerhalb der externen Wertschöpfungsnetzwerke frühzeitig und effizient zu entdecken. Das Ziel eine Methode zu identifizieren, die in der Lage ist, Wissen durch die Nutzung von Datenmustern zu erkennen, ist mit dem Data Mining gelungen. Im Kapitel 3 wird das TSM als Grundlage für den Managementprozess zur Sicherung und Wiederherstellung der Leistungserbringung der Lieferanten genutzt. Darauf aufbauend ist in Kapitel 4 das Gesamtmodell zur Datenmustererkennung im TSM auf Basis des Wissensmanagements konzipiert und in Kapitel 6 anhand ausgewählter Daten rechnerisch validiert worden. Kapitel 5 erörtert die zugehörige Datenqualität. Somit sind in der vorliegenden Arbeit verschiedene Themengebiete miteinander verknüpft worden. Dazu zählen:

- Lieferantenmanagement mit der Aufgabe der Lieferantenbewertung
- Total Supplier Management
- Wissensmanagement
- Data Mining

Durch die Verarbeitung großer Datenmengen der Lieferantenbasis ist eine systemische Unterstützung notwendig. Bisherige Data Mining IT-Systeme können jedoch die in der vorliegenden Arbeit genutzte quantitative Assoziationsanalyse nicht abbilden [NOR12, KOT15]. Somit ist die Konzeptionsprüfung mit Hilfe einer eigenen, im Rahmen der Arbeit entwickelten, Lösung, dem *Analyzer*, vorgenommen worden. Der *Analyzer* stellt die pilothafte Umsetzung des Konzepts zur frühzeitigen Risikoidentifikation auf Basis von quantitativen Assoziationsregeln dar und bietet die Möglichkeit die Machbarkeit, des Konzepts zu prüfen. Ziel ist es, mit Hilfe einer einfachen und rein funktionalen IT-Pilotunterstützung die quantitative Assoziationsanalyse im Rahmen großer Datenmengen darzustellen.

In dieser Arbeit sind in den vorangegangenen Kapiteln verschiedene Forschungsergebnisse erarbeitet worden. Diese Forschungsergebnisse werden nun im Folgenden zusammengefasst und kritisch gewürdigt.

Supplier Risk Monitoring

Neue Komplexitätsform der Lieferantenbewertung

Bisher publizierte Lieferantenbewertungsverfahren werden in Kapitel 2 erörtert. Dabei wird eine stufenweise Steigerung der Komplexität von einer eindimensionalen Betrachtung einzelner Lieferantenbewertungsverfahren ausgehend zur Vernetzung von Informationen zu Wissen beschrieben. Diese Vernetzung verschiedener Informationen zu Wissen ist nur durch die Kombination verschiedener Lieferantenbewertungsverfahren möglich. Dadurch werden Synergien gebündelt, was einen positiven Effekt auf eine Wissensgenerierung auf Basis großer Datenmengen hat. Eine beschränkte Lieferantenbewertung auf Teilmengen der Lieferantenbasis muss somit nicht mehr durchgeführt werden. Erwartungsgemäß sollten sich zukünftige Studienergebnisse, wie die von DUST UND WILDE [DUS16d], in Bezug auf die bewertete Lieferantenbasis positiv entwickeln.

Wissensmanagement als Grundlage einer Lieferantenbewertung

Die zu Beginn der Arbeit von JANKER [JAN08] beschriebene Forderung nach einer Neugestaltung des Wissensmanagements für den Bereich des Lieferantenmanagements ist in Kapitel 4 aufgearbeitet worden. Das Wissensmanagement ist dabei als ganzheitliches Konzept mit dem Workflow des TSM sowie dem Prozess des Data Mining für eine präventive Lieferantenbewertung als durchgängiges Steuerungskonzept verbunden worden. Es hat sich herausgestellt, dass das Wissensmanagement mit den acht Bausteinen (Kapitel 4.1) als Grundlage eines Prozesses zur Lieferantenbewertung geeignet ist. Somit kann das Wissen über die Lieferanten nicht nur strukturiert generiert, sondern auch unter anderem bewertet und identifiziert, verteilt und genutzt werden. Ein Wissensverlust über die Leistungserbringung von Lieferanten wird somit minimiert.

Data Mining als präventives Element zur Steuerung der externen Wertschöpfungsnetzwerke

Um Risiken im externen Wertschöpfungsnetzwerk mit Hilfe von Datenmustern zu erkennen, bietet das Data Mining einen standardisierten Prozess zur Wissensgenerierung. Es kann somit eine bereichsübergreifende Entscheidungsgrundlage zur Absicherung oder Wiederherstellung der Lieferantenleistung erstellt werden. Dieses generierte Wissen über Risiken im externen Wertschöpfungsnetzwerk ist somit in einen standardisierten Workflow zur Risikominimierung und -vermeidung eingebunden. Die Prävention innerhalb der Lieferantenbewertung entsteht durch ein von MODER [MOD08] und auch JUNG [JUN14] gefordertes Frühwahnsystem. Dies wird in der vorliegenden Arbeit mit Hilfe der Verbindung der Trendberechnung auf Basis des Trend- und Prognosemodells und den ermittelten Datenmustern der Assoziationsanalyse theoretisch ermöglicht, wobei die praxisnahe Nutzung im Sinne des Wissenszuwachses nicht abschließend belegt werden kann.

Wissensgenerierung als ganzheitlicher Prozess

Vernetzte Informationen und somit die Generierung von Wissen über die Leistungserbringung von Lieferanten ist durch die immer stärker werdende Komplexität der externen Wertschöpfungsnetzwerke von hoher Bedeutung. Dabei reichen herkömmliche Lieferantenbewertungsverfahren nicht mehr aus, wie in Kapitel 2 dargestellt worden ist. Vielmehr ist ein ganzheitlicher Prozess zu installieren, der die Möglichkeit einer Automatisierung auf Grund der wachsenden Datenmengen bietet. Dabei wird die Datenbasis auf ihre Datenqualität überprüft.

Nachweis der Machbarkeit des angewendeten Konzeptes

Auf Basis der Konzeptionsprüfung ist die generelle Machbarkeit des erarbeiteten Konzeptes theoretisch nachgewiesen worden. Das über den Prozess des Data Mining generierte Wissen ist effizient reproduzierbar und kann in der Praxis zur Steuerung der externen Wertschöpfungsnetzwerke eingesetzt werden. Es bleibt jedoch als Ausblick die Frage offen, wann der initiale Lernprozess innerhalb des Konzeptes abgeschlossen ist. Dieser initiale Lernprozess des Konzeptes hat das Ziel, die Ergebnisse und somit das Finden potenziell kritischer Lieferanten, stetig zu verbessern, so dass die gefundenen Lieferanten eine hohe Relevanz für eine präventive Maßnahmendefinition zur Erhaltung oder Wiederherstellung der Lieferantenleistungsfähigkeit hat. Auch wie der lernende Prozess konkret anhand der Interessantheitsmaße ausgestaltet werden kann, ist in folgenden Arbeiten zu erörtern. Dabei empfiehlt es sich, in einem zweistufigen Vorgehen in einer Langzeitstudie mit Daten aus der Praxis zu arbeiten:

1. Stufe: Langzeitstudie auf Basis der Ergebnisse eines Unternehmers
2. Stufe: Langzeitstudie auf Basis der Ergebnisse verschiedener Unternehmen

Nach der 2. Stufe ist es dann möglich, eine generische Aussage über die Wirksamkeit des lernenden Prozesses zu formulieren, um damit einen Indikator über den Wissenszuwachs im Rahmen der als relevant definierten Assoziationsregeln zu erhalten.

Ausgehend von den formulierten zentralen Forschungsergebnissen ist der Neuigkeitsgehalt der vorliegenden Arbeit entsprechend hoch. Bezugnehmend zu dem in Kapitel 1 formulierten Forschungsbedarf werden die dabei genannten Forschungsvorhaben nun mit den entsprechenden Alleinstellungsmerkmalen der vorliegenden Arbeit belegt. Tabelle 7-1 dient dem strukturierten Überblick.

Tabelle 7-1: Bezug zwischen Forschungsvorhaben und Alleinstellungsmerkmalen der vorliegenden Arbeit
Quelle: Eigene Darstellung

Forschungsvorhaben aus Kapitel 1	Alleinstellungsmerkmal der vorliegenden Arbeit
Das Wissensmanagement wird durch ein ganzheitliches Konzept mit dem Workflow des Total Supplier Managements sowie dem Prozess des Data Mining für eine präventive Lieferantenbewertung als durchgängiges Steuerungskonzept verbunden.	Kombination der der verschiedenen Themenbereiche: • Aufgaben des Wissensmanagements • TSM-Workflow • Neu entwickelter Data Mining-Prozess • Neu entwickelter Prozess der Lieferantenbewertung

Tabelle 7-1: Bezug zwischen Forschungsvorhaben und Alleinstellungsmerkmalen der vorliegenden Arbeit (Fortsetzung)

Forschungsvorhaben aus Kapitel 1	• **Alleinstellungsmerkmal der vorliegenden Arbeit**
Es wird im Rahmen der Wissensgenerierung eine bereichsübergreifende Entscheidungsgrundlage erarbeitet. Dieses generierte Wissen über Risiken im externen Wertschöpfungsnetzwerk wird somit in einen standardisierten Workflow zur Risikominimierung und -vermeidung eingebunden.	Kombination verschiedener Data Mining-Prozesse zu einem neuen Data Mining-Prozess: • KDD • SEMMA • CRISP-DM
Es wird ein Prozess der Lieferantenbewertung erarbeitet, damit präventive Maßnahmen zur Absicherung oder Wiederherstellung der Lieferantenleistung initiiert werden können.	Kombination der Lieferantenbewertungsverfahren zu einem neu entwickelten Prozess der Lieferantenbewertung: • Trendberechnung auf Basis des Trend- und Prognosemodells • Clusteranalyse • Assoziationsanalyse • Relevanzprüfung

Auf Basis der in Tabelle 7-1 zusammengefassten Alleinstellungsmerkmale der vorliegenden Arbeit ist ein signifikanter Mehrwert durch die vorliegende Forschungsarbeit bestätigt worden. Aus der Literatur ist ein solches Vorgehen nicht bekannt.

Die bestehende Zusammenarbeit zwischen Lieferant und Abnehmer wird sich durch die stetige Veränderung der externen Wertschöpfungsnetzwerke weiterhin verändern [MÜL18, WIL18b, HER19]. Somit werden auch zukünftigen Forschungstätigkeiten hohe Bedeutung zukommen. Ausgehend von den zentralen Forschungsergebnissen der vorliegenden Arbeit werden nun im folgenden Kapitel mögliche weiterführende Forschungsvorschläge erläutert.

7.2 Weiterführende Forschungsvorschläge

Das Data Mining ist ein iterativer Prozess zur Optimierung der Methode. Für ein hinreichend genaues Ergebnis reicht es oft nicht aus, den Prozess nur ein- oder zweimal zu durchlaufen. Das gewünschte Ergebnis im ersten Anlauf zu erreichen ist praktisch nicht möglich [CLE16]. Somit könnte in einer Langzeitstudie die Anwendbarkeit zusätzlich validiert werden.

Auf der Grundlage der vorliegenden Arbeit kann weiterführend geforscht werden. Im Folgenden werden mögliche zukünftige Forschungsvorschläge kurz skizziert. Diese haben nicht den Anspruch auf eine vollständige Darstellung des Vorhabens. Vielmehr sollen sie mögliche Forschungsfelder anreißen und anregen, ohne den Forschungsbedarf bei den einzelnen Themen in der Tiefe geprüft zu haben.

Erweiterung des Data Mining Modells um das Text Mining

Bisher sind in der vorliegenden Arbeit Daten aus Datenbanken im Rahmen des Data Mining verarbeitet worden. Neben dem Data Mining gibt es weitere Möglichkeiten, Datenmuster zu erkennen. Eine „Methode zur Entdeckung von Mustern in unstrukturierten Texten“ [GAB09] wird als Text Mining bezeichnet. Es wäre somit denkbar, innerhalb des erarbeiteten Prozesses das Data Mining und das Text Mining zu verbinden. Leistungsbeschreibende und nicht leistungsbeschreibende Daten werden um Daten aus Textquellen erweitert. Somit wäre es möglich, dass auch in Bezug auf Risikoereignisse (Kapitel 3), die bisher im Data Mining nicht betrachtet worden sind, über einen standardisierten Prozess Wissen für ein präventives Handeln generiert werden kann.

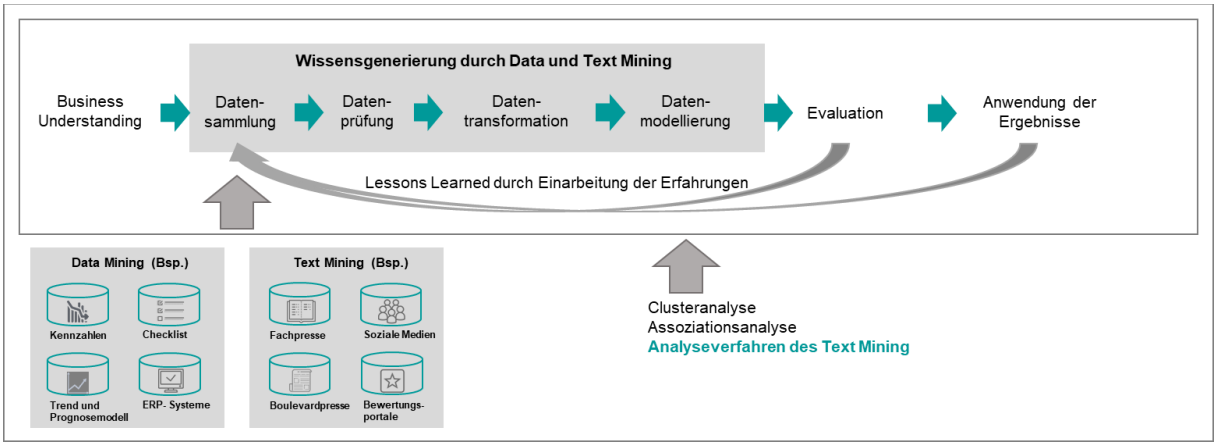


Bild 7-1: Erweiterung des Data Mining um das Text Mining
Quelle: Eigene Darstellung

Erste Nutzungsmöglichkeiten sowie der generelle Einsatz von Texten der sozialen Medien im Bereich des Lieferantenrisikomanagements sind von HOFFMANN UND ROLAND [HOF13] erörtert worden. Die Autoren postulieren, dass im Einsatz von sozialen Medien beim frühzeitigen Erkennen von Risiken viel Potential verborgen ist, da somit der Zugang zu weiteren Informationen gewährleistet wird. Daneben konstatiert auch SCHUH [SCH14B], dass es durch die immer weiter wachsenden Datenmengen und differenten Datenquellen eine Erfordernis gibt, diese für die Wissensgenerierung nutzbar zu machen. Es wäre somit zu prüfen, ob zukünftig alle zur Verfügung stehenden Daten für eine Datenmustererkennung in Betracht kommen.

Erweiterung des Data Mining Modells um eine Prozesskostenstruktur

Die Kosten im Lieferantenmanagement sind oft in den Gemeinkosten verborgen [HEL16, DUS18]. Die expliziten Kosten zur Steuerung der externen Wertschöpfungsnetzwerke sind laut der Studie von DUST UND WILDE [DUS16d] nur einem Viertel der teilnehmenden Unternehmen bekannt. Es scheint zwar einen hohen Bedarf zu geben, die entstandenen Kosten regelmäßig zu überprüfen, doch bislang fehlen geeignete Strukturen zur Prozesskostenerfassung [DUS16e]. Ein Beispiel zur Prozesskostenüberwachung verschiedener Lieferanten (L_x) ist in Bild 7-2 visualisiert.

