

ARBEITSPAPIERE
ZUR
MATHEMATISCHEN WIRTSCHAFTSFORSCHUNG

**Data Mining Projekte
im unternehmerischen Umfeld:
Eine empirische Studie
deutscher Unternehmen**

Andreas Hilbert

Heft 183/2002

Dr. Andreas Hilbert

Institut für Statistik und Mathematische Wirtschaftstheorie

Universität Augsburg

Universitätsstraße 16, D-86159 Augsburg

Telefon: (0821) 598-4150

Telefax: (0821) 598-4226

e-mail: andreas.hilbert@wiwi.uni-augsburg.de

A. Einführung

Seit Ende der Achtziger Jahre kam es in vielen Märkten zu einer deutlichen Verschärfung der Wettbewerbssituation, die Unternehmen in allen Branchen und Größen zu spüren bekamen (Raab und Lorbacher, 2002, S. 11). Dies äußerte sich unter anderem in gesättigten Märkten, austauschbaren Produkten mit immer kürzeren Produktlebenszyklen, den ständig wachsenden Ansprüchen der Kunden sowie einer erhöhten Markttransparenz mit der Folge zunehmend illoyalerer Kunden. Um den Vorsprung vor Mitbewerbern zu halten und sich Wettbewerbsvorteile zu sichern, rückte der Kunde mehr und mehr in den Mittelpunkt der unternehmerischen Aktivitäten. Dies führte zur Managementphilosophie des Customer Relationship Managements, das ab Anfang der Neunziger Einzug in Unternehmen hielt (Homburg und Bruhn, 2000, S. 7)

Das **Customer Relationship Management (CRM)** versucht dabei – als Folge der Kundenorientierung – jedem Kunden *sein* Produkt zur richtigen Zeit auf dem passenden Distributionskanal zum adäquaten Preis zukommen zu lassen. Um dies zu bewältigen, sind vor allem Informationen über Kunden unabdingbar, die ihrerseits wiederum geeignet gespeichert, ausgewertet und interpretiert werden müssen. Damit sind für einen erfolgreichen Einsatz sowohl adäquate Speichermöglichkeiten sowie geeignete Analysetools, die in der Lage sind, auch größte Datenbestände zu bearbeiten, erforderlich.

Da gleichzeitig mit der Einführung der CRM-Philosophie in die Betriebswirtschaft, bedingt durch die Fortschritte im IT-Bereich, akzeptable Speichermöglichkeiten für die Kundeninformationen, die sog. **Data Warehouses**, sowie *neue* Analysetechniken inkl. geeigneter Software-Lösungen, das sog. **Online Analytical Processing (OLAP)** und das sog. **Data Mining** sowie entsprechende **Tools**, auf den Markt kamen, wurde dem CRM und damit auch seinen Teilbereichen ein **ungeheures Potential** an Anwendungsmöglichkeiten vorausgesagt. Es kam, wie viele Studien vor allem für die sog. **CRM-Systeme** im Allgemeinen belegen, zu einer Situation, wie sie in den sechziger, siebziger und achtziger Jahren schon einmal bei der Einführung der Management Information Systeme (MIS, z.B. Chamoni, Zeschau, 1996, S. 51), der Decision Support Systeme (DDS, z.B. Heinrich, 1998, S. 190) und der Executive Information Systeme (EIS, z.B. Hummeltenberg, 1995, S. 262) zu beobachten war: Es entstand ein regelrechter Hype, jedes Unternehmen *wollte* und *sollte*, ob gerechtfertigt oder nicht, ein CRM-System installieren. Leider ist jedoch die Implementierung solcher IT-gestützter Lösungen in der

Regel **teuer**, bedarf (teurer) **Experten** und kann nur dann Erfolge liefern, wenn (genügend) Daten, d.h. Informationen über den Kunden vorliegen.

Daraus ergibt sich unmittelbar die Frage, wann und unter welchen Umständen es sich lohnt, ein CRM-System für ein Unternehmen zu installieren. Zur Beantwortung dieser Frage existieren bereits eine Vielzahl von Studien, die sich aber immer sehr allgemein mit dem Thema *CRM-System als Ganzes* beschäftigen (z.B. Wilde, Hippner, 2000 oder Holzer et al., 2000). Des Weiteren existieren auch Studien, die sich eher mit der praktischen Anwendung der CRM-Systeme oder der konkreten Anwendung einzelner Komponenten wie Data Warehouse oder Data Mining (z.B. Wilde, Hippner, 2002) auseinandersetzen. Allenfalls für die Teilkomponente *Data Warehouse* existiert eine erfolgsorientierte Studie (Dittmar, 1999) aus dem Jahre 1996, die aber eher deskriptiv angelegt und aufgrund der Schnelligkeit der IT-Branche heute bereits an Aussagekraft verloren habe dürfte. Eine sowohl theoretisch fundierte als auch empirisch unterstützte, konfirmatorisch ausgerichtete Untersuchung der Teilkomponente *Data Mining*, die die Frage klären soll, ob Determinanten, sog. **Erfolgsfaktoren**, existieren, die den Erfolg der Anwendung von Data Mining im Unternehmen und damit auch den Erfolg eines CRM-Systems beeinflussen, fehlt aber bisher völlig.

Zur Beantwortung dieser Frage soll nun diese Studie beitragen. Dazu werden zunächst einmal die konzeptionellen Grundlagen des Customer Relationship Managements und der sog. CRM-Systeme dargestellt sowie die Einbettung von Data Warehouse und Data Mining Technologie in diesem Kontext erörtert. Danach erfolgt eine Literatur gestützte Diskussion möglicher Erfolgsdeterminanten von CRM-Systemen in Hinblick auf den Einsatz von Data Mining. Die daraus abgeleiteten Hypothesen bzgl. kritischer Erfolgsfaktoren des Data Mining sollen dann im Rahmen einer empirischen Studie genauer analysiert werden. Dazu werden die Ergebnisse der Studie uni-, bi- und multivariat deskriptiv ausgewertet sowie konfirmatorisch zur Validierung der Thesen im Rahmen einer Kausalanalyse überprüft. Abschließend sollen dann noch Handlungsempfehlungen gegeben werden, die Unternehmen helfen sollen, die Implementierung und Umsetzung von Data Mining Technologien zielgerichtet voranzutreiben.

B. Customer Relationship Management, Data Warehouses und Data Mining

I. Grundlagen des Customer Relationship Managements

Der Blick in die moderne, technologisch geprägte Welt zeigt ein Bild des Umbruchs. Im Übergang vom Industrie- zum Informationszeitalter vollzieht sich in der wirtschaftlichen und gesellschaftlichen Entwicklung ein starker Wandel. Der Wettbewerb in den Märkten steigt zusehends. Die Produkte werden immer ähnlicher. Unternehmen können sich kaum noch aufgrund ihrer Kernleistung auf dem Markt positionieren. Sie müssen vielmehr dem Kunden Zusatznutzen, sog. „added values“ bieten, um sich gegenüber den Wettbewerbern hervorzuheben (Brendel, 2002, S. 17). Des Weiteren hat sich auch das traditionelle Kundenverhalten geändert. Kunden werden zunehmend illoyaler. Es gibt immer weniger Kunden, die eine langjährige, traditionelle Geschäftsbeziehung mit Unternehmen eingehen. Kunden wollen das beste Produkt, den besten Service und das zum niedrigsten Preis. Auf diese Kundenwünsche und Kundenerwartungen einzugehen, ist unabdingbar, um als Unternehmen in heutiger Zeit zu überleben und sich Wettbewerbsvorteile zu verschaffen (Brendel, 2002, S. 15).