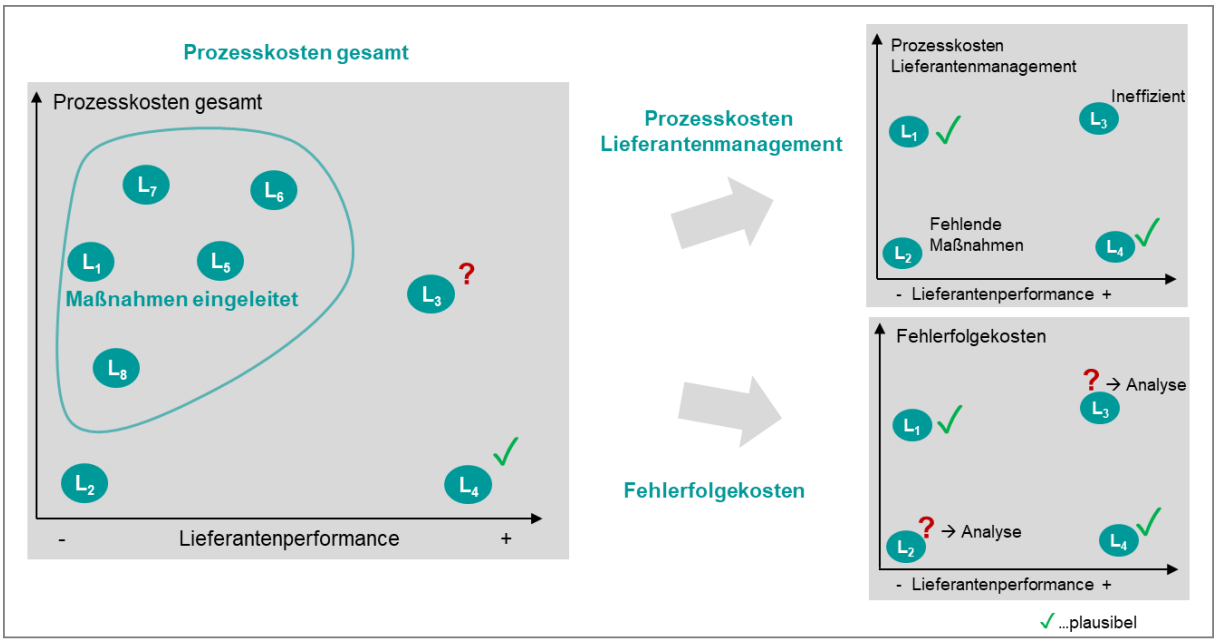


Bild 7-2: Prozesskostencockpit
Quelle: [DUS16e]

Die Grafik zeigt beispielhaft ein Prozesskostencockpit zur Erfassung der anfallenden Kosten im Lieferantenmanagement. Dabei wird die Leistungserbringung (leistungsbeschreibende Daten) eines Lieferanten in Bezug zu den anfallenden Prozesskosten gesetzt. Die in Beziehung gesetzten Daten werden auf Plausibilität hin überprüft. Hat einerseits ein Lieferant eine geringe Leistungserbringung und weist auch geringe Prozesskosten auf, fehlen mit hoher Wahrscheinlichkeit Maßnahmen zur Wiederherstellung der Leistung. Ist andererseits der Lieferant in seiner Leistungserbringung sehr gut und hat einen hohen Kostenfaktor, ist entweder ein Lieferantenentwicklungsprojekt erfolgreich abgeschlossen worden oder die Maßnahmen, die durchgeführt werden, sind ineffizient.

Werden die Ergebnisse des Data Mining nun um die Erkenntnisse der Prozesskostenbetrachtung erweitert, kann die Grundlage für die Managemententscheidungen im TSM zusätzlich um eine wirtschaftliche Betrachtung bereichert werden. Damit wäre eine Betrachtung sowohl von qualitativen (Leistung) und zeitlichen (Trendberechnung auf Basis des Trend- und Prognosemodells) Aspekten als auch von den Prozesskosten möglich. Bislang ist eine Betrachtung und Optimierung der Prozesskosten oft als eigenständige Analyse im Rahmen einer ABC-Lieferanteneinteilung oder des TCO postuliert worden [HOF09, NAR12, HEL16].

Aufbrechen der Datensilostrukturen mit Hilfe von Graphdatenbanken

„An Silodenken scheitert das Wissensmanagement in vielen Unternehmen“ [BLO12]. Die Fachbereiche haben oft ihre isolierten IT-Systeme, wodurch ein Datenaustausch nur manuell, über Systembrüche oder vollkommen unmöglich ist. Doch für ein ganzheitliches Wissensmanagement sowie die Absicherung der Datenqualität ist eine unternehmensweit einheitliche Sicht auf die Daten notwendig (Kapitel 4 und 5). Somit müssen die einzelnen Datensilos miteinander vernetzt werden [STA17]. Bei der Lösung dieser Herausforderung kann eine Graphdatenbank helfen (Bild 7-3).

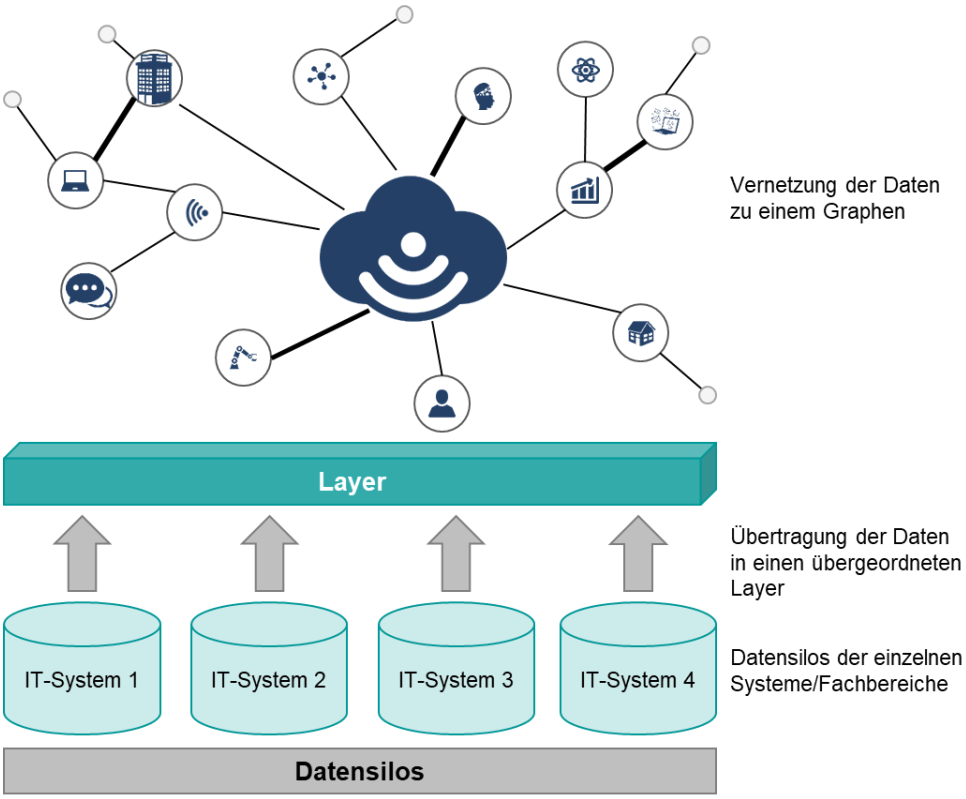


Bild 7-3: Schema einer Graphdatenbank
Quelle: Eigene Darstellung

Die Daten verschiedener Datenquellen werden als Graph in einer Datenbank dargestellt. Graphen können in gerichtet und ungerichtet unterteilt werden [HER00]. Mit dieser Technologie werden Abhängigkeiten zwischen Knoten visualisiert und Beziehungen bewertet. Durch das Erkennen von Ähnlichkeiten innerhalb der graphischen Darstellung wird explizites in implizites Wissen umgewandelt [TOM14].

Der Vorteil dieser Vorgehensweise liegt in der einfachen Implementierung. Die IT-Infrastruktur der Datensilos kann erhalten bleiben, wobei über den Layer dennoch alle Daten miteinander vernetzt sind. Diese vernetzten Daten könnten dann als Ausgangspunkt für das Data Mining im Rahmen der Datensammlung genutzt werden (Kapitel 4). Bisher ist jedoch keine wissenschaftliche Forschungsaktivität zur Erprobung eines Datengraphen in Verbindung mit einer optimalen Steuerung der externen Wertschöpfungsnetzwerke bekannt.

7.3 Schlusswort

„Wir ertrinken in Informationen und hungern nach Wissen."
John Naisbitt (*1929)

Die vorliegende Arbeit orientiert sich an strukturierten Prozessen zur Wissensgenerierung und -nutzung, um eine effiziente und effektive Steuerung der externen Wertschöpfungsnetzwerke zu erhalten. Bislang gibt es bereits eine Vielzahl von Bemühungen, Daten im Rahmen des Wissensmanagements strukturiert nutzbar zu machen [LEH12]. Die Technologie, die Methoden und Prozesse sind soweit, eine Vernetzung von Daten und Informationen zu Wissen möglich zu machen. Das hat die vorliegende Forschungsarbeit bestätigt.

„Daten, Informationen und Wissen sind wertvolle Ressourcen, die geplant, organisiert und verwertet werden müssen" [BOD03]. Wird diese Aussage auf das Wissen zur Steuerung der externen Wertschöpfungsnetzwerke adaptiert, ist ein standardisierter Prozess mit Elementen des Wissensmanagements, des Data Mining sowie des TSM notwendig. Doch nun stellt sich zum einen die Frage nach dem Nutzen und zum anderen nach den Herausforderungen und auch dem Aufwand, wie beispielsweise den Prozesskosten, bei der Einführung eines solchen Gesamtmodells.

Mit der Umsetzung des in dieser Arbeit beschriebenen Modells ist es möglich, dass jederzeit fachbereichsübergreifend alle notwendigen Informationen für das benötigte Wissen in Bezug auf eine frühzeitige Risikoerkennung innerhalb der Lieferantenbasis zur Verfügung stehen. Um das Wissen dann als Wettbewerbsfaktor gegenüber Marktbegleitern zu nutzen, sind folgende Faktoren entscheidend:

- Geschwindigkeit und somit frühzeitige Risikoerkennung durch explizites Wissen
- Präventive Maßnahmendefinition bei drohenden Risiken
- Zügiges Durchführen, bei definierten Maßnahmen
- Kontinuierliche Einarbeitung und Überführung des impliziten Wissens in explizites Wissen

Über die Vorteile von Sammlung, Analyse und Nutzung großer Datenmengen mit standardisierten Prozessen sind bisher zahlreiche Studien und Whitepaper veröffentlicht worden. In einer Studie von TROST [TRO15] ist ermittelt worden, dass mit Hilfe von Big Data die Prognosegenauigkeit um 48 Prozent steigt. Doch ebenso besagt die Studie, dass viele Unternehmen (94 Prozent) bisher keine Konzepte zur Nutzung von großen Datenmangen eingeführt haben [TRO15]. Auch die Studie von DUST UND WILDE [DUS16d] zeigt, dass nur wenige Unternehmen in der Lage sind, standardisiert und prozessorientiert Daten zu sammeln, z.B. für Prognosen zu analysieren und auch für die Definition von Maßnahmen und deren Umsetzung zu nutzen.

Das Wissen um Risiken ist nicht allein die Lösung [BOG17]. Die Frage ist somit, warum ganzheitliche, standardisierte und fachbereichsübergreifende Konzepte nicht umgesetzt werden können bzw. welche Hürden es bei der Umsetzung zu beachten gibt.

„Die Informationsbasis ist der zentrale Bereich eines jeden Risikomanagements" [HOF13]. Doch HENKE [HEN09] zeigt, dass bisher viele Unternehmen eine unzureichende Qualität oder fehlende Verfügbarkeit der notwendigen Daten haben.

Allgemein scheitern Vorhaben im Bereich des Wissensmanagements oft, weil nur einzelne Elemente implementiert werden, ohne diese in einen Workflow zu integrieren [HEI14]. BULLINGER ET AL. [BUL97] werden in ihren Ausführungen detaillierter und fassen die Barrieren einer Wissensmanagementeinführung in folgende Punkte:

- Silodenken von Abteilungen eines Unternehmens und folglich Wissen als (persönliches) Eigentum
- Fehlende standardisierte Prozesse und Methoden zum Wissenserwerb, -speicherung und -transfer
- Fehlende Schnittstellen zwischen IT-Systemen
- Inkonsistente Daten
- Wissensfluktuation und somit fehlendes Know-how auf Grund von Personalfluktuation

Eine weitreichende Diskussion zu Herausforderungen im Umgang mit Wissen ist auch in LEHNER [LEH12] zu finden. Zusammenfassend kann festgehalten werden, dass letztendlich immer die Menschen in den Unternehmen bei Veränderungen mitgenommen werden müssen. Die Methoden, Prozesse und Technologie können nur die Grundlage für die durchzuführenden Prozesse darstellen. Die Methoden, die Prozesse und die Technologie müssen jedoch von den Führungskräften und den Mitarbeitern möglichst bereichsübergreifend angewendet werden. Ein ganzheitliches Changemanagement für die Veränderung bietet dafür die notwendigen Rahmenbedingungen [SCH06a, ROS12].

Somit ist das Wissensmanagement eine bereichsübergreifende Management- und damit Führungsaufgabe. Gibt das Management keine klaren Ziele vor, was es als Entscheidungsgrundlage erwartet, werden weiterhin lediglich Informationen aus der immer größer werdenden Datenbasis generiert. Das Wissen entsteht erst durch die Vernetzung der Informationen. Doch für diese Vernetzung geben die Fachbereiche einen Teil ihrer abgeschotteten Datensilos auf und werden transparent. Die Frage ist demnach, ob diese Transparenz von den Menschen zugelassen wird. Schafft es das Management, die Kollegen, Führungskräfte und Mitarbeiter auf dem Weg der Vernetzung mitzunehmen? Das ist keine einfache Aufgabe.

Auf Grund der großen Datenmengen wird auch zukünftig immer öfter die Frage nach dem „Was passiert?“ als nach dem „Warum passiert es?“ gestellt werden. Unternehmen müssen schnell auf neue Anforderungen reagieren können. In diesem Zug stellt sich die Frage, wer das notwendige Wissen schneller generieren kann.

Diese Fragen kann die vorliegende Forschungsarbeit in diesem Rahmen nicht beantworten. Doch die immer größeren Datenmengen machen ein Um- und Neudenken bei deren Nutzung erforderlich. Das schnelle und effizient generierte Wissen über die externen Wertschöpfungsnetzwerke wird dabei zukünftig noch mehr als bislang zum absoluten Wettbewerbsvorteil beitragen.

Glossar

Begriff	Erläuterung
B2B-Portal	Internetportal zum Handeln Geschäftsbeziehungen
Beschaffungsmarktforschung	Systematische Ermittlung zur Erweiterung oder Reduzierung der Lieferantenbasis
csv-Dateiformat	Spezifischer Aufbau einer Datei zur Speicherung oder zum Austausch einfach strukturierter Daten
Effektivität	Verhältnis zwischen einer Tätigkeit und dem bewirkten Resultat
Effizienz	Einsparpotenzial
Eingriffsgrenze	Spezifisch definierte Grenze zum Start von Maßnahmen
Einkaufscontrolling	Unternehmerisches Führungssystem zur Kontrolle der Einkaufsaktivitäten
Einstandspreis	Bezugspreis zum Erwerb von Waren
Task Force	Reaktive Maßnahmeneinleitung bei Leistungsdefiziten von Lieferanten
Handel	Kauf und/oder Verkauf verschiedener Waren und/oder Dienstleistungen
Iteratives Vorgehen	Wiederholendes Vorgehen gleicher oder ähnlicher Prozesse zur Annäherung an eine Lösung
IT-Tools	IT-Programme zur Lösung spezieller Aufgaben
Kardinalitäten	Menge der Beziehungen zwischen Merkmalen in verschiedenen Tabellen oder zwischen Datensätzen
Kritischer Lieferant	Lieferant, der die Anforderungen des Kunden nicht erfüllt
Lieferantenbasis	Gesamtheit aller Lieferanten eines Unternehmens
Materialgruppenstrategie	Definition und Umgang mit Gruppen gleicher oder ähnlicher Waren
Materialgruppenmanagement	Führung und Kontrolle im Umgang mit Gruppen gleicher oder ähnlicher Waren

Begriff	Erläuterung
Materialwirtschaft	Verwaltung der zeitlichen, mengenmäßigen, qualitativen und räumlichen Planung und Steuerung der Warenbewegung
Megatrend	Trend mit einem hohen gesellschaftlichen, ökonomischen, politischen und technologischen Einfluss über einen Zeitraum von über zehn Jahren [NAI92]
Metadatenmanagement	Geordnete Datenhaltung von strukturierte Daten, die Informationen über Merkmale anderer Daten enthalten
Prognose	Zukunftsbezogene Aussage über einen Sachverhalt auf der Grundlage von Erfahrungen und theoretischen Ergebnissen
Prozessanalyse	Standardisierte Untersuchung von Prozessen, um Schwachstellen zu erkennen
Risikomanagement	Aktivitäten innerhalb eines Unternehmens im Umgang mit Risiken [GLE05]
Robuste Daten	Fähigkeit der Daten einer Beeinflussung durch Ausreißer oder anderen Veränderungen standzuhalten
Standardabweichung	„Maß für die Streuung eines zufälligen Wertes um den Mittelwert“ [MÜL10]
Supply Relationship Management	Bereich des Supply Chain Managements, der sich mit der Auswahl, Steuerung, Kontrolle, Entwicklung und -Integration der Lieferanten beschäftigt
Testdaten	Daten zum Testen eines Systems oder Programms
Trainingsdaten	Daten zur Verbesserung eines Systems oder Programms im Rahmen des maschinellen Lernens
Warengruppenstrategie	Strategischer Umgang mit verschiedenen Waren- oder Produktgruppen innerhalb der Beschaffung in einem Unternehmen; Synonym für Materialgruppenstrategie
Wertschöpfung	Gesamtheit der geschaffenen Werte
Workflow	Vollständige oder teilweise Standardisierung eines Geschäftsprozesses, in dem Dokumente, Informationen oder Aufgaben entlang des Prozesses zur Bearbeitung weitergegeben werden [HEI02]

Begriff	Erläuterung
Workflow-Management-System	System, „das softwareunterstützt die Definition, den Entwurf und die Ablaufsteuerung von ausführbaren Workflows ermöglicht“ [HEI02].

Literaturverzeichnis

ADA97 Adam, D.: Planung und Entscheidung. Wiesbaden: Gabler, 1997.

ADR98 Adriaans, P.; Zantinge, D.: Data Mining. Harlow: Addison-Wesley, 1998.

ALE08 Alex, B.; Becker, D.; Stratmann, J.: Ganzheitliches Wissensmanagement und wertorientierte Unternehmensführung. In: Wissensmanagement. Hrsg.: Götz, K. Mering: Rainer Hampp, 2008, S. 47 - 69.

APE15 Apel, D.; Behme, W.; Eberlein, R.; Merighi, C.: Datenqualität erfolgreich steuern. Heidelberg: dpunkt., 2015.

APP11 Appelfeller, W.; Buchholz, W.: Supplier Relationship Management. Wiesbaden: Gabler, 2011.

ARN08a Arndt, H.: Supply Chain Management. Wiesbaden: Gabler, 2008.

ARN08b Arnold, D.; Isermann, H.; Kuhn, A.; Tempelmeier, H.; Furmans, K. (Hrsg.): Handbuch Logistik. Berlin: Springer, 2008.

ARN10 Arnolds, H.; Heege, F.; Röh, C.; Tussing, W.: Materialwirtschaft und Einkauf. Wiesbaden: Gabler, 2010.

AZE08 Azevedo, A.; Santos, M.F.: KDD, SEMMA and CRISP-DM: A parallel Overview. 2008. URL: http://recipp.ipp.pt/bitstream/10400.22/136/3/KDD-CRISP-SEMMA.pdf (Zugriff: 2017-05-20).

BAC10 Bacher, J.; Pöge, A.; Wenzig, K.: Clusteranalyse. München: Oldenbourg, 2010.

BAC16 Backhaus, K.; Erichson, B.; Plinke, W.; Weiber, R.: Multivariate Analysemethoden. Berlin, Heidelberg: Springer Gabler, 2016.

BAE08 Baecker, D.: Die "andere Seite" des Wissensmanagements. In: Wissensmanagement. Hrsg.: Götz, K. Mering: Rainer Hampp, 2008, S. 97 - 108.

BAL11 Ballod, M.: Informationen und Wissen im Griff. Bielefeld: Bertelsmann, 2011.

BAN16 Bange, C.: Werkzeuge für analytische Informationssysteme. In: Analytische Informationssysteme. Hrsg.: Gluchowski, P.; Chamoni, P. Berlin, Heidelberg: Springer Gabler, 2016, S. 97 - 126.

BAU14 Baumöl, U.; Berlitz, P.-D.: Big Data als Entscheidungsunterstützung: Herausforderungen und Potenziale. In: Controlling und Big Data. Hrsg.: Leyk, J. et al. Freiburg: Haufe, 2014, S. 159 - 176.

BEE03 Beekmann, F.: Stichprobenbasierte Assoziationsanalyse im Rahmen des Knowledge Discovery in Databases. Wiesbaden: Deutscher Universitätsverlag, 2003.

BEL02 Bellmann, K.: Produktion und Beschaffung - Management einer innerbetrieblichen Schnittstelle. In: Handbuch industrielles Beschaffungsmanagement. Hrsg.: Hahn, D.; Kaufmann, L. Wiesbaden: Gabler, 2002, S. 361–379.

BEN01 Bensberg, F.: Web Log Mining als Instrument der Marketingforschung. Wiesbaden: Deutscher Universitätsverlag, 2001.

BIE98 Biethahn, J.; Hönerloh, A.; Kuhl, J.; Leisewitz, M.-C.; Nissen, V.; Tietze, M. (Hrsg.): Betriebswirtschaftliche Anwendungen des Soft Computing. Wiesbaden: Vieweg+Teubner, 1998.

BIR11 Birkenbihl, V. F.: Trotzdem lehren. München: mvg, 2011.

BLE15 Bleymüller, J.; Weißbach, R.: Statistik für Wirtschaftswissenschaftler. München: Vahlen, 2015.

BLO98 Blobel, V.; Lohrmann, E.: Statistische und numerische Methoden der Datenanalyse. Wiesbaden: Vieweg+Teubner, 1998.

BLO12 Bloching, B.; Luck, L.; Ramge, T.: Data unser. München: Redline, 2012.

BLO18 Block, F.: Verknüpfung von DG-Indikatoren mit KPIs und Auswirkungen auf das Return on Invest. In: Daten- und Informationsqualität. Hrsg.: Hildebrand, K. et al. Wiesbaden: Springer Vieweg, 2018, 393–414.

BLU17 Blume, J.: Autohersteller eifern Paypal nach. 2017. URL: http://www.handelsblatt.com/my/finanzen/banken-versicherungen/mobilitaet-der-zukunft-autohersteller-eifern-paypal-nach/19781542.html?ticket=ST-205669-SrHlt2viTfkWFCBLlwjF-ap4 (Zugriff: 2017-12-04).

BME16 BME e.V.: Grundlagen des Einkaufs. Frankfurt am Main, 2016. URL: https://shop.bme.de/products/leitfaden-grundlagen-des-einkaufs?q%5Bproduct_group%5D=7&q%5Bproduct_subgroups%5D%5B%5D=14 (Zugriff: 2017-03-02).

BOD03 Bodendorf, F.: Daten- und Wissensmanagement. Berlin, Heidelberg: Springer, 2003.

BOD97 Bode, U.: Die Informationsrevolution. Wiesbaden: Gabler, 1997.

BOG05 Bogaschewsky, R.: Global Sourcing – wettbewerbsstrategische Bedeutung und methodische Unterstützung. In: Marketing im Perspektivenwechsel. Hrsg.: Fröhlich-Glantschnig, E. Berlin, Heidelberg: Springer, 2005, S. 31–58.

BOG17 Bogaschewsky, R.: Wir schaffen das! – Schaffen wir das? BMEnet Guide Beschaffungsdienstleister (2017), S. 3.

BOL07 Bolstorff, P. A.; Rosenbaum, R. G.; Poluha, R. G.: Spitzenleistungen im Supply Chain Management. Berlin, Heidelberg, New York: Springer, 2007.

BRO13 Brodersen, J.; Pfüller, K.: Information und Wissen als Wettbewerbsfaktoren. München: Oldenbourg, 2013.

BRU15 Brunelli, M.: Introduction to the Analytic Hierarchy Process. Cham, Heidelberg, New York, Dordrecht, London: Springer, 2015.

BUC03 Bucher, B.: Statistik. Zürich: Compendio Bildungsmedien, 2003.

BÜC98 Büchter, O.; Wirth, R.: Discovery of Association Rules over Ordinal Data: A New and Faster Algorithm and Its Application to Basket Analysis. In: Research and Development in Knowledge Discovery and Data Mining. Hrsg.: Wu, X.; Kotagiri, R.; Korb, K. B. Berlin, Heidelberg: Springer, 1998, S. 36–47.

BÜH08 Bühl, A.: SPSS 16 - Einführung in die moderne Datenanalyse. München, Boston, San Francisco: Pearson Studium, 2008.

BUL96 Bullinger, H.-J. (Hrsg.): Neue Organisationsformen im Unternehmen. Berlin: Springer, 1996.

BUL97 Bullinger, H.-J.; Wörner, K.; Prieto, J.: Wissensmanagement heute: Daten, Fakten, Trends. Stuttgart, 1997.

BUS14 Buschmacher, F.; Konrad, R.; Mußmann, B.; Weber, M.: Big Data-Projekte: Vorgehen, Erfolgsfaktoren und Risiken. In: Controlling und Big Data. Hrsg.: Leyk, J. et al. Freiburg: Haufe, 2014, S. 83 - 106.

CHA09 Chakrabarti, S.: Data Mining. Amsterdam: Morgan Kaufmann, 2009.

CHA98 Chamoni, P.: Ausgewählte Verfahren des Data Mining. In: Analytische Informationssysteme. Hrsg.: Chamoni, P.; Gluchowski, P. Berlin, Heidelberg, New York: Springer, 1998, S. 301–320.

CHA16 Chamoni, P.; Gluchowski, P.: Analytische Informationssysteme – Einordnung und Überblick. In: Analytische Informationssysteme. Hrsg.: Gluchowski, P.; Chamoni, P. Berlin, Heidelberg: Springer Gabler, 2016, S. 3–12.

CHR04 Christopher, M.; Peck, H.: Building the resilient Supply Chain. International Journal of Logistics Management (2004) Vol. 15, No. 2, S. 1–13.

CIO07 Cios, K. J.; Pedrycz, W.; Swiniarski, R. W.; Kurgan, L. A.: Data Mining. Boston MA: Springer, 2007.

CLE16 Cleve, J.; Lämmel, U.: Data Mining. Berlin: De Gruyter, 2016.

COR12 Cordts, S.: Datenqualität in Datenbanken. Heide: Mana-Buch, 2012.

COR98 Corsten, H.; May, C.: Produktionssteuerung für die Zementherstellung auf Grundlage Neuronaler Netze. In: Betriebswirtschaftliche Anwendungen des Soft Computing. Hrsg.: Biethahn, J. et al. Wiesbaden: Vieweg+Teubner, 1998, S. 181–198.

CRE17 Creusen, U.; Gall, B.; Hackl, O.: Digital Leadership. Wiesbaden: Springer Gabler, 2017.

DAN04	Dangelmaier, W.; Emmrich, A.; Gajewski, T.; Heidenreich, J.: Ein Referenzmodell zur Beschreibung der Geschäftsprozesse von After-Sales-Dienstleistungen. In: Referenzmodellierung. Hrsg.: Becker, J.; Delfmann, P. Heidelberg: Physica, 2004, S. 73–98.
DEM98	Deming, W. E.: Out of the crisis., Vol. 26. Cambridge, Massachusetts: Massachusetts Institute of Technology, 1998.
DGI07	DGIQ: IQ-Definitionen. 2007. URL: http://www.competence-site.de/?s=15+dimensionen (Zugriff: 2017-09-07).
DIN1319-1	DIN 1319-1, (01.1995) Grundlagen der Messtechnik.
DIN69901	DIN 69901, Projektmanagement – Projektmanagementsysteme.
DIN EN31010	DIN EN 31010, 2010. (11.2010) Risikomanagement – Verfahren zur Risikobeurteilung. Berlin: VDE Verlag.
DIN EN ISO9000	DIN EN ISO 9000, (2014) Qualitätsmanagementsysteme – Grundlagen und Begriffe. Berlin: Beuth.
DIN EN ISO9001	DIN EN ISO 9001, (2015) Qualitätsmanagementsysteme – Anforderungen. Berlin: Beuth.
DIN EN ISO9004	DIN EN ISO 9004 (2009): Leiten und Lenken für den nachhaltigen Erfolg einer Organisation – Ein Qualitätsmanagementansatz. Berlin: Beuth.
DIS04	Disselkamp, M.; Schüller, R.: Lieferantenrating. Wiesbaden: Gabler, 2004.
DÖL11	Dölle, J. E.: Lieferantenmanagement in der Automobilindustrie. Wiesbaden: Springer Gabler, 2011.
DRE00	Dreyer, H. W.: Lieferantentypspezifische Bewertung von Lieferleistungen. Frankfurt am Main: Peter Lang, 2000.
DUR11	Durst, S. M.: Strategische Lieferantenentwicklung. Wiesbaden: Springer Gabler, 2011.
DUS10a	Dust, R.; Schneider, K.: Im Netzwerk schlummert die Rendite. Qualität und Zuverlässigkeit Jg. 55 (2010) Ausg. 7, S. 27–30.
DUS10b	Dust, R.: Machtverhältnisse im Wandel. Beschaffung aktuell (2010) Ausg. S1/2010, S. 8 - 9.
DUS10c	Dust, R.; Gleisner, M.; Gürtler, B.: Total Supplier Risk Monitoring. Management und Qualität (2010) Ausg. 1-2, S. 27–29.
DUS11	Dust, R.; Hecht, J.; Gürtler, B.: Total Supplier Management. Heilbronn, 2011.
DUS13	Dust, R.: Total Supplier Management. Heilbronn, 2013.
DUS14	Dust, R.: Total Supplier Management. BMEnet Guide Beschaffungsdienstleister (2014), S. 14.

DUS15 Dust, R.; Wilde, A.: Datenqualität im Lieferanten-Risikomanagement. ERP Management (2015) Ausg. 3, S. 35–37.

DUS16a Dust, R.; Wilde, A.: Fit für die Zukunft? Der Reifegrad des heutigen Lieferantenmanagements. Qualität und Zuverlässigkeit Jg. 61 (2016) Ausg. 6/2016, S. 42–45.

DUS16b Dust, R.; Wilde, A.; Nowak, A.: Smart Data Intelligence zur Steuerung der externen Wertschöpfungsnetzwerke. Beschaffung aktuell (2016) Ausg. 09, S. 22–23.

DUS16c Dust, R.; Wilde, A.: Strategische Wettbewerbsvorteile durch Risikoprävention im Lieferantenmanagement. Q1 (2016) Ausg. 06, S. 36–39.

DUS16d Dust, R.; Wilde, A.: Total Supplier Management. Berlin, 2016.

DUS16e Dust, R.; Wilde, A.: Was kostet die Steuerung Ihrer Lieferanten? Controlling & Management Review Jg. 60 (2016) Sonderheft 2, S. 36–41.

DUS16f Dust, R.; Wilde, A.: Wissensmanagement als Grundlage einer präventiven Lieferantenbewertung. Beschaffung aktuell (2016) Ausg. 02, S. 20–21.

DUS17 Dust, R.; Ramm, A.; Paasch, R. (Hrsg.): Organisationsentwicklung zur Absicherung neuer Technologien und Geschäftsmodelle in globalen Partnernetzwerken. Berlin: Universitätsverlag TU Berlin, 2017.

DUS18 Dust, R.: Total Supplier Management. München: Hanser, 2018.

EBE13 Ebert, C.: Risikomanagement kompakt. Berlin, Heidelberg: Springer, 2013.

EIG17a Eigner, M.: Ausgangssituation. In: Modellbasierter Entwicklungsprozess cybertronischer Systeme. Hrsg.: Eigner, M.; Koch, W.; Muggeo, C. Berlin: Springer Vieweg, 2017, S. 5–12.

EIG17b Eigner, M.; Muggeo, C.: Zielstellung des Projekts mecPro2. In: Modellbasierter Entwicklungsprozess cybertronischer Systeme. Hrsg.: Eigner, M.; Koch, W.; Muggeo, C. Berlin: Springer Vieweg, 2017, S. 13–18.

ELM11 Elmasri, R.; Navathe, S.; Shafir, A.: Grundlagen von Datenbanksystemen. München: Pearson Studium, 2011.

ELM17 Elmasri, R.; Navathe, S. B.: Fundamentals of Database Systems. Boston, London, Munich: Pearson, 2017.

EßI13 Eßig, M.; Hofmann, E.; Stölzle, W.: Supply Chain Management. München: Vahlen, 2013.

EST00 Ester, M.; Sander, J.: Knowledge Discovery in Databases. Berlin, Heidelberg: Springer, 2000.

ETT13 Etterich, H. J.: Informationen und Wissen. Wiesbaden: Springer Fachmedien, 2013.

FAH96 Fahrmeir, L.: Multivariate statistische Verfahren. Berlin, New York: De Gruyter, 1996.

FAL07 Falzmann, J.: Mehrdimensionale Lieferantenbewertung. 2007. URL: http://d-nb.info/1058561723/34 (Zugriff: 2017-08-20).

FAS16 Fasel, D., Meier, A. (Hrsg.): Big Data. Wiesbaden: Springer Vieweg, 2016.

FAY96 Fayyad, U. M. (Hrsg.): Advances in Knowledge Discovery and Data Mining. Menlo Park: AAAI Press, 1996.

FEI14 Feindt, M.; Grüßing, D.: Strategische Entscheidungen mit automatisierten Prognosen operativ umsetzen. In: Controlling und Big Data. Hrsg.: Leyk, J. et al. Freiburg: Haufe, 2014, S. 177–188.

FER07 Ferreras, M.: Beziehungsmanagement zu Lieferanten. Saarbrücken: VDM Dr. Müller, 2007.

FIE16 Fieten, R.: Von der Automatisierung zur digitalen Transformation: Supply Management redefined. Beschaffung aktuell (2016) 12, S. 20.

FOT16 Foth, E.: Erfolgsfaktoren für eine digitale Zukunft. Berlin: Springer Vieweg, 2016.

FRA16 Fraunhofer IML; BME e.V.: Einkauf 4.0 – Digitalisierung des Einkaufs. Dortmund, Frankfurt, 2016.

FRI15 Fries, A.: „House of sustainable SRM“: Die wachsende Bedeutung von Nachhaltigkeit im Rahmen des Supplier Relationship Management. In: CSR und Beschaffung. Hrsg.: Fröhlich, E. Berlin: Springer Gabler, 2015, S. 77–92.