Dennoch ist trotz dieser Veränderungen für viele Unternehmen noch immer die Produktorientierung der Mittelpunkt ihres unternehmerischen Handelns. Die oben skizzierten aktuellen Veränderungen verlangen eine Neuausrichtung der Unternehmensstrategie. Im Vordergrund muss dabei der Kunde und die Beziehung des Unternehmens zum Kunden stehen: „... products come and go, but customers remain“ (Rust et al., 2000, S. 6). In schnelllebigen, dynamischen Märkten mit sich ständig verändernden Produkten können die Kunden dem Unternehmen Stabilität bieten, während die Produkte einem dynamischen Wechsel unterliegen.

Der Aufbau langfristiger und profitabler Kundenbeziehungen sowie deren nachhaltige Pflege rückt damit in den Mittelpunkt einer modernen Unternehmensstrategie. Und genau dieses Ziel ist auch zentraler Bestandteil des sog. **Customer Relationship Managements**, auch **CRM** oder **Kundenbindungsmanagement** (Hippner, Wilde, 2001a, S. 6) genannt. CRM lässt sich dabei wie folgt definieren: „*CRM ist ein ganzheitlicher Ansatz zur Unternehmensführung. Er integriert und optimiert auf der Grundlage einer Datenbank und Software zur Marktbearbeitung sowie eines definierten Verkaufsprozesses*“

ses abteilungsübergreifend alle Kunden bezogenen Prozesse in Marketing, Vertrieb, Kundendienst, F&E, u.a. Zielsetzung von CRM ist die gemeinsame Schaffung von Mehrwerten auf Kunden- und Lieferantenseite über die Lebenszyklen von Geschäftsbeziehungen. Das setzt voraus, dass CRM-Konzepte Vorkehrungen zur permanenten Verbesserung der Kundenprozesse und für ein berufslebenslanges Lernen der Mitarbeiter enthalten.“ (Deutscher Direktmarketing Verband, 2002)

Beim CRM handelt es sich somit nicht alleine um eine Strategie oder, wie häufig auch beschrieben, um eine Technologie sondern vielmehr um eine Kombination aus beiden. Der Strategie-Aspekt bildet dabei den Hauptbestandteil und unterstreicht die neue Denkhaltung des Unternehmens, die aber erst durch die notwendige Einführung einer Software, eines sog. **CRM-Systems** zum Tragen kommen kann.

II. Customer-Relationship-Management-Systeme

Für CRM-orientierte Unternehmen steht der Kunde im Mittelpunkt ihrer Tätigkeiten. Jede Abteilung und jeder Mitarbeiter, der mit Kunden in Kontakt treten kann, sollte in diese Strategie integriert werden. Kerngedanke ist dabei, sich vom Massenmarketing zu lösen und zu einer kundenindividuellen Behandlung jedes bestehenden oder potenziellen Kunden überzugehen. Alle Kommunikationskanäle mit den Kunden müssen über alle Abteilungen hinweg koordiniert werden. Eine komplette Vernetzung aller Informationen und Interaktionen über bzw. mit einem Kunden sollte erfolgen, um jedem Mitarbeiter den Zugriff auf alle aktuell vorhandenen Kundeninformationen gewährleisten zu können. Jeder einzelne Mitarbeiter sollte wissen, was, wann und wer mit einem Kunden gesprochen und was der Kunde gesagt hat.

Um dies zu erreichen, muss neben der Neuausrichtung der Geschäftsprozesse in Bezug auf die neue Unternehmensstrategie auch ein integriertes Informationssystem im Unternehmen, ein sog. **CRM-System** eingeführt werden (Hippner, Wilde, 2001a, S. 6). Dieses System sollte zum einen die Möglichkeit bieten, allen involvierten Mitarbeitern des Unternehmens vergangenheits- und gegenwartsbezogene Informationen aller Kunden zur Verfügung zu stellen, diese Informationen anwendungsorientiert in einer Datenbank, einem sog. **Data Warehouse** zu speichern und somit zu einer Synchronisierung aller Kommunikationskanäle zum Kunden beizutragen. Der Aufbau eines „Informationsnetzes“, das konsequent genutzt werden kann, ist die Folge. Zum anderen sollte ein CRM-

System dem Unternehmen aber nicht nur erlauben, **Informationen** bzgl. der Kunden zu nutzen, vielmehr sollte auch die Möglichkeit bestehen, sich **Wissen** über den Kunden zu beschaffen; Wissen, das weniger vergangenheits- als zukunftsorientiert ist. Zur Beschaffung dieses detaillierten Wissens über den Kunden und dessen Wünsche sollten einem modernen CRM-System dabei Analyse-Werkzeuge wie **OLAP-** oder **Data Mining-**Tools zur Verfügung stehen, die auf dem Data Warehouse aufsetzen und zum Teil noch nicht bekannte Zusammenhänge bzgl. der Kunden aufzudecken im Stande sind. Dieses Wissen kann dann wiederum zur Erhöhung der Kundenloyalität und Verbesserung der Kundenzufriedenheit führen, was im Allgemeinen auch den Unternehmenserfolg steigern kann (Göttgens, 2000, S. 5.).

Gemäß der Aufgabenstellungen und Ziele ergeben sich somit drei Einsatzbereiche für CRM-Systeme, die in engen Austauschbeziehungen zueinander stehen:

- **Kommunikatives oder kollaboratives CRM (kCRM):** Steuerung, Unterstützung sowie Synchronisation aller unmittelbaren Kommunikationskanäle zum Kunden, wie Internet, Email oder Telefon. Ziel ist eine effektive und effiziente Kommunikation zwischen Unternehmen und Kunden sowie eine einheitliche Darstellung des Unternehmens gegenüber dem Kunden (*One Face to the Customer*). Zentrale Rolle spielt dabei das Customer Interaction Center (CIC) als Kommunikationsschnittstelle (Rosemann et al., 1999, S. 112).
- **Operatives CRM (oCRM):** Unterstützung aller Kunden orientierten Geschäftsprozesse, insbesondere an den Customer Touch Points *Marketing* (Marketing Automation), *Vertrieb* (Sales Automation) und *Service* (Service Automation) (vgl. z.B. Hippner, Wilde, 2000, S. 16). Es umfasst damit alle Anwendungen, die den direkten Kontakt des Unternehmens mit dem Kunden unterstützen (Front Office). Dazu gehören z.B. die bedarfsgerechte Erstellung von Direct Mails oder aber die automatisierte Weiterleitung von Beschwerden (Hippner, Wilde, 2001a, S. 14).
- **Analytisches CRM (aCRM):** Zusammenführung aller vorhandenen Kundeninformationen wie beispielsweise Kundenkontakte und Kaufhistorien in eine einheitliche Informationsgrundlage (*One Face of the Customer*). Basis ist ein *Customer Data Warehouse*, das alle Kundendaten aufzeichnet und diese mittels *OLAP-* und *Data Mining* Techniken zur Optimierung der Kunden bezogenen Geschäftsprozesse auswertet (Hippner, Wilde, 2000, S. 16).

Wie man an den Definitionen bereits erkennen kann, sind die drei Einsatzbereiche nicht unabhängig voneinander zu sehen. Vielmehr findet zwischen allen drei Bereichen ein

ständiger Austausch von Informationen statt. Vor allem zwischen dem operativen und dem analytischen CRM besteht eine enge Verbindung: Informationen aus dem operativen CRM fließen in das analytische CRM ein und werden dort ausgewertet und analysiert. Die gewonnenen Ergebnisse dienen zur Verbesserung der operativen CRM-Maßnahmen. CRM wird somit zu einem **lernenden System** (*Closed Loop Architecture*), in dem ein- und ausgehende Informationen systematisch genutzt werden, um z.B. die Kommunikation mit dem Kunden zu optimieren. Dieser Kreislauf zieht sich über alle Phasen hinweg und ermöglicht immer genauere Modelle zum Kundenverhalten.

Trotz der nicht zu unterschätzenden Bedeutung des kommunikativen CRM aus Sicht des Kunden (One Face to the Customer) sind aus der Sicht des Unternehmens vor allem die Bereiche des operativen und des analytischen CRM kritisch für den Erfolg eines CRM-Systems. Obwohl also die Gesamteffizienz eines CRM-Systems mitunter durch viele Faktoren bestimmt wird, ist die Datenbasis des operativen und des analytischen CRM, das **Customer Data Warehouse**, von zentraler Bedeutung (Schulze, 2001, S. 238) und soll im Folgenden näher betrachtet werden.

III. Data Warehouses

Ein Data Warehouse ist nach Schweizer (1999, S. 47) eine „zentrale, vom operativen Betrieb losgelöste Datenbank, auf der alle geschäftsrelevanten Daten möglichst detailliert die vollzogenen Aktivitäten beschreiben und über eine lange Zeitspanne im Data Warehouse verbleiben.“ Grundlage für die Differenzierung der Kundenbeziehung bildet im CRM somit ein (Customer) Data Warehouse, das alle Kunden bezogenen Informationen aus unterschiedlichen Quellen innerhalb und außerhalb des Unternehmens zusammenführen und verwalten kann. Typische Informationen für ein Customer Data Warehouse sind beispielsweise die Stammdaten eines Kunden (Adressdaten, Demographie, etc.), die Kaufhistorien der Kunden, die Aktionsdaten (Daten über Kundenkontakte) und auch Reaktionsdaten (z.B. Beschwerden). Ein Data Warehouse ist aber nicht nur eine „themenorientierte, integrierte, beständige und zeitorientierte Sammlung von Daten, die zur Unterstützung von Entscheidungen auf Managementebene“ (Stengl et al., 2001, S. 65) dient. Hinter einem Data Warehouse verbirgt sich mehr als nur ein „Daten-Lager“; es ist vielmehr ein System mit vielen Methoden, um aus Daten wertvolle Informationen und Wissen gewinnen zu können. Diese Umwandlung von Daten in Informa-

tionen erfolgt im Allgemeinen in fünf Phasen: Datengewinnung, -aufbereitung, -organisation, -auswertung und -interpretation (Stengl et al., 2001, S. 69). Besonders erfolgskritisch sind dabei die Phasen der Datengewinnung und -aufbereitung. Denn mitentscheidend für den Nutzen eines Data Warehouse ist die Datenqualität sowie die Pflege der Datenbank. Die Verwendung der gespeicherten Daten ist nur dann aussagekräftig, wenn keine Fehler in den Datenbeständen zu finden sind. Unvollständige, redundante und inkonsistente Daten sollten vermieden werden. Dazu ist es bei einem Data Warehouse, das Informationen aus verschiedenen Bereichen eines Unternehmens enthält, nötig, alle Fachabteilungen auf die Datenpflege aufmerksam zu machen und somit einen Qualitätsstandard zu definieren, der von allen Mitarbeitern unterstützt wird (Ahlemeyer-Stubbe, 2001, S. 27).

Das (Customer) Data Warehouse stellt bei zielgerichteter Entwicklung und entsprechender Pflege im Rahmen des CRM-Konzeptes einen grundlegenden Wissenspool dar, der im Sinne einer kontinuierlichen Optimierung der Kunden bezogenen Prozesse ausgewertet werden kann. Dies geschieht mittels verschiedener Analyseansätze, wie z.B. dem **Online Analytical Processing (OLAP)** oder dem **Data Mining**.

IV. Online Analytical Processing – OLAP

OLAP-Systeme dienen der mehr oder weniger differenzierten, intuitiven Abfrage von Datenbanken bzw. Data Warehouses. Dabei ermöglichen sie eine mehrdimensionale Sicht auf die vorhandenen Daten (Codd et al., 1993). Des Weiteren zeichnen sich OLAP Systeme durch eine einfache, intuitive und somit leicht zu erlernende Benutzerführung aus.

Das grundlegende Prinzip von OLAP ist dabei die Abbildung betriebswirtschaftlicher Maßgrößen wie Absatz, Kosten oder Marktanteilen in Form eines multidimensionalen Datenwürfels. Die Dimensionen dieses Würfels bilden betriebswirtschaftlich relevante Gliederungskriterien, wie z.B. Produkt- oder Kundengruppen, Verkaufsgebiete oder Vertriebskanäle, ab. Je nach Fragestellung können diese Dimensionen disaggregiert oder aggregiert werden. Des Weiteren können auch interessierende „Scheiben“, „Ebenen“ oder „Teilwürfel“ des ursprünglichen Datenwürfels extrahiert und dargestellt werden, um relevante Teilaspekte der Fragestellung zu beantworten (Lusti, 1999, S. 153). Damit besteht für das Management die Möglichkeit, direkt auf sehr viele unternehmensinterne

und -externe Datenquellen zu zugreifen. Meist geschieht dies über die Frontend-Schnittstelle des Data Warehouse.

Allerdings haben OLAP-Systeme in der heutigen Form eine entscheidende Einschränkung: Sie liefern lediglich eine deskriptive Darstellung der Daten. Nur mittels explizit formulierter a-priori-Hypothesen über die Art des Zusammenhangs und über die relevanten Merkmale ist eine Aufdeckung interessanter Zusammenhänge möglich. Die Komplexität der Zusammenhänge innerhalb der Daten sowie das begrenzte Zeitbudget des Managements verhindern somit Lösungen von anspruchsvollen, unscharf formulierten und somit besonders interessanten Fragestellungen. Aus diesem Grund muss die manuelle Suche nach a-priori vermuteten Zusammenhängen, wie bei einem OLAP-System, durch eine automatische Suche nach a-priori nicht vermuteten Beziehungen ergänzt werden. Dies ist die zentrale Aufgabe des **Data Mining** (Hippner, Wilde, 2001a, S. 16).

OLAP-Werkzeuge können allerdings, aufgrund ihrer Mehrdimensionalität und ihrer Benutzerfreundlichkeit, erfolgreich in der Datenaufbereitungsphase des Data Mining Prozesses eingesetzt werden. Auch zur anschaulichen Präsentation sowie zur Interpretation und Evaluation der Data Mining Ergebnisse sind OLAP-Systeme sehr sinnvoll (Wilde, 2000, S. 12).

V. Data Mining

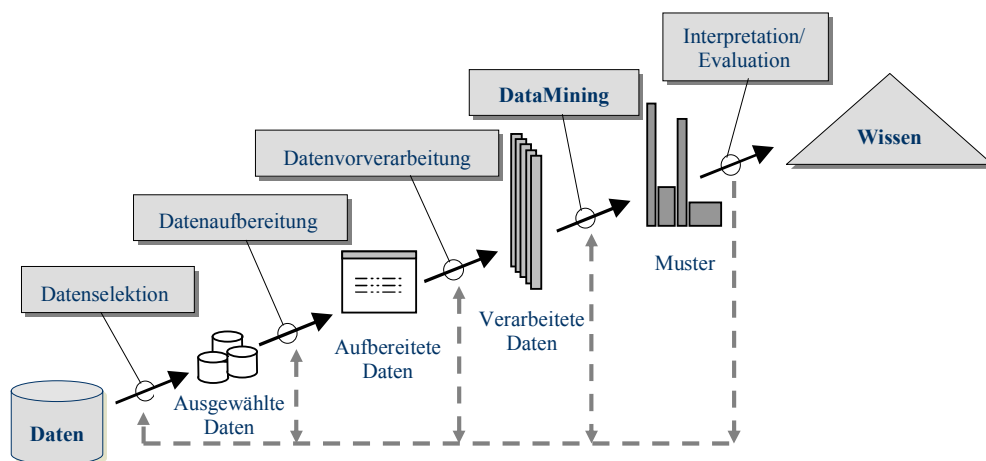
In Anlehnung an Fayyad et al. (1996) wird in dieser Arbeit unter **Knowledge Discovery in Databases** (KDD, Wissensentdeckung in Datenbanken) der nicht-triviale Prozess der Identifikation gültiger, neuer, potenziell nützlicher und verständlicher Muster in großen Datenbeständen verstanden. **Data Mining** kann dann in diesem Zusammenhang als ein Schritt im KDD-Prozess gesehen werden, in dem verschiedene Methoden zur Mustererkennung zur Anwendung kommen. Da man das Data Mining aber ebenfalls als eigenen Prozess definieren kann, der weitgehend dem des KDD entspricht, werden die Begriffe KDD und Data Mining häufig synonym verwendet. KDD kann als Data Mining im weiteren Sinn verstanden werden, während die Phase des Data Mining selbst als Data Mining im engeren Sinne betrachtet wird (Meyer, 2001, S. 568).