FRO10 Froschmayer, A.; Göpfert, I.: Logistik-Bilanz. Wiesbaden: Gabler, 2010.

GAB10 Gabath, C.: Risiko- und Krisenmanagement im Einkauf. Wiesbaden: Gabler, 2010.

GAB08 Gabath, C. W.: Gewinngarant Einkauf. Wiesbaden: Gabler, 2008.

GAB09 Gabriel, R.; Gluchowski, P.; Pastwa, A.: Data Warehouse und Data Mining. Witten: W3L, 2009.

GAB15 Gabriel, R.: Einführung eines stadtweiten IT-Multiprojektmanagements. In: Multiprojektmanagement. Hrsg.: Hüsselmann, C. Düsseldorf: Symposion, 2015, 313–340.

GAD17 Gadatsch, A.: Datenmodellierung für Einsteiger. Wiesbaden: Springer, 2017.

GAG98 Gago, P.; Bento, C.: A metric for selection of the most promising rules. In: Principles of Data Mining and Knowledge Discovery. Hrsg.: Żytkow, J. M.; Quafafou, M. Berlin, Heidelberg: Springer, 1998, S. 19–27.

GEH05 Gehra, B.: Früherkennung mit Business-Intelligence-Technologien. München: Deutscher Universitätsverlag, 2005

GEI01 Geißler, K. A.; Hege, M.: Konzepte sozialpädagogischen Handelns. Weinheim: Beltz, 2001.

GIE11 Giebel, M.: Wertsteigerung durch Qualitätsmanagement. Kassel: Univ. Press, 2011.

GLA94 Glantschnig, E.: Merkmalsgestützte Lieferantenbewertung. Köln: Fördergesellschaft Produkt-Marketing e.V., 1994.

GLE05 Gleißner, W.; Romeike, F.: Risikomanagement. Freiburg im Breisgau: Haufe, 2005.

GLE16 Gleißner, W.: Reifegradmodelle und Entwicklungsstufen des Risikomanagements: ein Selbsttest. CONTROLLER Magazin (2016) Ausg. 6, S. 31–36.

GLU08 Gluchowski, P.; Dittmar, C.; Gabriel, R.: Management Support Systeme und Business Intelligence. Berlin, Heidelberg: Springer, 2008.

GLU16 Gluchowski, P., Chamoni, P. (Hrsg.): Analytische Informationssysteme. Berlin, Heidelberg: Springer Gabler, 2016.

GOB18 Gobrecht, R.: Philosophische Gedanken zur Mathematik. Norderstedt: BoD, 2018.

GOL09 Golmohammadi, D.; Creese, R. C.; Valian, H.; Kolassa, J.: Supplier selection based on a neural network model using genetic algorithm. IEEE transactions on neural networks 20 (2009) 9, S. 1504–1519.

GOM06 Gomez, J. M.; Rautenstrauch, C.; Cissek, P.; Grahlher, B.: Einführung in SAP Business Information Warehouse. Berlin, Heidelberg, New York: Springer, 2006.

GÖP13 Göpfert, I.: Logistik. München: Vahlen, 2013.

GÖP16 Göpfert, I.; Grünert, M.; Schmid, N. A.: Logistiknetze der Zukunft – Das neue Hersteller-Zulieferer-Verhältnis in der Automobilindustrie. In: Logistik der Zukunft - Logistics for the Future. Hrsg.: Göpfert, I. Wiesbaden: Springer Gabler, 2016, S. 175–218.

GÖT15 Götze, U.; Mikus, B.: Der Prozess des Risikomanagements in Supply Chains. In: Risikomanagement in Supply Chains. Hrsg.: Siepermann, C.; Amann, M. Berlin: Schmidt Erich, 2015, S. 29–59.

GRO80 Grochla, E.; Schönbohm, P.: Beschaffung in der Unternehmung. Stuttgart: Poeschel, 1980.

GRO06 Gronau, N.; Müller, C.: Wissensmanagement in Wertschopfungsnetzwerken. In: Innovative Kooperationsnetzwerke. Hrsg.: Wojda, F.; Berth, A. Wiesbaden: Deutscher Universitätsverlag, 2006, S. 107–128.

GRO15 Gronwald, K.-D.: Integrierte Business-Informationssysteme. Berlin: Springer Vieweg, 2015.

GRÜ17 Grünig, R.: Prozess zur Lösung komplexer Entscheidungsprobleme. Berlin, Heidelberg: Springer, 2017.

GRU17	Grunwald, G.; Hempelmann, B.: Angewandte Marketinganalyse. Berlin, Boston: De Gruyter Oldenbourg, 2017.
GUD05	Gudehus, T.: Logistik. Berlin: Springer, 2005.
GUD15	Gudehus, T.: Dynamische Märkte. Berlin: Springer Gabler, 2015.
GÜR13	Gürtler, B.: Supplier ranking aligned by risk specific frequency distributions. 2013. URL: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2552819 (Zugriff: 2017-04-24).
HAA01	Haasis, H.-D.; Kriwald, T.: Wissensmanagement in Produktion und Umweltschutz. Berlin, Heidelberg: Springer, 2001.
HAH02	Hahn, D.; Kaufmann, L. (Hrsg.): Handbuch industrielles Beschaffungsmanagement. Wiesbaden: Gabler, 2002.
HAM86	Hammann, P.: Beschaffungsmarketing. Stuttgart: Poeschel, 1986.
HAN17	Handelsblatt: Fehlendes Bauteil. 2017. URL: http://www.handelsblatt.com/unternehmen/industrie/fehlendes-bauteil-bmw-produktion-steht-teilweise-still/19860828.html (Zugriff: 2017-06-01).
HAR06	Harding, J. A.; Shahbaz, M.; Srinivas; Kusiak, A.: Data Mining in Manufacturing. J. Manuf. Sci. Eng. Jg. 128 (2006) Nr. 4, S. 969–976.
HAR10a	Harrach, H.: Risiko-Assessments für Datenqualität. Wiesbaden: Vieweg, 2010.
HAR15	Harter, V.: Risikomanagement von Lieferanten - Implementierung einer Lieferantenbewertung mit Hilfe von Trend- und Prognoseverfahren. Heilbronn, 2015
HAR94	Harting, D.: Lieferanten-Wertanalyse. Ein Arbeitshandbuch mit Checklisten und Arbeitsblättern für Auswahl, Bewertung und Kontrolle von Zulieferern. Stuttgart: Schäffer-Poeschel, 1994.
HAR10b	Hartmann, H.: Lieferantenmanagement. Gernsbach: Dt. Betriebswirte-Verlag, 2010.
HAR13	Hartmann, H.; Orths, H.; Kössel, N.: Lieferantenbewertung - aber wie?. Gernsbach: Dt. Betriebswirte-Verlag, 2013.
HAß16a	Haßmann, V.: Lieferkette: So mindern Sie ihre Risiken. Best in Procurement Jg. 7 (2016) Ausg. 2, S. 14–20.
HAß16b	Haßmann, V.: Lieferkette: Somindern Sie Risiken. Best in Procurement 7. (2016) 2, S. 14–20.
HAß17	Haßmann, V.: Einkaufscontrolling: Kollege Roboter. Best in Procurement Jg. 8 (2017) Ausg. 4, S. 14–18.
HEI09	Heinrich, L. J.; Stelzer, D.: Informationsmanagement. München: Oldenbourg, 2009.
HEI14	Heinrich, L. J.; Stelzer, D.; Riedl, R.: Informationsmanagement. Berlin, Boston: De Gruyter, 2014.

HEI02	Heinz, K.; Mesenhöller, E.; Grünz, L.: Workflow-Management-Systeme. Dortmund: Verlag Praxiswissen, 2002.
HEI11	Heiserich, O.- E.; Helbig, K.; Ullmann, W.: Logistik. Wiesbaden: Springer Gabler, 2011.
HEL02	Helfert, M.: Planung und Messung der Datenqualität in Data-Warehouse-Systemen. Bamberg, 2002. URL: http://dataquality.computing.dcu.ie/thesis/(German).Markus.Helfert.thesis.2002.pdf (Zugriff: 2017-09-06).
HEL17	Helmke, S.; Uebel, M.; Dangelmaier, W. (Hrsg.): Effektives Customer Relationship Management. Wiesbaden: Springer Gabler, 2017.
HEL16	Helmold, M.; Terry, B.: Lieferantenmanagement 2030. Wiesbaden: Springer Gabler, 2016.
HEN09	Henke, M.; Weimar, M.; Potzner, A.; Besl, R.: Supplier Risk Management in der Automobilindustrie. Wiesbaden, 2009.
HER19	Herbst, T.; Wilde, A.: evan.network – die neue Art der Vernetzung. In: Logistik der Zukunft – Logistics for the Future. Hrsg.: Göpfert, I. Wiesbaden: Springer, 2019, S. 281–305.
HER00	Herman, I.; Melancon, G.; Marshall, M. S.: Graph visualization and navigation in information visualization. IEEE Trans. Visual. Comput. Graphics Jg. 6 (2000) Heft 1, S. 24–43.
HER17	Hermanni, A.-J.: Digitalisierung-Chancen und Herausforderungen für Medien und Kommunikation. In: Digitalisierung in Wirtschaft und Wissenschaft. Hrsg.: Fernhochschule, S. Wiesbaden: Springer, 2017, S. 13–26.
HER11	Hertel, J.; Zentes, J.; Schramm-Klein, H.: Supply-Chain-Management und Warenwirtschaftssysteme im Handel. Berlin, Heidelberg: Springer, 2011.
HEß08	Heß, G.: Supply-Strategien in Einkauf und Beschaffung. Wiesbaden: Gabler, 2008.
HEß15	Heß, G.: Reifegradmanagement im Einkauf. Wiesbaden: Springer Gabler, 2015.
HEß16	Heß, G.; Lüninck, J. von; Kittel, F.: Strategisches Lieferantenmanagement. All about Sourcing (2016) Ausg. 03, S. 6–7.
HET01	Hettrich, S.; Hippner, H.: Assoziationsanalyse. In: Handbuch Data Mining im Marketing. Hrsg.: Hippner, H. Braunschweig: Vieweg, 2001, S. 459–495.
HIL15	Hildebrand, K.; Gebauer, M.; Hinrichs, H.; Mielke, M.: Daten- und Informationsqualität. Wiesbaden: Springer Vieweg, 2015.

HIP17	Hippner, H.; Wilde, K. D.: Data Mining im CRM. In: Effektives Customer Relationship Management. Hrsg.: Helmke, S.; Uebel, M.; Dangelmaier, W. Wiesbaden: Springer Gabler, 2017, S. 142–159.
HOF09	Hofbauer, G.; Mashhour, T.; Fischer, M.: Lieferantenmanagement. München: Oldenbourg, 2009.
HOF13	Hoffmann, S.; Roland, F.: Nutzungspotenziale von Social Media im Supplier Risk Management. In: Supply Management Research. Hrsg.: Bogaschewsky, R. et al. Wiesbaden: Springer, 2013, S. 223–250.
HOM08	Homburg, C.; Pflesser, C.; Klarmann, M.: Strukturgleichungsmodelle mit latenten Variablen: Kausalanalyse. In: Handbuch Marktforschung. Hrsg.: Herrmann, A. Wiesbaden: Gabler, 2008, S. 545–577.
HRU00	Hruschka, H.: Neuronale Netze. In: Marktforschung. Hrsg.: Herrmann, A.; Homburg, C. Wiesbaden: Gabler, 2000, S. 661–683.
HÜT00	Hüttner, M.; Schwarting, U.: Exploratorische Faktorenanalyse. In: Marktforschung. Hrsg.: Herrmann, A.; Homburg, C. Wiesbaden: Gabler, 2000, S. 381–412.
IBM11	IBM Corporation: IBM SPSS Modeler CRISP-DM Guide, 2011. URL: ftp://ftp.software.ibm.com/software/analytics/spss/documentation/modeler/14.2/en/CRISP_DM.pdf (Zugriff: 2017-06-27).
IRL12	Irlinger, W.: Kausalmodelle zur Lieferantenbewertung. Wiesbaden: Springer Gabler, 2012.
ISO31000	ISO 31000, (11.2009) Risk management – Principles and guidelines. Geneva: ISO copyright office.
JAN08	Janker, C. G.: Multivariate Lieferantenbewertung. Wiesbaden: Springer Fachmedien, 2008.
JÜN89	Jünemann, R.: Materialfluß und Logistik. Berlin: Springer, 1989.
JUN14	Jung, H.: Controlling. Berlin: De Gruyter, 2014.
JÜT11	Jüttner, U.; Maklan, S.: Supply chain resilience in the global financial crisis. Supply Chain Management: An International Journal Jg. 16 (2011) Heft 4, S. 246–259.
KAP97	Kaplan, R. S.; Norton, D. P.; Horváth, P.: Balanced Scorecard. Stuttgart: Schäffer-Poeschel, 1997.
KAP04	Kaplan, R. S.; Norton, D. P.; Horváth, P.: Strategy Maps. Stuttgart: Schäffer-Poeschel, 2004.
KAU84	Kaufmann, H.; Pape, H.: Clusteranalyse. In: Fahrmeier, L.; Hammerle, A. (Hrsg.): Multivariate statistische Verfahren. Berlin: de Gruyter, 1984, S. 371–472.
KLE14	Kleemann, F. C.: Supplier Relationship Management im Performance-based Contracting. Wiesbaden: Springer Gabler, 2014.

KLE06 Kleinaltenkamp, M. (Hrsg.): Markt- und Produktmanagement. Wiesbaden: Gabler, 2006.

KLE95 Kleinau, A. C.: Zur Strategie der Lieferantenentwicklung. Frankfurt am Main, Berlin: Lang, 1995.

KNA00 Knapp, T. M.; Durst, M.; Bichler, K.: Permanente Bewertung der Lieferantenleistung. Beschaffung aktuell (2000) Ausg. 12, S. 42–47.

KOL13 Kolmykova, A.: Supply Chain Integration. Dissertation, 2013.

KOP95 Koppelmann, U.: Beschaffungsmarketing. Berlin, Heidelberg: Springer, 1995.

KÖP14 Köppen, V.; Saake, G.; Sattler, K.-U.: Data Warehouse Technologien. Heidelberg: Verlagsgruppe Hüthig Jehle Rehm, 2014.

KOT15 Kotu, V.: Predictive Analytics and Data Mining. Waltham, MA: Morgan Kaufmann, 2015.

KRO09 Kromrey, H.; Strübing, J.: Empirische Sozialforschung. Stuttgart: Lucius & Lucius, 2009.

KUH02 Kuhn, A.; Hellingrath, B.: Supply Chain Management. Berlin, Heidelberg: Springer, 2002.

KÜH13 Kühnapfel, J. B.: Vertriebscontrolling. Wiesbaden: Springer, 2013.

KÜH15 Kühnapfel, J. B.: Vertriebsprognosen. Wiesbaden: Springer Gabler, 2015.

KUR16 Kurbel, K.: Enterprise Resource Planning und Supply Chain Management in der Industrie. Berlin/Boston: De Gruyter, 2016.

KÜS01 Küsters, U.: Data Mining Methoden: Einordnung und Überblick. In: Handbuch Data Mining im Marketing. Hrsg.: Hippner, H. Braunschweig: Vieweg, 2001, S. 95–130.

LAM05 Lamming, R.: Supplier Relationship Management. In: Perspektiven des Supply Management. Hrsg.: Eßig, M. Berlin: Springer, 2005, S. 81–94.

LAN01 Laney, D.: 3D Data Management: Controlling Data Volume, Velocity, and Variety, 2001. URL: https://blogs.gartner.com/doug-laney/files/2012/01/ad949-3D-Data-Management-Controlling-Data-Volume-Velocity-and-Variety.pdf (Zugriff: 2017-05-23).

LAN15 Lang, P.; Franke, J.: Datenanalyse. In: Mathematik im Fraunhofer-Institut. Hrsg.: Neunzert, H.; Prätzel-Wolters, D. Berlin: Springer Spektrum, 2015, 65–83.

LAR09 Large, R.: Strategisches Beschaffungsmanagement. Wiesbaden: Gabler, 2009.

LEE89 Leenders, M. R.; Blenkhorn, D. L.: Reverse Marketing. Frankfurt/Main: Campus, 1989.

LEH12 Lehner, F.: Wissensmanagement. München: Hanser, 2012.