Hauptaufgabe des Data Mining ist die oben erwähnte **Mustererkennung**. Zur Lösung dieser Aufgabe sollen Methoden bereit gestellt werden, die in der Lage sind, aus großen

Datenmengen autonom die bedeutsamsten und aussagekräftigsten Muster zu identifizieren und diese Muster dem Anwender als interessantes Wissen zu präsentieren. Im Rahmen des CRM bedeutet dies konkret die Bearbeitung großer Datenbestände eines Customer Data Warehouse mit Hilfe von anspruchsvollen, automatischen Methoden, um neue, interessante, gesicherte und relevante Geschäftserfahrungen zu finden. Im Gegensatz zu den OLAP-Systemen sind dabei vom Anwender keine festgelegten a-priori-Hypothesen zu fordern (Wilde, 2001a, S. 13).

Die gewünschte Extraktion verborgenen Wissens vollzieht sich dabei nicht als ein einzelner Schritt, sondern im Rahmen eines **Data Mining Prozesses** (vgl. auch Abbildung 1), der von der „Selektion und Aufbereitung der Daten über das Generieren interessanter Datenmuster (das eigentliche Data Mining) bis hin zur Ergebnis-Präsentation und -Interpretation reicht.“ (Gentsch, 2000, S. 40)

Abbildung 1: Der Data-Mining-Prozess ¹



Zu beachten ist dabei, dass, entgegen der weitläufigen Meinung, auch der Data Mining Prozess nur **begrenzt automatisierbar** ist. Die IT-Systeme untersuchen zwar mit Hilfe intelligenter Algorithmen große Datenbestände „selbständig“ nach Auffälligkeiten und Mustern, dennoch ist der Mensch für die sachgerechte Datenaufbereitung sowie für die Interpretation und Umsetzung der Ergebnisse sowie für die Auswahl dieser Algorithmen verantwortlich. Somit ist Data Mining immer durch ein Zusammenspiel von Mensch und Maschine gekennzeichnet und kann nur so gut sein, wie das schwächste Glied in dieser Kette (Gentsch, 2000, S. 40).

Die Algorithmen selbst, die dem Data Mining zur Lösung der beschriebenen Aufgabe zur Verfügung stehen, stammen aus den unterschiedlichsten Fachdisziplinen. Die Wur-

zeln der Methoden sind aber vor allem im Bereich der **traditionellen Statistik** (z.B. Korrelations-, (logistische) Regressions- und Faktorenanalyse sowie Zeitreihenanalyse), der **Datenanalyse** (z.B. Cluster- und Assoziationsanalyse), der **Künstlichen Intelligenz** (z.B. Maschinelles Lernen, Neuronale Netze, Evolutionäre Algorithmen) und der **traditionellen Mustererkennung** (Pattern Recognition) zu finden (Küsters, 2000, S. 95).

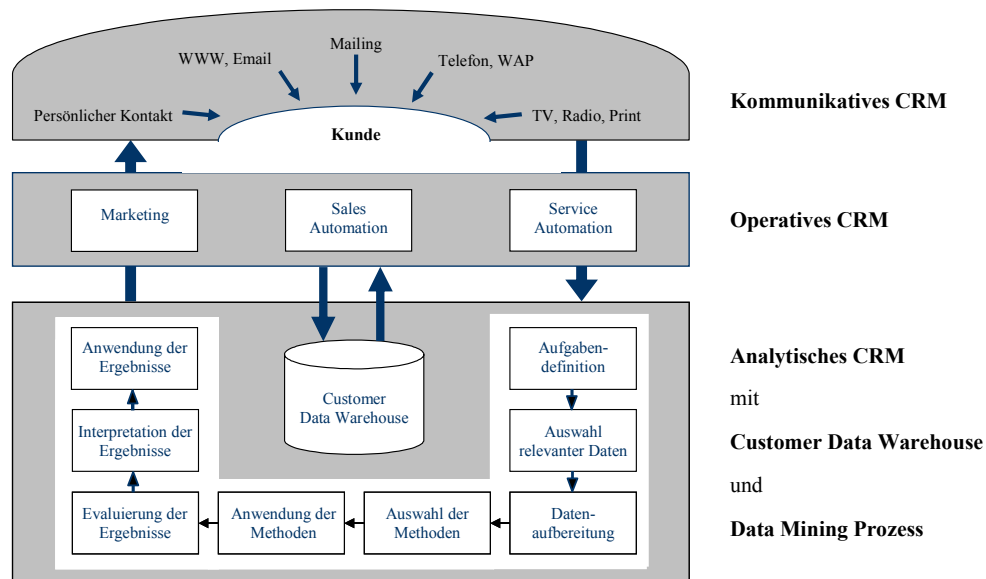
VI. Der Data Mining Prozess im CRM-Kontext

Das Customer Relationship Management konstatiert sich, wie bereits mehrfach erwähnt, im Unternehmen als Prozess, in dessen Mittelpunkt der Kunde und die den Kunden beschreibenden Daten stehen. Entscheidend ist dabei, dass in jeder Phase dieses Prozesses relevante Informationen aus den erfassten Daten zu gewinnen sind. Und die Data Mining Methoden selbst sind ein geeignetes Mittel, aus einer großen Datenmenge Informationen so zu extrahieren, dass entsprechende (CRM-)Maßnahmen direkt daraus abgeleitet werden können; ein direktes „Aufsetzen“ der Maßnahme auf die Ergebnisse der Analyse ist möglich (Poloni, Beilke, 2000, S. 14). Genauer betrachtet, erkennt man, dass das Data Mining zusammen mit dem (Customer) Data Warehouse den Teilbereich des analytischen CRM bildet, dessen Ziel die Zusammenführung aller vorhandenen Kundeninformationen in eine einheitliche **Informations- und Wissensgrundlage** ist. Diese beiden Elemente stellen einen kritischen Erfolgsfaktor für ein CRM-System dar: Funktioniert die geforderte Aufzeichnung und Analyse der Kundendaten nicht, erhält das Unternehmen keine Handlungsvorschläge für das Kundenmanagement. Das Unternehmen kennt seine Kunden also nicht gut genug und kann diese auch nicht differenziert ansprechen. Das Ziel der Kundenbindung und der Optimierung der Kunden bezogenen Prozesse wäre somit nicht realisierbar. Die entsprechende Einbindung des Data Warehouse und des Data Mining in den Kontext des CRM verdeutlicht nachfolgende Abbildung 2.

In das Data Warehouse werden ständig neue Informationen über die Kunden eines Unternehmens und die Aktions- und Reaktionsdaten von Kontakten mit den Kunden aus dem Marketing, dem Vertrieb und dem Service eingespeist. Entsprechend der Ziele und Aufgaben in den Unternehmensbereichen bzw. den Customer Touch Points werden zur Initiierung des Data Mining Prozesses geeignete Analyseverfahren ausgewählt. Die Ergebnisse dieser Analysen stellen wiederum den Ausgangspunkt für weitere Aktionen und die Optimierung der Kunden bezogenen Geschäftsprozesse dar. Zudem werden die Ergebnisse in Form von „neuem Wissen über den Kunden“ in das Data Warehouse ab-

gespeichert. Dieser Kreislauf wird kontinuierlich weiter durchlaufen (Hippner, Wilde, 2001b, S. 220).