LEI98	Leiner, B.: Grundlagen der Zeitreihenanalyse. München: Oldenbourg, 1998.
LIE16	Liebetruth, T.: Prozessmanagement in Einkauf und Logistik. Wiesbaden: Springer Gabler, 2016.
LIN05	Linder, A.: Web Mining. Wiesbaden: Deutscher Universitätsverlag, 2005.
LIP13	Lippold, D.: Die Unternehmensberatung. Wiesbaden: Springer, 2013.
LOC07	Lochmahr, A.; Wildemann, H.: Die Einführung logistischer Konzepte in Theorie und Praxis – Fallbeispiel Kapazitätsmanagement. In: Neue Wege in der Automobillogistik. Hrsg.: Günthner, W. A. Berlin, Heidelberg: Springer, 2007, S. 509–524.
LÜN16a	Lünendonk GmbH: Lünendonk®-Marktstichprobe 2016. Mindelheim, 2016.
LÜN16b	Lünendonk, J.: Unternehmen sehen Vielzahl von Veränderungen – der Beratermarkt wächst. BIP Einkaufsberater Report 2016 (2016), S. 6–7.
MAC02	Mack, D.: Computational Intelligence in der Materialwirtschaft. Wiesbaden: Deutscher Universitätsverlag, 2002.
MAI09	Maier, U.: Automatisierungsstrukturen. In: Handbuch der Prozessautomatisierung. Hrsg.: Früh, K. F.; Ahrens, W. München: Oldenbourg, 2009, S. 180–190.
MAK16	Makert, S.; Kreis, A.; Hartmann, E.: Pilotprojekte zur Zukunft des Supply Chain Managements. Beschaffung aktuell (2016) Ausg. 03, S. 22–23.
MAN17	Mandl, C.; Minner, S.: Big Data in der Rohstoffbeschaffung. Beschaffung aktuell (2017) Ausg. 04, S. 22–23.
MAT99	Matzenbacher, H.-J.; Bertsch, D.; Christe, R.; Falb, E.; Fricke, U.; Heyl, F. von; Schiefer, B.; Veltmann, L.: Risikomanagement in der Beschaffung. Frankfurt am Main, 1999.
MAU14	Mauro, A. de; Greco, M.; Grimaldi, M.: What is Big Data? A Consensual Definition and a Review of Key Research Topics, 2014.
MAY13	Mayer-Schönberger, V.; Cukier, K.: Big Data. München: Redline, 2013.
MCK13	McKinsey Global Institute: Open data: Unlocking innovation and performance with liquid information, 2013. URL: http://www.mckinsey.com/business-functions/digital-mckinsey/our-insights/open-data-unlocking-innovation-and-performance-with-liquid-information (Zugriff: 2017 - 07- 11).
MED99	Medin, D. L.; Aguilar, C.: Categorization. In: The MIT Encyclopedia of the Cognitive Sciences. Hrsg.: Wilson, R. A. Cambridge, Mass.: MIT Press, 1999, S. 104–106.
MEL89	Melzer-Ridinger, R.: Materialwirtschaft. München: Oldenbourg, 1989.

MER94	Mertens, P.; Deistler, M. (Hrsg.): Prognoserechnung. Heidelberg: Physica, 1994.
MET15	Metz, P. J.: Finanzen in Einkauf und Supply Chain. In: Chefsache Finanzen in Einkauf und Supply Chain. Hrsg.: Locker, A.; Grosse-Ruyken, P. T. Wiesbaden: Springer Gabler, 2015, S. 1–28.
MOD08	Moder, M.: Supply Frühwarnsysteme. Wiesbaden: Gabler, 2008.
MÖD19	Mödritscher, G.; Wall, F.: Controlling von Beschaffungsprozessen – Wirtschaftliche Nachhaltigkeit, Chancen und ausgewählte Potenziale durch Digitalisierung. In: Nachhaltiges Beschaffungsmanagement. Hrsg.: Wellbrock, W.; Ludin, D. Wiesbaden: Springer Gabler, 2019, S. 389–406.
MÖß07	Mößmer, H. E.; Schedlbauer, M.; Günthner, W. A.: Die automobile Welt im Umbruch. In: Neue Wege in der Automobillogistik. Hrsg.: Günthner, W. A. Berlin, Heidelberg: Springer, 2007, S. 3–15.
MÜL10	Müller, M.; Poguntke, W.: Basiswissen Statistik. Herdecke: W3L, 2010.
MÜL13	Müller, R. M.; Lenz, H.-J.: Business Intelligence. Berlin, Heidelberg: Springer Vieweg, 2013.
MÜL18	Müller, T.; Wilde, A.: n-tier Lieferantenmanagement – die Blockchain macht es möglich. Beschaffung aktuell (2018) 03, S. 30–31.
MUS98	Muschinski, W.: Empirische Bestandsaufnahme der Lieferantenbewertung in Deutschland. Mönchengladbach: Fachbereich Wirtschaft Fachhochsch. Niederrhein, 1998.
MÜS07	Müssigmann, N.: Strategische Liefernetze. Wiesbaden: Deutscher Universitätsverlag, 2007.
NAI92	Naisbitt, J.; Aburdene, P.: Megatrends 2000. Düsseldorf: ECON-Taschenbuch, 1992.
NAK98	Nakhaeizadeh, G.: Data Mining. Heidelberg: Physica, 1998.
NAR12	Narr, C.: Kooperatives Lieferantenmanagement im Maschinen- und Anlagenbau. Aachen: Apprimus Wissenschaftsverlag, 2012.
NAT17	National Institute of Stansards and Technology: DRAFT NIST Big Data Interoperability Framework: Volume 1, Definitions. Gaithersburg, 2017.
NAU96	Nauck, D.; Klawonn, F.; Kruse, R.: Neuronale Netze und Fuzzy-Systeme. Wiesbaden: Vieweg+Teubner, 1996.
NAU07	Naumann, F.: Datenqualität. Informatik Spektrum Jg. 30 (2007), S. 27–31.
NIK17	Nikodemus, P.: Lernprozessorientiertes Wissensmanagement und kooperatives Lernen. Wiesbaden: Springer, 2017.
NON95	Nonaka, I.; Takeuchi, H.: The Knowledge-Creating Company. New York: Oxford Univ. Press, 1995.

NOR11	North, K.: Wissensorientierte Unternehmensführung. Wiesbaden: Springer Gabler, 2011.
NOR16	North, K.; Brandner, A.; Steininger, T.: Wissensmanagement für Qualitätsmanager. Wiesbaden: Springer Gabler, 2016.
NOR12	North, M.: Data Mining for the Masses. Global Text Project, 2012.
ORA13	Oracle Corp.: Big Data for the Enterprise. Redwood Shores, 2013.
PAL02	Palupski, R.: Management von Beschaffung, Produktion und Absatz. Wiesbaden: Gabler Verlag, 2002.
PAS96	Paschka, R.: Multipersonalität bei Mehrfachzielentscheidungen. Wiesbaden: Deutscher Universitätsverlag, 1996.
PAW11	Pawlowsky, P.; Gözalan, A.; Schmid, S.: Wettbewerbsfaktor Wissen: Managementpraxis von Wissen und Intellectual Capital in Deutschland. Chemnitz, 2011. URL: https://www.bmwi.de/Redaktion/DE/Publikationen/Studien/studie-wissensmanagement.pdf?__blob=publicationFile&v=3 (Zugriff: 2017-07-20).
PEN13	Peneder, S.: Die neue Welt der Zusammenarbeit. Wissensmanagement (2013) Ausg. 7, S. 8–10.
PER04	Perlitz, M.: Internationales Management. Stuttgart: Lucius & Lucius, 2004.
PER09	Pernul, G.; Unland, R.: Datenbanken im Unternehmen. München, Wien: Oldenbourg, 2009.
PET09	Petersohn, H.: Data Mining. München, Wien: Oldenbourg, 2009.
PFE02	Pfefferli, H.; Springer, G.: Lieferantenqualifikation. Renningen: expert, 2002.
PIA10	Piazza, F.: Data Mining im Personalmanagement. Wiesbaden: Gabler, 2010.
POL10	Politis, S.: Risikomanagement in der Lieferantenbewertung. Berlin: Logos, 2010.
POL97	Pollandt, S.: Fuzzy-Begriffe. Berlin, Heidelberg: Springer, 1997.
POL13	Poltermann, A.: Wissensgesellschaft. Belgrad, 2013. URL: http://www.bpb.de/gesellschaft/kultur/zukunft-bildung/146199/wissensgesellschaft?p=all (Zugriff: 2017-08-08).
POL07	Poluha, R. G.: Anwendung des SCOR-Modells zur Analyse der Supply Chain. Lohmar: Josef Eul, 2007.
POR08	Porschen, S.: Austausch impliziten Erfahrungswissens. Wiesbaden: VS Verlag für Sozialwissenschaften / GWV Fachverlage GmbH Wiesbaden, 2008.
POR14	Porter, M. E.: Wettbewerbsvorteile. Frankfurt am Main: Campus, 2014.

PRO12 Probst, G.; Raub, S.; Romhardt, K.: Wissen managen. Wiesbaden: Springer Gabler, 2012.

QUA14 Quatember, A.: Datenqualität in Stichprobenerhebungen. Berlin: Springer Spektrum, 2014.

RAM17 Ramm, A.; Randow, N. von; Reinhardt, A.; Trotz, M.; Wilde, A.; Eggert, J.: Tools zur Absicherung neuer Technologien und Gechäftsmodelle. In: Organisationsentwicklung zur Absicherung neuer Technologien und Geschäftsmodelle in globalen Partnernetzwerken. Hrsg.: Dust, R.; Ramm, A.; Paasch, R. Berlin: Universitätsverlag TU Berlin, 2017, S. 129–162.

RAN17 Randow, N. von; Ramm, A.; Behr, C.-M. von: Präventive Absicherung von Mobilitätsdienstleistungen mit intelligenten Datenanalyseverfahren. In: Organisationsentwicklung zur Absicherung neuer Technologien und Geschäftsmodelle in globalen Partnernetzwerken. Hrsg.: Dust, R.; Ramm, A.; Paasch, R. Berlin: Universitätsverlag TU Berlin, 2017, S. 71–97.

REH96 Rehäuser, J.; Kremar, H.: Wissensmanagement im Unternehmen. In: Wissensmanagement. Hrsg.: Schreyögg, G.; Conrad, P. Berlin: De Gruyter, 1996, S. 1–40.

REI06 Reichmann, T.; Richter, H. J.: Controlling mit Kennzahlen und Management-Tools. München: Vahlen, 2006.

REI17 Reinhart, G.: Handbuch Industrie 4.0. München: Hanser, 2017.

REI07 Reiss, K.; Schmieder, G.: Basiswissen Zahlentheorie. Heidelberg, Springer, 2007.

REI02 Reith-Ahlemeier, G.: Ressourcenorientierte Bestellmengenplanung und Lieferantenauswahl. Norderstedt: Books-on-Demand, 2002.

REM02 Remus, U.: Prozessorientiertes Wissensmanagement. Regensburg, 2002.

RIE17 Rieder, G.; Simon, J.: Big Data: A New Empiricism and its Epistemic and Socio-Political Consequences. In: Berechenbarkeit der Welt? Hrsg.: Pietsch, W.; Wernecke, J.; Ott, M. Wiesbaden: Springer, 2017, S. 85–105.

RÖS12 Rössler, I.; Ungerer, A.: Statistik für Wirtschaftswissenschaftler. Berlin, Heidelberg: Springer Gabler, 2012.

ROM04 Romeike, F.: Lexikon Risiko-Management. Weinheim: WILEY-VCH, 2004.

ROM05 Romeike, F. (Hrsg.): Modernes Risikomanagement. Weinheim: WILEY-VCH, 2005.

ROM09 Romeike, F.; Hager, P.: Erfolgsfaktor Risiko-Management 2.0. Wiesbaden: Gabler, 2009.

ROM94 Rommelfanger, H.: Fuzzy Decision Support-Systeme. Berlin, Heidelberg: Springer, 1994.

ROM06 Rommelfanger, H.: Fuzzy-Nutzwertanalyse und Fuzzy-AHP. In: Perspectives on Operations Research. Hrsg.: Morlock, M. et al. Wiesbaden: Deutscher Universitätsverlag, 2006, S. 403–423.

ROS75 Rosch, E.; Mervis, C. B.: Family Resemblances: Studies in the Internal Structure of Categories. Cognitive Psychology Jg. 7 (1975), S. 573–605.

ROS12 Rosenstiel, L. v.; Hornstein, E. v. (Hrsg.): Change Management Praxisfälle, 2012.

RUD14 Rudow, B.; Heidecke, H.-C.; Neubauer, W.: Betriebliche Informationssysteme in der Automobilproduktion. In: Betriebliche Informationssysteme in der Automobilproduktion. Hrsg.: Rudow, B. München: Oldenbourg, 2014, S. 1–56.

SAC78 Sachs, L.: Angewandte Statistik. Berlin, Heidelberg: Springer, 1978.

SAC97 Sachs, L.: Angewandte Statistik. Berlin, Heidelberg: Springer, 1997.

SAI13 Saint-Mont, U.: Die Macht der Daten. Berlin: Springer, 2013.

SAR19 Sarnow, T.; Schröder, M.: Supply-Chain-Risiken in der Textilindustrie. In: Supply Management Research. Hrsg.: Bode, C. et al. Wiesbaden: Springer, 2019, S. 255–276.

SAS17 SAS Institute Inc.: Data Mining Overview, 2017. URL: http://support.sas.com/documentation/cdl/en/emgs/59885/HTML/default/viewer.htm#a000167823.htm (Zugriff: 2017-06-27).

SCH09a Schaffranietz, K.; Neumann, F.: Wissensgenerierung aus Datenbanken. In: Wissens- und Informationsmanagement. Hrsg.: Keuper, F.; Neumann, F. Wiesbaden: Gabler, 2009, S. 150–177.

SCH10a Schatz, A.; Mandel, J.; Hermann, M.: Studie Risikomanagement in der Beschaffung 2010. Stuttgart, 2010.

SCH09b Schedl, S.: Integration von Anforderungsmanagement in den mechatronischen Entwicklungsprozess. Herbert Utz Verlag, 2009.

SCH07 Schendera, C. F. G.: Datenqualität mit SPSS. München: Oldenbourg, 2007.

SCH15a Schendera, C. F. G.: Deskriptive Statistik. Konstanz: UVK Verlagsgesellschaft, 2015.

SCH08a Schlittgen, R.: Einführung in die Statistik. München: Oldenbourg, 2008.

SCH09c Schlittgen, R.: Multivariate Statistik. München: Oldenbourg, 2009.

SCH10b Schmidt, A.: Entwicklung einer Methode zur Stammdatenintegration. Berlin: Logos, 2010.

SCH15b Schmitt, R.; Pfeifer, T.: Qualitätsmanagement. München: Hanser, 2015.

SCH16	Schmitt, R.; Ngo, Q. H.; Groggert, S.; Elser, H.: Datenbasierte Qualitätsregelung. In: Qualitätsmanagement 4.0 – Status quo! Quo vadis? Hrsg.: Refflinghaus, R.; Kern, C.; Klute-Wenig, S. Kassel: Kassel University Press, 2016, S. 23–42.
SCH89	Schneider, D. J. G.: Datenbankgestützte Marktselektion. Stuttgart: Poeschel, 1989.
SCH97	Schönert, O.: Frühaufklärung im internationalen Strategiekontext. Wiesbaden: Deutscher Universitätsverlag, 1997.
SCH04	Scholl, W.: Innovation und Information - Wie in Unternehmen neues Wissen produziert wird. Göttingen: Hogrefe, 2004.
SCH96	Schreyögg, G.; Conrad, P. (Hrsg.): Wissensmanagement. Berlin: De Gruyter, 1996.
SCH14a	Schuh, C.; Strohmer, M. F.; Easton, S.; Hales, M.; Triplat, A.: Supplier Relationship Management. Berkeley, CA: Apress, 2014.
SCH05	Schuh, G.: Produktkomplexität managen: Strategien – Methoden – Tools. München, Wien: Hanser, 2005.
SCH06a	Schuh, G.: Change Management – Prozesse strategiekonform gestalten. Berlin, Heidelberg: Springer, 2006.
SCH14b	Schuh, G.; Bremer, D.; Drescher, T.; Essig, J.: Beschaffungscontrolling. In: Einkaufsmanagement. Hrsg.: Schuh, G. Berlin: Springer Vieweg, 2014, S. 147–182.
SCH14c	Schuh, G. (Hrsg.): Einkaufsmanagement. Berlin: Springer Vieweg, 2014.
SCH17	Schüller, K.; Fritsch, S.: Wie man Wert aus Smart Data schöpft. In: Herausforderung Utility 4.0. Hrsg.: Doleski, O. D. Wiesbaden: Springer Vieweg, 2017, S. 477–500.
SCH13	Schulte, C.: Logistik. München: Vahlen, 2013.
SCH99	Schulz, E. H.; Sempert, F. P.: Die Jahr-2000-Krise. Wiesbaden: Gabler, 1999.
SCH08b	Schumacher, S. C.; Schiele, H.; Contzen, M.; Zachau, T.: Die 3 Faktoren des Einkaufs. Weinheim: WILEY-VCH, 2008.
SCH06b	Schwenke, M. C.: Individualisierung und Datenschutz. Wiesbaden: Deutscher Universitätsverlag, 2006.
SEI06	Seibold, H.: IT-Risikomanagement. München: Oldenbourg, 2006.
SEU08	Seufert, A.; Back, A.; Krogh, G. von: Wissensnetzwerke: Vision – Referenzmodell – Archetypen und Fallbeispiele. In: Wissensmanagement. Hrsg.: Götz, K. Mering: Rainer Hampp, 2008, S. 129–153.
SIB05	Sibbel, R.; Hartmann, F.; Siekaup, T.: Operatives Lieferantenmanagement. Beschaffung aktuell (2005) Heft 12, S. 62.