Abbildung 2: CRM, Data Warehouse und der Data Mining Prozess



Die Einführung des Data Mining in den Ablauf eines CRM-Systems selbst verläuft in vier Phasen. Grundlage bildet die Erstellung eines Konzeptes zur Einführung der Data Mining Technik. Dies sollte stets im Rahmen einer engen Zusammenarbeit von Marketing- und Data Mining Spezialisten erfolgen. Anschließend folgt die Implementierung der erstellten Data Mining Algorithmen und Modelle sowie die Integration in das vorhandene (Customer) Data Warehouse. Dabei ist darauf zu achten, dass für die Fachabteilungen die nachfolgende Nutzung des Systems weitgehend ohne Kenntnis der zugrunde liegenden Algorithmen möglich ist (Poloni, Beilke, 2000, S. 14).

Entscheidend für die effektive und sinnvolle Nutzung des Data Mining ist die technische und fachliche Integration in die bestehende Infrastruktur des Unternehmens. Zudem muss das Data Mining im Sinne des CRM-Ansatzes global verwaltet und koordiniert werden. Diese nötige Koordination erfolgt in einem sog. Data Mining Provider (Poloni, Beilke, 2000, S. 15). Ein Data Mining Provider enthält alle Module, die für das Data Mining und dessen Management sowie für die Schnittstellen zu den Unternehmensdaten nötig sind. Dabei sollte zur besseren Akzeptanz des Data Mining für zukünftige Anwender keinerlei Methodenkenntnis vorausgesetzt werden müssen. Eine solche Automatisierung ermöglicht es dann, Analysen unkompliziert und schnell durchzuführen und umzusetzen (Poloni, Beilke, 2000, S. 15).

C. Theoretische Herleitung erfolgskritischer Faktoren

Die klassische Vorgehensweise bei der Herleitung erfolgskritischer Faktoren, die auch empirisch überprüfbar sein und normative Empfehlungen erlauben soll, ist das Studium publizierter Ergebnisse anderer erfolgsanalytischer Untersuchungen der gleichen Problemklasse, die dann im Allgemeinen den Ausgangspunkt der neuen empirischen Studie bilden (können). Die Übertragung dieser Vorgehensweise auf die hier zu untersuchenden Thematik der „Erfolgsfaktoren im Data Mining“ gestaltet sich allerdings vergleichsweise schwierig. Data Mining als professionelles und akzeptiertes Tool im Unternehmensumfeld existiert erst seit wenigen Jahren, etwa seit Mitte bis Ende der Neunziger. Damit können die meisten Unternehmen, die Data Mining betreiben, erst auf eine recht kurze Zeit der Erfahrung zurückblicken. Dies erklärt, warum derartige (auch publizierte) Studien zu Unternehmen aus Deutschland bzw. den USA, die auch konfirmatorischen Fragestellung nachgehen, bisher gänzlich fehlen.

Dementsprechend soll diese Studie eine gewisse Vorreiterrolle dieser Forschungsrichtung einnehmen und sich vor allem an vergleichbaren Studien aus dem IT-Bereich, dem CRM-System Bereich und dem Data Warehouse Bereich orientieren, wobei Expertenbefragungen die Modellierung abschließend ergänzen sollen.

I. Erfolgsfaktorenforschung

1. Systematisierung der Erfolgsfaktorenforschung

Der Begriff des Erfolgsfaktors wird in der Literatur in vielfältiger Weise und häufig sehr kontrovers verwendet. Das Konzept der kritischen Erfolgsfaktoren selbst wurde von Daniel (1961) im Kontext der Entwicklung von Managementinformationssystemen in die Diskussion eingebracht und von Rockart (1979) auch auf unternehmensumfeldspezifische Aspekte ausgeweitet. Entsprechend dem Anliegen der Erfolgsfaktorenforschung, die versucht, Einflussgrößen eines Unternehmens, einer (strategischen) Geschäftseinheit, eines Produktes oder einer Marke herauszufinden, die den Erfolg des Unternehmens, der Geschäftseinheit oder eben des Produktes bzw. der Marke beeinflussen, soll der Begriff des Erfolgsfaktors in Anlehnung an Müller (1999, S. 53) wie folgt definiert werden: „Als **Erfolgsfaktoren** sollen die Faktoren bezeichnet werden, die einen nachhaltigen und längerfristigen Einfluss auf den Erfolg des Unternehmens haben und

erfolgsfördernd sind. Durch ihren gezielten Einsatz können Wettbewerbsvorteile gegenüber der Konkurrenz erzielt werden.“

Da es unbestritten ist, dass eine sehr große Zahl von Einflussgrößen auf den Erfolg einer Unternehmung bzw. einer Geschäftseinheit einwirken, muss es somit Ziel dieser Forschungsrichtung sein, die wesentlichen Determinanten des Erfolgs, die sog. **kritischen Erfolgsfaktoren**, zu extrahieren. Die Beschränkung der Analyse auf die als wesentlich erachteten Einflussgrößen des Erfolgs ermöglicht eine Reduktion der im Allgemeinen sehr komplexen Wirkungszusammenhänge und ist auch wissenschaftlich vertretbar, da die Analyse aller denkbaren Einflussgrößen aufgrund der offensichtlich vorhandenen wenigen *Schlüsselfaktoren* nicht notwendig ist (vgl. z.B. Daschmann, 1994, S. 12).

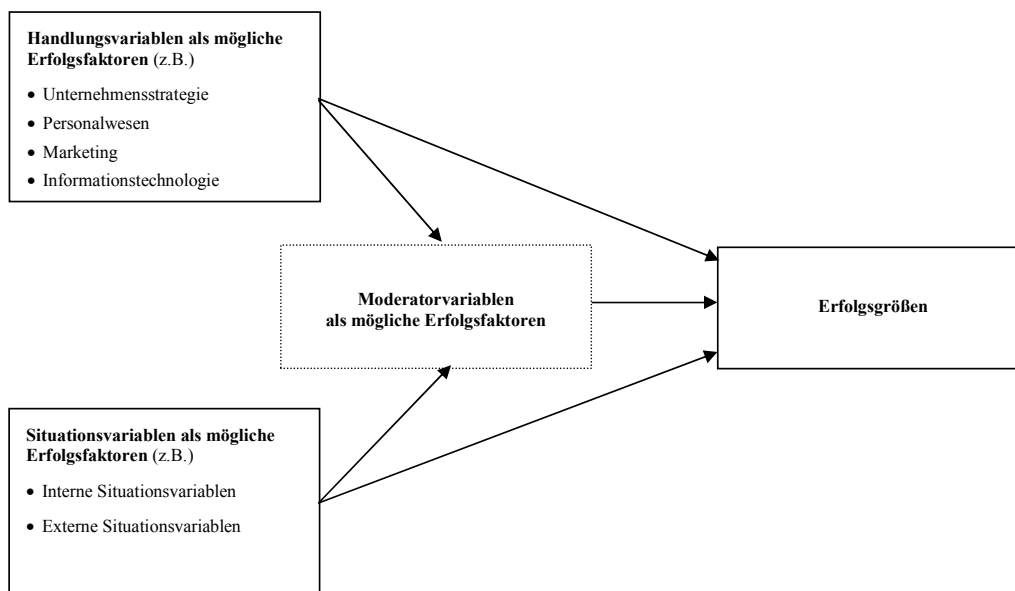
Hilfreich ist im Weiteren eine Unterscheidung der Einflussgrößen in **exogene** (nicht kontrollierbare) und **endogene** (kontrollierbare) **Erfolgsfaktoren** (Pümpin, 1986, S. 31). Unter exogenen Erfolgsfaktoren versteht Pümpin dabei solche, die durch die Beteiligten nicht oder nur in sehr geringem Ausmaß beeinflusst werden können, sog. Rand- oder Rahmenbedingungen. Nach Patt (1990, S. 43) können diese nicht kontrollierbaren Faktoren noch einmal unterschieden werden. Solche Erfolgsgrößen, die auf feststehende Gegebenheiten einer Unternehmung zurückgehen und von den Verantwortlichen allenfalls langfristig zu beeinflussen sind, werden nach Patt als **interne exogene Einflussgrößen** bezeichnet. Beispielhaft wären hier die Größe einer Unternehmung oder die gewählte Betriebsform zu nennen. **Externe** nicht kontrollierbare Faktoren umfassen im Gegensatz dazu Einflussgrößen aus dem Umfeld der Unternehmung, die nicht steuerbar sind, gleichwohl aber einen Einfluss auf die endogenen Erfolgsfaktoren und die Erfolgsgrößen ausüben können, wie z.B. die Wettbewerbsintensität. Auf endogene Faktoren hingegen ist eine direkte Einflussnahme von Seiten der Akteure möglich (z.B. die Unternehmensstrategie, die Informationstechnologie oder das Marketing). Die gleiche Unterscheidung treffen im Übrigen auch Ulrich und Probst (1988), die allerdings von **Einfluss-** bzw. **Handlungsfaktoren** sprechen, während Müller (1999, S: 140) sie als **Situations-** bzw. **Managementvariablen** bezeichnet.

Aufgrund dieser Trennung ergibt sich als Konsequenz für die Erfolgsfaktorenforschung, dass der Schwerpunkt entsprechender Analysen im Allgemeinen auf den sog. endogenen Erfolgsfaktoren, d.h. auf den kontrollierbaren Einflussgrößen liegen sollte. Zwar sind auch exogene Größen veränderbar (zumindest langfristig bei entsprechender Positionierung des Unternehmens im Markt), spielen aber kurz- bis mittelfristig eine stark unter-

geordnete Rolle. Dennoch sollten auch sie berücksichtigt werden, um bei der Erstellung des Bezugsrahmens zur Klärung des (Unternehmens-)Erfolgs dem sog. kontingenztheoretisch orientierten, d.h. situativen Ansatz (Kast und Rosenzweig, 1973, S. IX) gerecht zu werden (Müller, 1999, S. 135). Gemäß dem Anliegen der situativen Ansätze analysiert der Bezugsrahmen neben der Ausgangssituation des Unternehmens als situative (exogene) Variable auch die kontrollierbaren (endogenen) Variablen, über die es dem Management möglich ist, auf die sog. **Ergebnisvariablen** wie z.B. den Gewinn oder den Return on Investment (ROI) Einfluss zu nehmen.

Werden zusätzlich noch sog. **Moderatorvariablen** berücksichtigt, die nach Steffenhagen (1998, S. 326) „ein Resultat des auf Erfolg ausgerichteten Handelns, [jedoch] keine Realisierung der betrachteten Erfolgsgröße(n) dar[stellen]“, so ergibt sich das grundlegende Modell des Zusammenhangs in der empirischen Erfolgsfaktorenforschung in Anlehnung an Hildebrandt und Trommsdorff (1989, S. 16) und Steffenhagen (1998, S. 327) gemäß Abbildung 3. Die Moderatorvariablen umfassen dabei sog. Zwischenziele des unternehmerischen Handelns, die zu den Erfolgsgrößen in einem Mittel-Zweck-Verhältnis stehen. Beispiele hierfür sind etwa ein hoher Marktanteil als Zwischenziel und Determinante des Return on Investment (ROI) als Erfolgsgröße.

Abbildung 3: Grundlegender Zusammenhang in der empirischen Erfolgsfaktorenforschung



Die abgebildete Wirkungsstruktur enthält sowohl direkte als auch indirekte Einflüsse der möglichen Erfolgsfaktoren auf den Erfolg respektive die Erfolgsgrößen. Die Handlungs- und Situationsvariablen können einen direkten Einfluss auf den Erfolg ausüben und/oder auf diesen indirekt über die Moderatorvariablen einwirken.

2. Erfolgsfaktorenforschung als Mittel wissenschaftlicher Theorienbildung

Ziel eines strategisch ausgerichteten Managements bzw. dessen strategischer Planung ist im Allgemeinen die Analyse der Erfolgsdeterminanten eines Unternehmens und die darauf aufbauende Entwicklung langfristig angelegter Konzepte, um die besten Voraussetzungen zur langfristigen Sicherung der Erfolgsmöglichkeiten zu schaffen und zu erhalten. Nur so ist auch langfristig die Überlebensfähigkeit eines Unternehmens zu sichern. „Die Identifizierung und Steuerung der Erfolgsfaktoren hat damit eine hohe Bedeutung für das Unternehmensmanagement“ (Müller, 1999, S. 58) und ist nach Rosenbauer (1994, S. 144) sogar die Voraussetzung für die Erstellung einer Unternehmensstrategie, die sich je nach Untersuchungsgebiet auf das Unternehmen als Ganzes oder auf Teilaspekte des Unternehmens, wie z.B. auf Strategische Geschäftseinheiten beziehen kann.

Ausgehend von der ersten Veröffentlichung zu diesem Thema (Daniel, 1961), in der Daniel die Existenz von Erfolgsfaktoren für verschiedene Branchen postulierte, folgten eine Vielzahl von Untersuchungen, die branchenübergreifend angelegt waren. Viele dieser Studien waren aber nicht wissenschaftlich orientiert und ernteten deshalb in der wissenschaftlichen Community berechnete Kritik (z.B. Frese, 1985, S. 604). Als Folge äußerten immer mehr Autoren die Notwendigkeit zur Überprüfung und weiteren Fundierung der Aussagen über Erfolgsfaktoren anhand **empirischer Erfolgsfaktorenforschung**, was vor allem seit Beginn der Neunziger Jahre zur starken Ausweitung der empirischen Erfolgsfaktorenforschung beigetragen hat (Küpper, 1994, S. 116). Erste Impulse erhielt diese Forschungsrichtung im Übrigen durch die *Profit Impact of Market Strategies* (kurz: PIMS) Studie (Buzzell und Gale, 1987) für vor allem amerikanische Firmen und die *Strategic Orientations of Small and Medium-sized Enterprises* (kurz: STRATOS) Studie (Bamberger, 1988) für kleine und mittlere Unternehmen aus Europa. Entscheidender Nachteil einer Vielzahl der in der Folge entstandenen Studien ist allerdings das eher journalistische Niveau, das die Arbeiten aufweisen (Aldrich, 1992). Als Folge konstatierte Fritz (1990, S. 91) zu Beginn der Neunziger Jahre, dass die Erfolgsfaktorenforschung „von gesicherten und umfassenden Resultaten noch weit entfernt“ war.