SIE15	Siepermann, C., Amann, M. (Hrsg.): Risikomanagement in Supply Chains. Berlin: Schmidt Erich, 2015.
SIM00	Simchi-Levi, D.; Kaminsky, P.; Simchi-Levi, E.: Designing and Managing the Supply Chain. Boston: McGraw-Hill, 2000.
SOD12	Sodhi, M. S.; Tang, C. S.: Managing Supply Chain Risk. New York, Dordrecht, Heidelberg, London: Springer, 2012.
SPE07	Specht, D.; Mieke, C.; Behrens, S.: Risikobeherrschung in Beschaffungsnetzwerken. ZWF Jg. 102 (2007) Ausg. 4, S. 211–215.
SRI96	Srikant, R.; Agrawal, R.: Mining Quantitative Association Rules in Large Relational Tables. 1996. URL: https://sci2s.ugr.es/keel/pdf/algorithm/congreso/1996%20-%20SrikantAgrawal-%20Mining%20Quantitative%20association%20rules%20in%20large%20relational%20tables.pdf (Zugriff: 2018-12-10).
STA17	Stahl, R.; Staab, P.: Die Vermessung des Datenuniversums. Berlin: Springer Vieweg, 2017.
STA16	Stauffer, H.: Business Intelligence (BI): Strategische Steuerung von Leistungen und Innovationen. 2016. URL: https://www.informatik-aktuell.de/management-und-recht/projektmanagement/business-intelligence-strategische-steuerung-von-leistungen.html (Zugriff: 2017-08-15).
STE13	Steger, A.: Diskrete Strukturen 1: Kombinatorik, Graphentheorie, Algebra. Berlin, Heidelberg: Springer, 2013.
STE09	Steiff, Z.: Risikomanagement in der Logistik von Unternehmensnetzwerken. Lohmar: Eul, 2009.
STE15	Steinbrecher, M.; Schumann, R.: Update. Frankfurt, New York: Campus, 2015.
STE11	Stein, P.; Vollnhals, S.: Grundlagen clusteranalytischer Verfahren. Universität Duisburg-Essen, 2011.
STÖ99	Stölzle, W.: Industrial Relationships. München: Oldenbourg, 1999.
STÖ03	Stölzle, W.; Korte, C.: Beziehungsmanagement mit Lieferanten. In: Praxishandbuch Einkauf. Hrsg.: Arnold, U.; Kasulke, G. Köln: Deutscher Wirtschaftsdienst, 2003.
STR15	Straßheim, J.: Sinn und Relevanz. Wiesbaden: Springer VS, 2015.
SUC16a	Sucky, E.: Risikomanagement in der nachhaltigen Beschaffung. Best in Procurement Jg. 7 (2016) Ausg. 4, S. 48–50.
SUC16b	Sucky, E.; Zitzmann, I.: Risikomanagement in nachhaltigen Supply Chains. In: Internationales Management und die Grundlagen des globalisierten Kapitalismus. Hrsg.: Eckert, S.; Trautnitz, G. Wiesbaden: Springer Gabler, 2016, S. 459–477.

SUM06 Sumathi, S.; Sivanandam, S. N.: Introduction to Data Mining and its Applications. Berlin, Heidelberg: Springer, 2006.

SUP08 Supply Chain Council: Supply-Chain Operations Reference-model., Version 9.0. Washington DC, Amsterdam, 2008.

SVE00 Svensson, G.: A conceptual framework for the analysis of vulnerability in supply chains. International Journal of Physical Distribution and Logistics Management Jg. 30 (2000) Heft 9, S. 731–750.

SYD99 Sydow, J.: Management von Netzwerkorganisationen. Wiesbaden: Gabler, 1999.

SYD10 Sydow, J. (Hrsg.): Management von Netzwerkorganisationen. Wiesbaden: Gabler, 2010.

SYD15 Sydow, J.; Möllering, G.: Produktion in Netzwerken. München: Vahlen, 2015.

SYS16 Syska, A.: Was wir wirklich brauchen: das Manifest für die vernetzte Wertschöpfung, 2016. URL: http://www.industry-of-things.de (Zugriff: 2017-05-16).

TAN08 Tang, C.; Tomlin, B.: The power of flexibility for mitigating supply chain risks. International Journal of Production Economics (2008) Heft 116, S. 12–27.

THE70 Theisen, P.: Grundzüge einer Theorie der Beschaffungspolitik. Berlin: Duncker & Humblot, 1970.

THO08 Thom, A.: Entwicklung eines Gestaltungsmodells zum Management von Risiken in Produktionsnetzwerken. Berlin: Universitätsverlag der Technischen Universität Berlin, 2008.

THU11 Thun, J.-H.; Drüke, M.; Hoenig, D.: Managing uncertainty – an empirical analysis of supply chain risk management in small and medium-sized enterprises. International Journal of Production Research Jg. 49 (2011) Heft 18, S. 5511–5525.

TIE97 Tiemeyer, E.; Konopasek, K.: Professionelles Datenbank-Design mit ACCESS. Wiesbaden: Vieweg+Teubner, 1997.

TIM86 Timmermann, E.: An Approach to Vendor Performance Evaluation. Journal of Purchasing and Materials Management (1986), S. 2–8.

TOM14 Tomschke, S.: Visualisierungs- und Interaktionskonzept zur graphenbasierten Exploration. Dresden, 2014. URL: http://www.qucosa.de/fileadmin/data/qucosa/documents/19263/Tomschke-Dissertation-PDFA.pdf (Zugriff: 2018-03-19).

TRO15 Trost, U.: BIG DATA Future – Chancen und Herausforderungen für die deutsche Industrie. 2015. URL: https://bzi40.eu/de/publikationen/tags/datenstroeme/11-big-data-future-chancen-und-herausforderungen-fuer-die-deutsche-industrie/file (Zugriff: 2018-04-23).

VAH08	Vahrenkamp, R.; Siepermann, C.: Produktionsmanagement. München: Oldenbourg, 2008.
VER94	Verband der Automobilindustrie VDA: Logistsche Lieferantenbewertung. Frankfurt, 1994.
VER11	Verband der Automobilindustrie VDA: QM-Systemaudit. Berlin, 2011.
VER16	Verband der Automobilindustrie VDA: Band 6 Teil 3, Prozessaudit. Berlin, 2016.
VOG15	Vogel, J.: Prognose von Zeitreihen. Wiesbaden: Springer Gabler, 2015.
VOS08	Vossen, G.: Datenmodelle, Datenbanksprachen und Datenbankmanagementsysteme. München: Oldenbourg, 2008.
VOß01	Voß, S.; Gutenschwager, K.: Informationsmanagement. Berlin, Heidelberg: Springer, 2001.
WAG01	Wagner, S. M.: Strategisches Lieferantenmanagement in Industrieunternehmen. Frankfurt am Main: Lang, 2001.
WAG02	Wagner, S. M.: Lieferantenmanagement. München: Hanser, 2002.
WAG08a	Wagner, S. M.; Bode, C.: An empirical Examination of Supply Chain performance along several dimensions of risk. Journal of Business Logistics Jg. 29 (2008) Ausg. 1, S. 307–325.
WAG08b	Wagner, S. M.: Nutzung von Lieferantenpotenzialen. In: Best Practice in Einkauf und Logistik; Bd. Band 2. Hrsg.: BME e.V. Wiesbaden: Gabler, 2008, S. 171–175.
WAL19	Walther, F.; Hein, C.; Wellbrock, W.: Proaktives Risikomanagement als Unterstützung einer nachhaltigen Beschaffung. In: Nachhaltiges Beschaffungsmanagement. Hrsg.: Wellbrock, W.; Ludin, D. Wiesbaden: Springer Gabler, 2019, S. 271–294.
WAL10	Walther, G.: Nachhaltige Wertschöpfungsnetzwerke. Wiesbaden: Gabler, 2010.
WAL01	Walz, G. (Hrsg.): Lexikon der Mathematik – Band 3. Heidelberg: Spektrum, 2001.
WAN96	Wang, R.; Strong, D.: Beyond Accuracy: What Data Quality Means to Data Consumers. Journal of Management Information Systems (1996), S. 5–34.
WAR13	Ward, S.W.; Barker, A.: Undefined By Data: A Survey of Big Data Definitions, 2013. URL: https://arxiv.org/pdf/1309.5821.pdf (Zugriff: 2017-06-13).
WEB90	Weber, K.: Wirtschaftsprognostik. München: Vahlen, 1990.
WEB14	Weber, W.; Kabst, R.; Baum, M.: Einführung in die Betriebswirtschaftslehre. Wiesbaden: Gabler, 2014.
WER17	Werner, H.: Supply Chain Management. Wiesbaden: Springer, 2017.

WES72	Westermann, H.: Gewinnorientierter Einkauf. Berlin: E. Schmidt, 1972.
WIE17	Wieczorrek, S.; Hermes, A.; Grunewald, M.; Sprengler, T. S.; Braun, M.: Logistisches Prozesspartnermanagement in der Beschaffungslogistik bei der Volkswagen AG. In: Automobillogistik. Hrsg.: Göpfert, I.; Braun, D.; Schulz, M. Wiesbaden: Springer Gabler, 2017, S. 53–76.
WIE10	Wiederkehr, B.; Züger, R.-M.: Risikomanagementsystem im Unternehmen. Zürich: Compendio Bildungsmedien, 2010.
WIE08	Wiedmann, K.-P.; Buckler, F.: Neuronale Netze. In: Handbuch Marktforschung. Hrsg.: Herrmann, A. Wiesbaden: Gabler, 2008, S. 713–741.
WIL17	Wilde, A.; Dust, R.; Paasch, R.: Total Supplier Management – Ein Beitrag zum Unternehmenserfolg. In: Organisationsentwicklung zur Absicherung neuer Technologien und Geschäftsmodelle in globalen Partnernetzwerken. Hrsg.: Dust, R.; Ramm, A.; Paasch, R. Berlin: Universitätsverlag TU Berlin, 2017, S. 101–130.
WIL18a	Wilde, A.; Dust, R.; Nowak, A.: Alle Lieferanten im Blick. Controlling & Management Review Jg. 62 (2018) Ausg. 2, S. 46–51.
WIL18b	Wilde, A.; Eiber, M.: M2M-Kommunikation – Wenn Maschinen miteinander sprechen. Fabriksoftware 23 (2018) 4, S. 54–57.
WIL97	Willke, H.: Supervision des Staates. Frankfurt am Main: Suhrkamp, 1997.
WIN11	Windt, K.; Knollmann, M.; Meyer Mirja: Anwendung von Data Mining Methoden zur Wissensgenerierung in der Logistik – Kritische Reflexion der Analysefähigkeit zur Termintreueverbesserung. In: Wissensarbeit. Hrsg.: Spath, D. Berlin: GITO, 2011, S. 223–249.
WOL09	Wolke, T.: Risikomanagement. München: Oldenbourg, 2009.
WÜR03	Würthele, V.G.: Datenqualitätsmetrik für Informationsprozesse. Zürich, 2003. URL: http://e-collection.ethbib.ethz.ch/cgi-bin/show.pl?type=diss&nr=15242 (Zugriff: 2017-06-12).
XU05	Xu, Z.: A Procedure for Decision Making Based on Incomplete Fuzzy Preference Relation. Fuzzy Optimization and Decision Making (2005) Heft 4, S. 175–189.
ZOB09	Zobolski, A.: Kooperationskompetenz im dynamischen Wettbewerb. Wiesbaden: Gabler, 2009.
ZUK16	zukunftsInstitut: Konnektivität: Die Vernetzung der Welt, 2016. URL: https://www.zukunftsinstitut.de/artikel/konnektivitaet-die-vernetzung-der-welt/ (Zugriff: 2017-07-18).

Anhang A

Im folgenden Anhang A wird das Verfahren des Trend- und Prognosemodells aus dem TSM anhand des in der Praxis verwendeten Excel-Tools „Watchlist“ erläutert. Als beispielhafte Berechnung wird dazu die Kennzahl Liefertreue verwendet. Das Ziel der Trendberechnung auf Basis des Trend- und Prognosemodells ist es, mögliche zukünftige Leistungsdefizite abzubilden. Die anonymisierte Datenbasis aus einem Forschungsprojekt in Tabelle A-1 dient als Beispiel für die folgenden Berechnungen:

Tabelle A-1: Datenbasis zur Berechnung des Trends für die Kennzahl Liefertreue
Quelle: Eigene Darstellung

L.-nummer	Kennzahl Liefertreue pro Monat in [%]											
	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12
L1	67	92	91	77	89	65	95	85	73	80	62	53
L2	68	70	100	100	100	72	88	70	83	80	58	67
L3	48	37	31	40	47	49	47	35	30	40	50	67
L4	76	92	93	100	100	97	86	97	86	82	95	81
L5	94	97	100	100	100	97	100	95	100	100	92	84
L6	100			100	100		0			100		

Im vorliegenden Fall besteht die anonymisierte Datenbasis aus maximal 12 möglichen Ausprägungen der Kennzahl Liefertreue. Jede Kennzahlenausprägung repräsentiert einen Monat (M1 bis M12) innerhalb eines Jahres. Durch die Lieferantennummern L1 bis L5 werden verschiedene Lieferanten (Lieferant 1 bis Lieferant 5) anonymisiert.

Nach einer manuellen Eingabe der Datenbasis, wird wie bereits in Kapitel 4.3.1 beschrieben, die Datenbasis zunächst auf die definierten Mindestvoraussetzungen geprüft (siehe Pfeil in Bild A-1). Die Prüfung erfolgt binär mit

0:= Anforderung nicht erfüllt

1:= Anforderungen sind erfüllt

Dateninput löschen | Watchlist

		Liefertreue											aktueller Monat		
	Vormonate	Feb 16	Mrz 16	Apr 16	Mai 16	Jun 16	Jul 16	Aug 16	Sep 16	Okt 16	Nov 16	Dez 16	Jan 17		
Lieferantennummer	Lieferantenname	Liefertreue	Liefertreue	Liefertreue	Liefertreue	Liefertreue	Liefertreue	Liefertreue	Liefertreue	Liefertreue	Liefertreue	Liefertreue	Liefertreue	Availability 12 months	Availability 2 months
L1	Lieferant 1	0,67	0,92	0,91	0,77	0,89	0,65	0,95	0,85	0,73	0,8	0,62	0,53	1	1
L2	Lieferant 2	0,68	0,7	1	1	1	0,72	0,88	0,7	0,83	0,8	0,58	0,67	1	1
L3	Lieferant 3	0,48	0,37	0,31	0,4	0,47	0,49	0,47	0,35	0,3	0,4	0,5	0,67	1	1
L4	Lieferant 4	0,76	0,92	0,93	1	1	0,97	0,86	0,97	0,86	0,82	0,95	0,81	1	1
L5	Lieferant 5	0,94	0,97	1	1	1	0,97	1	0,95	1	1	0,92	0,84	1	1
L6	Lieferant 6	1			1	1		0			1			0	0

Bild A-1: Dateninput und Prüfung der Mindestvoraussetzung der Watchlist
Quelle: Eigene Darstellung

Alle Daten, welche die Anforderungen erfüllen, werden für die folgenden Berechnungen im Rahmen des Trend- und Prognosemodells berücksichtigt. Somit entfällt für die weitere Betrachtung Lieferant L5, da dieser beide Mindestvoraussetzungen nicht erfüllt.

Nun wird der Anstieg b der linearen Regression, wie in Kapitel 4.3.1 beschrieben, berechnet.

Liefertreue

Vormonate		Regression analysis to n month				
Supplier Number		n	arithmetic average x	arithmetic average y	a	b
L1	Lieferant 1	12	6,5	0,774166667	0,888484848	-0,017587
L2	Lieferant 2	12	6,5	0,796666667	0,891666667	-0,014615
L3	Lieferant 3	12	6,5	0,434166667	0,365757576	0,010524
L4	Lieferant 4	12	6,5	0,904166667	0,923484848	-0,002972
L5	Lieferant 5	12	6,5	0,965833333	1,003787879	-0,005839

Bild A-2: Berechnung der linearen Regression
Quelle: Eigene Darstellung

Als Ergebnis wird der Trendverlauf über 3 und 12 Monate der linearen Regression (Pfeile als Indikation für den Verlauf in den entsprechenden Spalten) in der „Watchlist“ dargestellt:

Watchlist - Indikator für kritische Lieferanten
Datum: 2016

				PRÄVENTIV 12 Monate	PRÄVENTIV 3 Monate	REAKTIV Rang
		Leistungsbeschreibende Kriterien				
Information		Liefertreue				
Lieferanten-nummer	Auswahl für das Diagramm	aktueller Monat	Prognose t+1	12-Monats Trend	3-Monats Trend	Rang (aktuell)
L5		84%	93%	→	↓	5
L1	x	53%	69%	↘	↓	1
L2		67%	74%	↘	↘	2
L4		81%	88%	→	→	4
L3		67%	49%	↗	↑	2
L6						

Bild A-10: Darstellung der Watchlist für den Beispieldatensatz
Quelle: Eigene Darstellung

Anhang B

Für die Ermittlung potenziell kritischer Lieferanten, wird in der vorliegenden Arbeit, wie bereits in Kapitel 4.3 beschrieben, als Vorbereitung zur Assoziationsanalyse die Clusteranalyse für metrische Datentypen (Kapitel 4.6.4) angewendet.