Versucht man nun, in Anlehnung an Müller (1999, S. 60) und Trommsdorff (1993, S. 142), Richtlinien bzgl. einer wünschenswerten Ausgestaltung der Forschungsmethodik der Erfolgsfaktorenforschung vorzuschlagen, so gelangt man zu Folgendem:

- Die Forschungsmethodik sollte nicht auf Lagentheorien sondern auf wissenschaftlichen Erfolgstheorien beruhen, d.h. deduktiv vorgehen und sich auf theoretisch fundierte Modelle von möglichst allgemeinem Charakter stützen, die sich im Anschluss daran auf empirischer Basis überprüfen lassen.
- Erfolgsfaktorenforschungen sollten hypothesenprüfend, d.h. konfirmatorisch und nicht explorativ erklärend sein. Die explorative Vorgehensweise birgt die Gefahr in sich, Scheinkorrelationen (fehl) zu interpretieren, während die konfirmatorische Vorgehensweise die fokussierte Überprüfung vorher theoretisch-deduktiv entwickelter Hypothesen ermöglicht. In Ermangelung einer fundierten Theorie oder eines geschlossenen Modells zur Klärung des (spezifischen) Erfolgs einer Unternehmung bzw. einer Geschäftseinheit sind jedoch die meisten Studien weder Theorien noch Hypothesen getrieben (Küpper, 1994, S. 116).
- Untersuchungen im Rahmen der Erfolgsfaktorenforschung sollten möglichst präzise, d.h. genau sein. Die Genauigkeit der Ergebnisse selbst hängt dabei von der gewählten Datenerhebungs- und Auswertungsmethode ab und weist bei qualitativen bzw. quantitativen Studien deutliche Unterschiede auf. Nach Kube (1991, S. 6) liefern qualitative, d.h. subjektiv analysierende Untersuchungen, die in der Regel Manager befragen, welche Faktoren diese subjektiv für wichtig erachten, sehr allgemeine Aussagen geringer Präzision, können aber im Rahmen explorativer Bemühungen zur Vorbereitung quantitativer und präziser Untersuchungen dienen. Erfolgt die Extraktion der Erfolgsfaktoren hingegen über eine (standardisierte) Erhebung von (Unternehmens-)Daten sowie eine statistisch/analytische Analyse, so ist im Allgemeinen von einer hohen Präzision der Studie auszugehen (Patt, 1990, S. 8).

3. Potentielle Probleme der Erfolgsfaktorenforschung

Werden die oben beschriebenen Empfehlungen bzgl. einer Ausgestaltung der Forschungsmethodik der Erfolgsfaktorenforschung beachtet, sind die meisten potentiellen Schwächen bereits behoben. Trotzdem bleiben Probleme, die im Folgenden kurz dargestellt werden sollen:

- Multidimensionalität der untersuchten Zusammenhänge: Die adäquate Herausarbeitung von Erfolgsfaktoren setzt die Analyse von Ursache-Wirkungs-Zusammenhängen zwischen mehreren erfolgsbestimmenden Größen und mehreren Erfolgsgrößen

ßen voraus. Aufgrund der Multidimensionalitätsproblematik kann nun jede Ursache sowohl Auswirkungen auf die Erfolgsgrößen als auch auf andere Erfolgsfaktoren besitzen (Interaktionsproblematik) und damit auch indirekt auf die Erfolgsfaktoren wirken. Dies gilt in den meisten Studien, da nicht davon ausgegangen werden kann, dass die Erfolgsfaktoren unabhängig voneinander sind. Diese Problematik lässt sich adäquat im Allgemeinen nur mit Hilfe statistisch komplexer Verfahren wie der Faktorenanalyse oder der Pfad- bzw. Kausalanalyse lösen, da diese Verfahren es ermöglichen, auch indirekte Einflüsse zu messen.

- Wertende Vorauswahl der Erfolgsfaktoren: Bedingt durch den Umstand, dass nur solche Faktoren, die empirisch in der Untersuchung erhoben werden, auch als Erfolgsfaktoren empirisch identifiziert werden können, sollte das Spektrum zu überprüfender Erfolgskorrelate möglichst umfassend sein. Dennoch wird der Forscher nicht dagegen ankommen, dass „eine wertende Vorauswahl im Entstehungszusammenhang wissenschaftlicher Arbeiten unvermeidlich ist“ (Schneider, 1991, S. 16).
- Bestimmung der richtigen Indikatoren: Jeder empirische Forschungsversuch kann immer nur das Abbild der Realität, oder mit anderen Worten den Schatten der Realität messen. Was gemessen werden soll, ist der Einfluss einer Erfolgsdeterminante auf den Erfolg; was jedoch gemessen wird, ist der Einfluss eines Indikators der Erfolgsdeterminante auf einen Indikator des Erfolgs. Je besser die jeweiligen Indikatoren definiert und gewählt sind, umso eher entsprechen die empirisch ermittelten Beziehungen der Wirklichkeit, oder vielleicht besser, dem unterstellten Erfolgsmodell. Zur Lösung dieses Problems bietet es sich an, bei der Bildung der Indikatoren besondere Aufmerksamkeit walten zu lassen. Zudem sollte vermieden werden, indirekte und zusammengesetzte Indikatoren zu verwenden.

Auf weitere, von Müller (1999, S. 64) beschriebene Probleme wie z.B. den *Time Lag zwischen Ursache und Wirkung*, die *Dynamik der Faktoren* oder *Probleme bei der Erhebung der Daten* soll nicht näher eingegangen werden.

Zusammenfassend lässt sich festhalten, dass es möglich ist, durch geeignete Auswahl der Forschungsmethodik und adäquate Behandlung zugrunde liegender Probleme die Aussagekraft einer Studie zum Unternehmenserfolg deutlich zu erhöhen. Trotzdem wird es nie möglich sein, alle potentiellen Risiken zu eliminieren. Aber selbst wenn es nicht möglich ist, über alle methodischen Zweifel erhaben die Faktoren zu identifizieren, die den Erfolg verursach(t)en, so kann man dennoch – bis auf statistische Zufälligkeiten –

die Faktoren herausarbeiten, die erfolgreiche von weniger erfolgreichen Unternehmen bzw. Geschäftseinheiten unterscheiden. Und allein diese Faktoren zu kennen, kann zur Ausgestaltung einer strategischer Planung wertvolle Hinweise liefern und dementsprechend normativen Charakter für das Unternehmensmanagement besitzen.

II. Kritische Erfolgsfaktoren von IT-Projekten

Vor allem im IT-Bereich ist die Suche nach kritischen Erfolgsfaktoren heutzutage von besonderer Bedeutung. Dies ist dadurch bedingt, dass die Informationstechnologie in modern ausgerichteten Unternehmen eine zentrale Funktion wahrnimmt und damit auf den Erfolg oder Misserfolg einer Unternehmung entscheidend Einfluss nehmen kann.

Analysiert man nun gleichzeitig eine Vielzahl eher **journalistisch geprägter, explorativer Studien** verschiedener Beratungsfirmen, so wird deutlich, wie schwierig sich die adäquate Implementierung einer IT-Landschaft in Unternehmen heute gestaltet. So berichtet z.B. die Gartner Group (11/2000) in einer Studie, dass etwa 40% aller IT-Projekte scheitern. Im Bereich Electronic Business ist die Erfolgsquote noch ernüchternder: „75% aller Projekte erreichen nicht das geplante Ziel“ (Mummert & Partner, 8/2000). Die Standish Group zeigte in einer Befragung von amerikanischen IT-Managern, dass nur 26% aller IT-Projekte erfolgreich waren, während 28% abgebrochen wurden und weitere 46% nicht die gesteckten Ziele erreichten. Als Hauptgründe für das Scheitern der Projekte ergaben sich dabei *mental-kulturelle Faktoren* wie mangelnde Einbeziehung der Anwender oder unrealistischen Erwartungen, aber auch Faktoren, die aus *Managementfehlern* resultier(t)en, wie z.B. die fehlende Top-Managementunterstützung oder eine mangelnde Planung der IT-Landschaft. Aber auch die *technologische Inkompetenz* sowie das *Fehlen entsprechender Ressourcen* wurden als Gründe für das Scheitern solcher Projekte genannt. Vorteilhaft auf den Erfolg von IT-Projekten wirkte sich vor allem die Tatsache aus, dass die Nutzer in den Prozess der Planung der Projekte einbezogen wurden, dass das Top-Management entsprechende Unterstützung signalisierte und dass kompetente Mitarbeiter eingesetzt wurden.