Beispielhaft wird nun die Kennzahl Liefertreue hierarchisch geclustert. Für eine hierarchische Clusterbildung werden die Merkmalsausprägungen der Kennzahl Liefertreue (LT) zunächst aufsteigend sortiert. Dazu werden beispielhaft die aus deinem Forschungsprojekt anonymisierten, aktuellen Werte (Merkmalsausprägungen) der Lieferanten L1 bis L5 aus Tabelle A-1 verwendet.

Tabelle B-1: Sortieren der zu clusternden Merkmalsaufprägungen
Quelle: Eigene Darstellung

Lieferantennummer	L1	L2	L3	L4	L5
Merkmalsausprägung LT	95%	61%	48%	96%	
Zugeordneter Index	I{1}	I{2}	I{3}	I{4}	I{5}

Da der Lieferant L5 keine Merkmalsausprägung für den aktuellen Monat besitzt, entfällt dieser wiederum für die weiteren Betrachtungen. Für die Merkmalsausprägungen der Liefertreue von Lieferant L1 bis L4 ergibt sich folgende Distanzmatrix D:

$$D = \begin{pmatrix} 0 & 34 & 47 & 1 \\ 34 & 0 & 13 & 35 \\ 47 & 13 & 0 & 48 \\ 1 & 35 & 48 & 0 \end{pmatrix} \begin{matrix} \text{I\{1\}} \\ \text{I\{2\}} \\ \text{I\{3\}} \\ \text{I\{4\}} \end{matrix}$$

I{1} I{2} I{3} I{4}

Zur Bestimmung der Distanzmatrix werden die minimalen Distanzen zwischen den einzelnen Merkmalsausprägungen in die Distanzmatrix D eingetragen. Die minimalen Abstände werden, wie in Kapitel 4.3.2, Formel (10) beschrieben, folgendermaßen errechnet:

$$dist(\alpha, \beta) = |\alpha_1 - \beta_1| + \cdots + |\alpha_d - \beta_d|$$

Die Merkmalsausprägungen mit den kleinsten Abständen werden zu Clustern zusammengefasst (Kapitel 4.3, Formel (11)):

$dist(\mathrm{A}, \mathrm{B}) = \ min\ dist(\alpha, \beta)$, wobei $\alpha \in \mathrm{A}, \beta \in \mathrm{B}$

Dies erfolgt so lange, bis nur noch ein Custer verbleibt. Die einzelnen Schritte der Clusterbildung werden nun am Beispiel der Distanzmatrix D näher erläutert.

Die kleinste Distanz der Distanzmatrix ist 1 (Kennzeichnung in Distanzmatrix D). Somit wird zunächst der Index {1} mit Index {4} verschmolzen:

$$D_{\{1,4\}.\{2\}} = \min\left\{D_{\{1\}.\{2\}}, D_{\{4\}.\{2\}}\right\} = \min\ \{34{,}35\} = 34$$

$$D_{\{1,4\}.\{3\}} = \min\left\{D_{\{1\}.\{3\}}, D_{\{4\}.\{3\}}\right\} = \min\ \{47{,}48\} = 47$$

Das Ergebnis des ersten Schrittes der hierarchischen Clusteranalyse ergibt folgende neue Distanzen:

Tabelle B-2: Ergebnis des ersten Schrittes der Clusteranalyse
Quelle: Eigene Darstellung

Schritt	{1,4}	{2}	{3}
{1,4}	0	34	47
{2}	34	0	13
{3}	47	13	0

Mit einer minimalen Distanz in der Distanzmatrix (Tabelle B-2) von 13 (Kennzeichnung in Tabelle B-2) wird nun das Cluster {2,3} mit dem Index {2} und {3} gebildet:

$$D_{\{2,3\}.\{1.4\}} = \min\left\{D_{\{2\}.\{1.4\}}, D_{\{3\}.\{1.4\}}\right\} = \min\ \{34{,}47\} = 34$$

Das Cluster {1,2,3,4} hat somit eine Distanz von 34. Das Ergebnis der Clusteranalyse auf Basis der Kennzahl Liefertreue wird in einem Dendrogramm dargestellt (Bild B-1Bild).

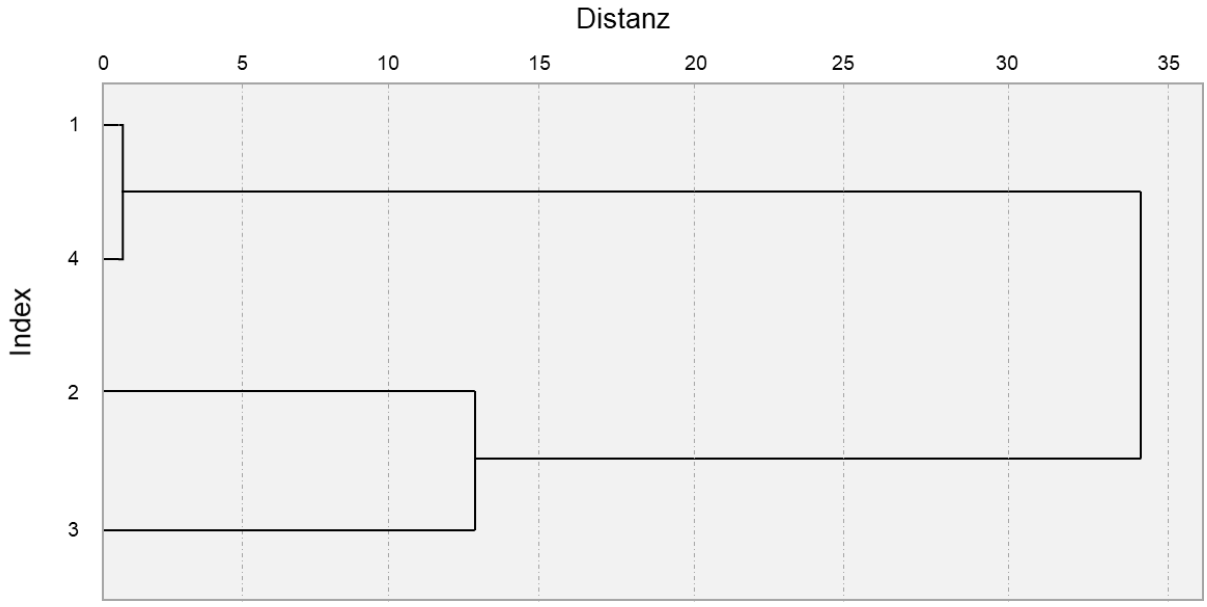


Bild B-1: Dendrogramm der Clusterbildung auf Basis der manuellen Berechnung
Quelle: Eigene Darstellung

Es ergeben sich verschiedene Cluster je größer die minimale Distanz wird. Auf dem Dendrogramm ist zu sehen, dass je Schritt dieser manuellen Berechnung die entsprechenden Cluster zusammengefasst werden.

Im Weiteren stellt sich die Frage, welche Clusteranzahl optimal ist. Zur Ermittlung der optimalen Clusteranzahl wird das Verschmelzungsniveau bzw. der Distanzzuwachs zwischen den einzelnen Clustern, wie in Kapitel 4.3.2 beschrieben, verwendet. Für das vorliegende Beispiel ergibt dies:

Tabelle B-3: Verschmelzungsniveau und Distanzzuwachs der Cluster
Quelle: Eigene Darstellung

Anzahl der Cluster c	Zu verschmelzende Objekte	Verschmelzungs-niveau	Distanz-zuwachs
3	{1}-{4}	1	1-0=1
2	{1,4} und {2}-{3}	13	13-1=12
1	{1,4}-{2,3}	34	34-13=21

Der Distanzzuwachs der Cluster steigt In Tabelle B-3 kontinuierlich an. Im vorliegenden Beispiel würde eine die Anzahl der Cluster c von $c = 3$ gewählt werden, da der Distanzzuwachs ab $c = 2$ stark zunimmt.

Anhang C

In Kapitel 4.3.4 wird die Gesamtanzahl aller möglichen Assoziationsregeln errechnet. Mit Tabelle C-1 wird das Ergebnis der formulierten Formel (13) validiert. Dazu werden in diesem Anhang vier Attribute zur Generierung der Assoziationsregeln verwendet. Es ergibt sich folgende Darstellung:

- Liefertreue (LT)
- parts per million (ppm)
- (Produktions-)Standort (PS)
- Anzahl der Mitarbeiter

Tabelle C-1: Zuordnung von vier Attributen zu Regelkopf und Regelrumpf
Quelle: Eigene Darstellung

	LT	ppm	PS	AM	LT, ppm	LT, PS	LT, AM	ppm, PS	ppm, AM	PS, AM	LT, ppm, PS	LT, ppm, AM	LT, AM, PS	ppm, AM, PS	LT, ppm, AM, PS	Summe
LT	0	1	1	1	0	0	0	1	1	1	0	0	0	1	0	
ppm	1	0	1	1	0	1	1	0	0	1	0	0	1	0	0	
PS	1	1	0	1	1	0	1	0	1	0	0	1	0	0	0	
AM	1	1	1	0	1	1	0	1	0	0	1	0	0	0	0	
LT, ppm	0	0	1	1	0	0	0	0	0	1	0	0	0	0	0	
LT, PS	0	1	0	1	0	0	0	0	1	0	0	0	0	0	0	
LT, AM	0	1	1	0	0	0	0	1	0	0	0	0	0	0	0	
ppm, PS	1	0	0	1	0	0	1	0	0	0	0	0	0	0	0	
ppm, AM	1	0	1	0	0	1	0	0	0	0	0	0	0	0	0	
PS, AM	1	1	0	0	1	0	0	0	0	0	0	0	0	0	0	

Tabelle C-1: Zuordnung von drei Attributen zu Regelkopf und Regelrumpf (Fortsetzung)

	LT	ppm	PS	AM	LT, ppm	LT, PS	LT, AM	ppm, PS	ppm, AM	PS, AM	LT, ppm, PS	LT, ppm, AM	LT, AM, PS	ppm, AM, PS	LT, ppm, AM, PS		
LT, ppm, PS	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0		
LT, ppm, AM	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0		
LT, AM, PS	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0		
ppm, AM, PS	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
LT, ppm, AM, PS	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
Summe																	50

Anhang D

Der Anhang D stellt grundsätzlich die Open-Source-Bibliotheken vor, auf die zur Programmierung des *Analyzers* zurückgegriffen worden ist. Die Open-Source-Bibliotheken unterstützen die Programmierungsarbeiten mit vordefinierten und frei zugänglichen Programmcodes. Zur Abgrenzung zwischen Open-Source-Bibliothek und eigener Entwicklung dient Bild B-1. Dabei interagiert die eigene Entwicklung des *Analyzers* mit der entsprechenden Bibliothek. Zunächst werden die Open-Source-Bibliotheken für das Aussehen (Framework) des *Analyzers* vorgestellt.

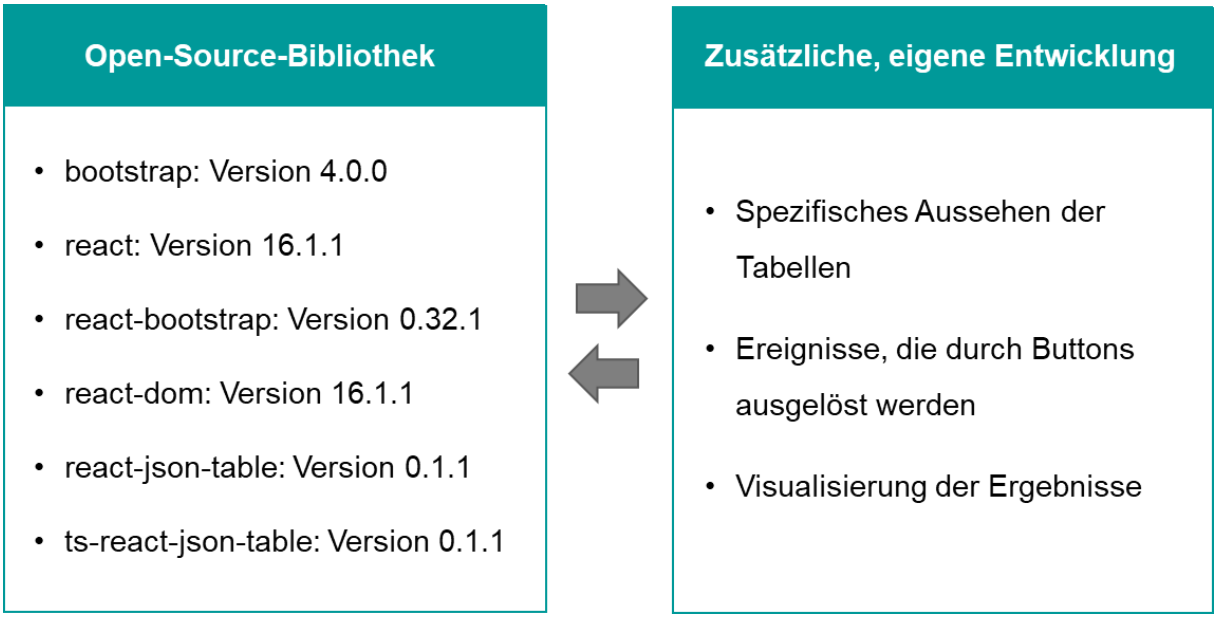


Bild B-1: Abgrenzung der Open-Source-Bibliotheken zum Framework zur zusätzlichen, eigenen Entwicklung
Quelle: Eigene Darstellung

Zusätzlich zum Aussehen des *Analyzers* wurde eine Open-Source-Bibliothek für die Clusteranalyse verwendet. Auch hier dient Bild B-2 der Abgrenzung zwischen den Umfängen der Open-Source-Bibliothek und der zusätzlichen, eigenen Entwicklung. Ebenso interagiert die eigene Entwicklung des *Analyzers* mit der entsprechenden Bibliothek.

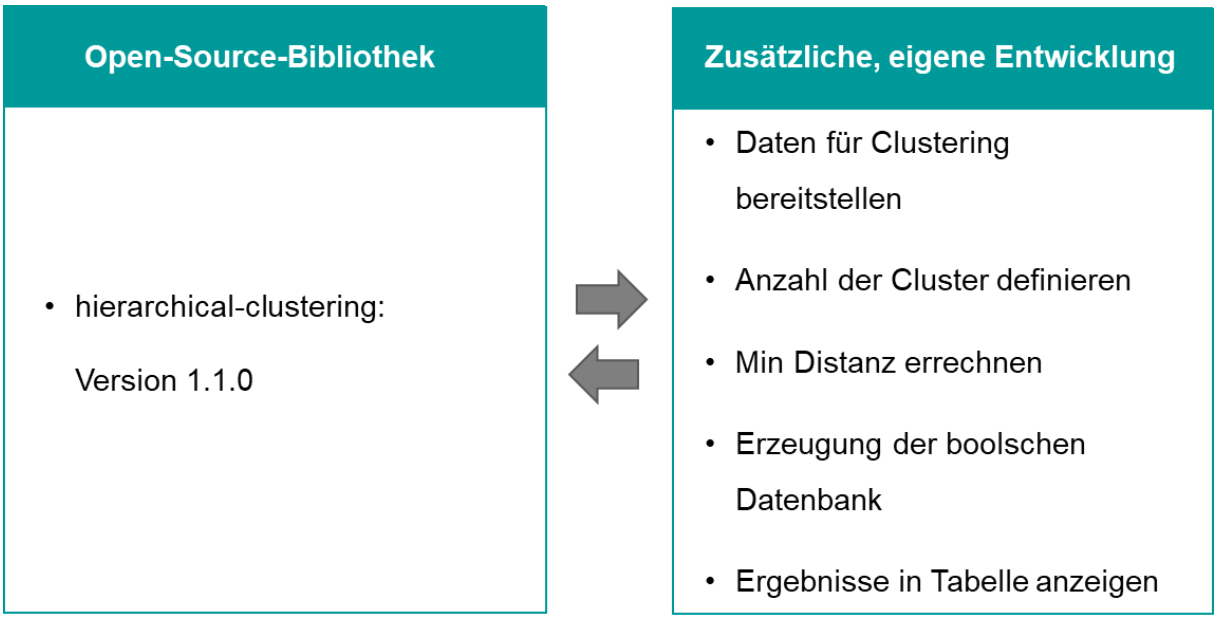


Bild A-2: Abgrenzung der Open-Source-Bibliothek der Clusteranalyse zur zusätzlichen, eigenen Entwicklung
Quelle: Eigene Darstellung

Da die Anwendung für Windows-Applikationen optimiert ist, werden zwei zusätzliche Open-Source-Bibliotheken eingebunden, die zum Ausführen der Windows-Applikationen erforderlich sind:

- electron-packager: Version 11.1.0
- shelljs: Version 0.8.1

Durch den electron-packager kann beispielsweise die Funktion des Dateien Speicherns ausgeführt werden. Die Open-Source-Bibliothek shelljs ist dafür zuständig, dass der *Analyzer* durch eine Anwendung in Form einer .exe ausgeführt werden kann.

Anhang E

Im folgenden Anhang E ist der verwendete Source-Code für den Analyzer dokumentiert. Die Programmiersprache ist Java Script. Für eine optimale Orientierung ist der Sourcecode im Weiteren kommentiert. Die Kommentare sind farblich gekennzeichnet.

```
////////////////////////////////////////////////////////////////////////////////////////////
/////////////////////////////////// Hilfsfunktionen/ ///////////////////////////////////////
////////////////////////////////////////////////////////////////////////////////////////////

//Einbindung von Bibliotheken, damit diese über die gesamte Anwendung zur Verfügung stehen
const path = window.require('path')
const {app} = window.require('electron').remote
const saveDir = app.getPath('appData') + '/SupplierAnalyzerStore';

function loadFile(pathToFile){
    var fs = window.require('fs')
    console.log("Loading file data at: " + pathToFile)
    return fs.readFileSync(pathToFile)
}

//save file - Zwischenspeicherung auf der Festplatte, damit Daten später verarbeitet werden können
function saveFile(dir,file, data){
    var fs = window.require('fs')

    try {
        if (!fs.exists(dir)) {
            console.log('try creating dir')
            fs.mkdir(dir, function (err) {
                if(err){
                    console.log(err);
                }
            });
```

```
            console.log('Creating dir.. ' + dir )
        }
        var fileName = dir + '/' + file;
        fs.writeFileSync(fileName, data , 'utf-8');
        console.log('Store data at: ' + fileName)
        return true;
    } catch(e) {
        console.log("Loading error" + e);
        return false;
    }
}

/**
 * function to load the basic data for analyzing process - csv-Datei wird für den Datenimput verwendet
*/
exports.loadCSV = function(pathToData){
    var result = "";
    var data = loadFile(pathToData)

    //commas to dots
    data = data.toString().replace(/,/g , ".");
    result = csvToJSON(data);
    //backup data
    saveFile(saveDir, 'backupBasicData.json', result)
    if(saveFile(saveDir, 'basicData.json', result)) {return true;}
}

/**
 * function parse csv to json - Datentransformation für zur Datenverarbeitung innerhalb des Analyzers
 * @return json as string
 */
function csvToJSON(csv){
```

```
    csv = csv + '';
    var lines=csv.split("\n");
    var result = [];
    var headers=lines[0].split(";");

    for(var i=1;i<lines.length;i++){

        var obj = {};
        var currentline=lines[i].split(";");
        for(var j=0;j<headers.length;j++){
            if(currentline[j]===''){currentline[j]="-"}
            obj[headers[j]] = currentline[j];
        }
     result.push(obj);
  }

  var str = JSON.stringify(result) //JSON
  str = str.replace(/(?:\\[rn])+/g , "");
  return str;
}

exports.loadStoredData = function (name){
    var saveDir = app.getPath('appData') + '/SupplierAnalyzerStore/' + name;
    var data = loadFile(saveDir)
    return data.toString()
}
```

```
////////////////////////////////////////////////////////////////////////////////////////////
////////////////////////////////////// CLUSTERING //////////////////////////////////////////
////////////////////////////////////////////////////////////////////////////////////////////

/**
 * transforming dataset into dataset of type bool - Erzeugung der boolschen Datenbank
 * -> calling clusterData for all headers
*/
exports.transformData = function(clusterQty){
    var data = loadFile(saveDir + '/basicData.json')
    data = JSON.parse(data);
    var first = true;
    var obj = data[1];
    for(var prop in data[0]){
        if(!first){
            if(/[a-zA-Z].*/.test(obj[prop])){
                console.log('Cluster string column')
                clusterStringCloumn(prop)
            } else {
                console.log("Starting clustering for column: " + prop)
                clusterData(prop, clusterQty);
            }
        }
        first = false;
    }
}

function clusterStringCloumn(column){
    var data = loadFile(saveDir + '/basicData.json');
    data = JSON.parse(data);
    var cluster =[];
    var tmpColumnData = [];
```

```
    for(let i = 0; i<data.length; i++){
        let obj = data[i];
        tmpColumnData.push(obj[column]);
        if(!exists(cluster, obj[column])){
            cluster.push(obj[column]);
        }
    }

    //generate json with cluster
    var resultJson = [];
    while(tmpColumnData.length != 0){
        var json = {};
    for(var i = 0; i<cluster.length; i++){
        var item = tmpColumnData[0]
        var value  = cluster[i]
        if(value === item){
            json[value] = "1";
        } else {
            json[value] = "0";
        }
    }
    tmpColumnData.shift();
    resultJson.push(json);
    }

    //insert json into main data and save
    var tmpData = [];
    for(i = 0; i<data.length; i++){
        var obj = data[i]
        delete obj[column]
        var tmp = resultJson[i];
        for (var prop in tmp) {
           obj[prop] = tmp[prop];
```

```
        }
        tmpData.push(JSON.stringify(obj))
    }
    data = tmpData

    //saving file
    data = "[" + data + "]";

    saveFile(saveDir, '/basicData.json', data)

}

/*
* Clustering data - Clusteranalyse der metrischen Datentypen
*/
function clusterData(column, clusterQty){
    //load basicData.json
    var data = loadFile(saveDir + '/basicData.json');

    var obj =[]

    //processing clustering
        data = JSON.parse(data);
        var tmpColumnData = [];
        for(var i = 0; i < data.length; i++){
            //example: data[i] => {Lieferant: 1, Liefertreue: 0.6, ppm: 7}
            obj = data[i];
            tmpColumnData.push(obj[column]);
        }

        tmpColumnData = JSON.stringify(tmpColumnData)
        tmpColumnData = JSON.parse(tmpColumnData)
        var tmpObj = [];
```

```
//tmpColumnData == all values of the column
//remove all ' - ' of tmpColumnData
for(var i = 0; i<tmpColumnData.length; i++){
   if(tmpColumnData[i] != '-'){
      tmpObj.push(tmpColumnData[i])
   }
}

var cluster = hierachichelClustering(tmpObj, column, clusterQty);

//generate json with cluster
var resultJson = [];
while(tmpColumnData.length != 0){
   var json = {};
for(i = 0; i<cluster.length; i++){
   var item = tmpColumnData[0]
   obj = cluster[i]
   var min = parseFloat(obj['min'])
   var max = parseFloat(obj['max'])
   item = parseFloat(item)
   if(min <= item && item <= max){
      json[column + 'C' + i] = "1";
   } else {
      json[column + 'C' + i] = "0";
   }
}
tmpColumnData.shift();
resultJson.push(json);
}

//insert json into main data and save
var tmpData = [];
for(i = 0; i<data.length; i++){
```

```
            obj = data[i]
            delete obj[column]
            var tmp = resultJson[i];
            for (var prop in tmp) {
               obj[prop] = tmp[prop];
            }
            tmpData.push(JSON.stringify(obj))
        }
        data = tmpData

        //saving file
        data = "[" + data + "]";

        saveFile(saveDir, '/basicData.json', data)
}

exports.getClusterBorders = function(name){
    let re = /(C\d+)/;
    let basicName = name.replace(re, "");
    var saveDir = app.getPath('appData') + '/SupplierAnalyzerStore/clusterSchema' + basic-
Name + '.json';
    var data = loadFile(saveDir)
    data = JSON.parse("[" + data + "]");
    re = /(C)(\d+)/
    let arr = name.match(re)
    let clusterIndex = arr[2]
    let resultStr = data[clusterIndex].min + '...' + data[clusterIndex].max
    return resultStr
}

/**
 * hierarchische Clusteranalyse
 * * @param {*} data
```

```
 * @param {*} name
 */
function hierachichelClustering(data, name, clusterQty){
    console.log("Clustering column: " + name);
    //princip see here https://www.npmjs.com/package/hierarchical-clustering
    var cluster = require('hierarchical-clustering');
    //data must have follow structure: [[1], [5], [9], [12], [2], ...]
    var input = []
    var singleObj = []
    for(var i = 0; i<data.length; i++){
        if(data[i]!=""){
            input.push(JSON.parse("[" + data[i] + "]"))
        }

    }

    //distance function of the clustering algorithm
    function distance(a, b) {
        var d = 0;
        for (var i = 0; i < a.length; i++) {
          d += Math.pow(a[i] - b[i], 2);
        }
        return Math.sqrt(d);
      }

    //linkage function of the clustering algorithm
    function linkage(distances) {
        return Math.min.apply(null, distances);
    }

    var levels = cluster({
        input: input,
        distance: distance,
```

```
        linkage: linkage,
        minClusters: clusterQty,
      });

    var clusters = levels[levels.length - 1].clusters;

    clusters = clusters.map(function (cluster) {
        return cluster.map(function (index) {
                return input[index];
        });
    });

    //sorted cluster saved in clusters
    //generate cluster schema
    cluster = [];
    for(var i = 0; i<clusters.length; i++){
        var obj = clusters[i]
        var min = obj.reduce(function(a, b) {
            return Math.min(a, b);
          });
        var max = obj.reduce(function(a, b) {
            return Math.max(a, b);
          });
        var schema = "{\"min\": \" " + min + " \", \"max\" : \" " + max + " \"}"
        cluster.push(schema)
    }

    saveFile(saveDir, 'clusterSchema' + name + '.json', cluster)
    cluster = "[" + cluster + "]";
    return JSON.parse(cluster);
}
```

```
////////////////////////////////////////////////////////////////////////////////////////////
////////////////////////////////////// Assoziationsanalyse ////////////////////////////
////////////////////////////////////////////////////////////////////////////////////////

/**
 * dummy function for calling other functions
*/
exports.calculateProbability = function(){
    let combinations = []
    //get all header rows
    var data = loadFile(saveDir + '/basicData.json');
    data = JSON.parse(data);
    let headers = []
    for(var prop in data[0]){
        headers.push(prop)
    }
    //remove id column
    console.log(headers)
    headers.shift()
    var originHeaders = headers;

    for(var a = 0; a<=0; a++){
        const size = 15;
        var begin = (a*size) % originHeaders.length;
        var end = (begin+size) % originHeaders.length;

        //console.log("Next" + begin + "/" + end);
        headers = originHeaders.slice(begin, end);

        //combin all headers to [{[..], [...]}, {[..], [..]}, ...]
        for(let i = 0; i<headers.length; i++){
            for(let j=1; j<headers.length; j++){
                //j range of the first part
```

```
            let tmpObj = headers
            tmpObj = JSON.stringify(tmpObj)
            tmpObj = JSON.parse(tmpObj)

            tmpObj.splice(i, j) //tmpObj => headers without the current header entry of the loop

            for(let h=0; h<=tmpObj.length; h++){
               //h is the size
               for(let l=0; l<h; l++){
                  //l is the index
                  let firstPart = tmpObj.slice(i, j+i)
                  let secondPart = tmpObj.slice(l, l+h)
                  let firstEl = firstPart;
                  let secondEl = secondPart;
                  let valid = true;

                  for(let a = 0; a<firstEl.length; a++){
                     if(exists(secondEl, firstEl[a])){
                        valid = false;
                     }
                  }
                  for(let a = 0; a<secondEl.length; a++){
                     if(exists(firstEl, secondEl[a])){
                        valid = false;
                     }
                  }

                  if(!exists(combinations, [firstEl, secondEl]) && JSON.stringify(firstEl) != "[]" &&
valid){
                     combinations.push([firstEl, secondEl])
                  }

                  let result = "";
```

```
                    let rule = JSON.stringify(firstPart) + '=>' + JSON.stringify(secondPart)
                    let supportVal = support(firstPart, secondPart)
                    let confidenceVal = confidence(firstPart, secondPart)
                    let liftVal = lift(firstPart, secondPart)
                    rule = rule.replace(/\"/g, '');
                    result += "{"
                    result += "\"rule\": \"" + rule +"\","
                    result += "\"support\": \"" + supportVal + "\","
                    result += "\"confidence\": \"" + confidenceVal + "\","
                    result += "\"lift\": \"" +  liftVal +"\""
                    result += "}"
                    result = JSON.parse(result)

                    result.matchesOn = getSupplier(result.rule)
                    var fs = window.require('fs')
                    fs.appendFileSync("/Users/matthias/Desktop/anja.txt", JSON.stringify(result)
+ "\n", 'utf-8');
                    console.log("Regel: " + JSON.stringify(result));


                }
            }
        }
    }
}


    let resultObj = []
    console.log(combinations)
        return resultObj;
}
```

```
////////////////////////////////////////////////////////////////////////////////////////////////////////////////////
//// teilweise Relevanzprüfung mit Berechnung der Interessantheitsmaße/////////////
////////////////////////////////////////////////////////////////////////////////////////////////////////////////////
```

//Hilfsfunktion, damit keine doppelten Attribute in der quantitativen Assoziationsregel erscheinen

```
/**
 * exists b in a?
 */
function exists(a, b){
    for(let i = 0; i<a.length; i++){
        if(JSON.stringify(a[i]) === JSON.stringify(b)){
            return true;
        }
    }
    return false;
}
```

//Berechnung der Interessantheitsmaße

```
/**
 *
 * @param {*} a [column1, column2, ... columnN]
 * @param {*} b [column1, column2, ... columnN]
 * calculating support of a => b ( sup(a=>b) )
 */
function support(a, b){
    //optional b
    if(b === undefined){b = [] }
    var data = loadFile(saveDir + '/basicData.json');
    data = JSON.parse(data);

    var count = 0;
```

```
    for(var i = 0; i<data.length; i++){
        //for each row ...
        var obj = data[i]
        var indexColumn = true;
        var result = 1;
        for (var prop in obj){
            if(!indexColumn){
                if(a.includes(prop)|| b.includes(prop)){
                  //relevant column
                  result = result * obj[prop]
                }
            }

            indexColumn = false;
        }
        if(result == 1) {count++}
    }

    return Number(count/data.length).toFixed(2)
}

/**
 *
 * @param {*} a [column1, column2, ... columnN]
 * @param {*} b [column1, column2, ... columnN]
 * calculating confidence of a => b (confidence(a=>b))
 */
function confidence(a, b){
    if(!isNaN(support(a, b) / support(a))){
        return Number(support(a, b) / support(a)).toFixed(2)
    } else {
        return '-'
    }
```

```
}

/**
 *
 * @param {*} a [column1, column2, ... columnN]
 * @param {*} b [column1, column2, ... columnN]
 * calculating lift of a => b (lift(a=>b))
 */
function lift(a, b){
    if(!isNaN((support(a, b))/(support(a) * support(b)))) {
        return Number((support(a, b))/(support(a) * support(b))).toFixed(2)
    } else {
        return '-'
    }
}
```

```
////////////////////////////////////////////////////////////////////////////////////////////////////////////////////////////////////////////
      Ausgabe, welche Lieferantennummer auf eine quantitative Assoziationsregel zutrifft
//////////////////(zum Erhalten von Teilmengen aus Lieferantenbasis pro Regel)/////////////////////////////


/**
 * getting suppliers which matchs the rule
 * @param {*} rule
 */
exports.getSupplier = function(rule){
      //load data
      var data = loadFile(saveDir + '/basicData.json')
      data = JSON.parse(data);
      console.log(data)
      //transforming rule
      rule = rule.replace(/^\[(.*)\]=>\[(.*)\]$/, "\$1,\$2")
      let ruleArr = rule.split(',')
      let suppliers = []
      for(let i=0; i<data.length; i++){
         let obj = data[i]
         let matches = true;
         for(let j=0; j<ruleArr.length; j++){
            if(obj[ruleArr[j]] != undefined){
               if(obj[ruleArr[j]] !=1){
                  matches = false;
               }
            }
         }
         if(matches){
            suppliers.push(obj)
         }
      }

      return suppliers
```

```
}

function getSupplier(rule){
    //load data
    var data = loadFile(saveDir + '/basicData.json')
    data = JSON.parse(data);
    console.log(data)
    //transforming rule
    rule = rule.replace(/^\[(.*)\]=>\[(.*)\]$/, "\$1,\$2")
    let ruleArr = rule.split(',')
    let suppliers = []
    for(let i=0; i<data.length; i++){
        let obj = data[i]
        let matches = true;
        for(let j=0; j<ruleArr.length; j++){
            if(obj[ruleArr[j]] != undefined){
              if(obj[ruleArr[j]] !=1){
                  matches = false;
              }
            }
        }
        if(matches){
            suppliers.push(obj.Lieferantennummer)
        }
    }

    return suppliers
}
```

Anhang F

Der Anhang F stellt die Anwendung des *Analyzers* dar. Diese Anwendung ist als .exe im Rahmen der vorliegenden Arbeit als CD übergeben worden.