Neben diesen (journalistisch) explorativ, eher hinführenden Studien existiert aber auch eine Vielzahl von **wissenschaftlich-fundierten, konfirmatorischen Studien** empirischer Prägung, die Aufschluss über kritische Erfolgsfaktoren im IT-Bereich geben können. Diese Studien behandeln zum Teil sehr allgemeine Fragestellungen, die die Infor-

mationstechnologie oder das sog. Produktivitätsparadoxon der Informationstechnologie betreffen. So analysiert z.B. Schober (1996) die Zusammenhänge zwischen Unternehmensstrategie und Informations- bzw. Kommunikationsstrategie von international-tätigen Unternehmen, während Daniel (1996) die Studie von Schober spezifiziert und kritische Erfolgsfaktoren bei der Einführung von Informationstechnologien in internationalen Unternehmen in Indonesien diskutiert.

Im Gegensatz zu diesen Untersuchungen, die teilweise stark am situativen Kontext der Unternehmen orientiert sind, existiert eine Vielzahl von empirischen Studien, die sich ganz konkret mit dem Zusammenhang zwischen Unternehmenserfolg, IT und dem Einfluss verschiedener Unternehmensmerkmale auf diese Beziehung beschäftigen. So identifiziert z.B. Weill (1990, S. 11) die Faktoren *Benutzerzufriedenheit*, *Unternehmenskultur*, *Top Management Commitment* und *IT-Erfahrung*, die die wichtigsten unternehmerischen Fähigkeiten reflektieren und gleichzeitig eine erfolgreiche Integration von Informationstechnologie in ein Unternehmen garantieren. Des Weiteren kann Weill (1990, S. 9) die Hypothese stützen, dass die oben genannten Faktoren, die sog. *Conversion Effectiveness*, den Einfluss von IT-Investitionsvolumina auf den Unternehmenserfolg positiv verstärken, eine Tatsache, die vor allem vor dem Hintergrund des Produktivitätsparadoxon überraschend erscheint, aber durch die Komplexität der Kausalbeziehungen erklärbar ist. Einer ähnlichen Fragestellung widmet sich auch Weitzendorf (2000), der zeigt, dass Informationstechnologie erfolgreich sein kann, wenn sie in die *strategischen Überlegungen* des Unternehmens einbezogen und durch *ablauf- und aufbauorganisatorische Maßnahmen* begleitet wird. Des Weiteren sollten *Führungskräfte* und *Mitarbeiter Initiatoren* der Nutzung der Technologie sein und mögliche Barrieren erkennen und besprechen. Weitzendorf belegt schließlich seine Hypothesen anhand einer empirischen Studie bei deutschen und österreichischen Banken. Bemerkenswert ist allerdings, dass Weitzendorf (2000, S. 133) strategische Überlegungen, die sich z.B. aus dem Wettbewerbsumfeld des Unternehmens ergeben, nicht als erfolgsgestimmend identifizieren kann.

Zusammenfassend zeigt sich letztlich, dass sowohl in den explorativen als auch in den wissenschaftlich geleiteten, konfirmatorischen Studien die Unterstützung des Projektes durch das Top-Management, die (sinnvolle) Integration des Projektes in das Unternehmen und seinen Work-Flow, die Qualität der Informationstechnologie selbst sowie die Qualität der Mitarbeiter als kritische Erfolgsfaktoren herausgearbeitet werden können.

III. Kritische Erfolgsfaktoren von CRM-Projekten

Die jüngste CRM-Studie der Meta Group ergab, dass ein Viertel aller CRM-Projekte in den USA ihre Ziele nicht erreichen. 59 Prozent aller befragten Firmen gaben unternehmensinterne Faktoren als Hauptgrund für den Misserfolg an. Gleichzeitig war aber zu beobachten, dass CRM-Projekte sich erfolgreich verwirklichen lassen, „wenn Unternehmen die Implementierung zur Chefsache machen“ (Schmidt, 2002). Des Weiteren wird im Rahmen dieser und einer Vielzahl anderer journalistisch explorativer Beiträge zu diesem Thema auf die sog. drei P's – *People, Process and Politics* – als kritische Erfolgsfaktoren hingewiesen. So schreibt z.B. Schmidt (2002), dass die organisatorisch-strategische Einordnung des CRM-Projektes von entscheidender Bedeutung für den Erfolg des Projektes ist. CRM-Lösungen haben *integrativen Charakter* und sollen *abteilungsübergreifende Prozesse* realisieren. Sie lassen sich nur dann erfolgreich implementieren, wenn das Thema entsprechende Unterstützung aus Reihen des Top-Management erfährt. Übernimmt eine nach geordnete Abteilung die Initiative, dann leidet die Akzeptanz einer CRM-Lösung. Um CRM-Projekte erfolgreich zu implementieren, bedarf es darüber hinaus einer *engen Abstimmung* der beteiligten Geschäftsbereiche und einer klaren und frühzeitigen *internen Kommunikation*. Unterstützt werden diese Aussagen durch eine aktuelle CRM-Studie des Forschungsinstituts Forrester Research, die ergab, dass bisher nur wenige CRM-Projekte alle notwendigen Abteilungen wie IT, Vertrieb, Marketing und Service in die Implementierung mit einbeziehen.

Zu ähnlichen Aussagen gelangt Resch (2001), der als einen maßgeblichen Grund für das Scheitern von CRM-Projekten das Fehlen der *kulturellen und organisatorischen Reife* des Unternehmens sieht. „CRM muss in den Köpfen aller Beteiligten fest verankert sein“ Resch (2001). Mangelndes Interesse oder die ungenügende Einbindung der Unternehmensführung sind schlechte Voraussetzungen. Des Weiteren bedarf es neben der Verankerung der Kundensicht innerhalb der Organisation, also einer strategischen Neuausrichtung des Unternehmens, einer *intensiven Geschäftsprozessanalyse*, um optimierte Abläufe zu entwickeln. Auch müssen Datenquellen identifiziert und deren *Qualität maximiert* werden. Da sowohl die hohe Komplexität heutiger CRM-Systeme als auch die *notwendige Integration* von vor- und nachgelagerten operativen Prozessen im Allgemeinen dazu führt, dass die Implementierung eines CRM-Systems zur *technologischen Herausforderung* für das Unternehmen wird, sollte die Einführung eines CRM-Systems unbedingt in die Hände *qualifizierter Berater* gelegt werden (Resch, 2001).

Auch Holzer et al. (2000, S. 14), die in einer empirisch explorativen Studie bei deutschen Autobanken und Kfz-Leasinggesellschaften den Einsatzes von CRM-Systemen vergleichen, kommen zum Schluss, dass vor allem die Faktoren *Mensch* (mangelnde Anwenderbeteiligung, fehlendes Commitment, ungenügende Qualität), *Organisation* (fehlender Support, mangelnde Integration) und *Technik* (Datenqualität, fehlende Schnittstellen, zu hohe Komplexität) erfolgsbestimmend sind.

Frielitz et al. (2000, S. 102) weisen in ihrer Arbeit vor allem auf Probleme hin, die zu einer deutlichen Erschwernis bei der Einführung und erfolgreichen Umsetzung von CRM-Systemen führen. Allen voran nennen sie die auch aus anderen Studien bereits bekannten Gründe, wie z.B. *Widerstände in der Geschäftsleitung*, *Widerstände in Service, Vertrieb oder Marketing*, *ungenügende Integration in den Work-Flow* sowie das *Fehlen technischer Voraussetzungen*; Gründe, die wiederum unter den Begriffe *Commitment*, *Organisation* und *Technik* subsummiert werden können.

Einen zentralen Stellenwert bzgl. des Einflusses auf den Erfolg einer CRM-Lösung nimmt der Faktor *Organisation* auch bei Wilde (2001b) ein. Er fordert, dass die Implementierung einer CRM-Lösung von einem *Change-Management* begleitet werden muss, das die betroffenen Mitarbeiter für die veränderten Anforderungen qualifiziert und sie motiviert, die zugrunde liegende Kundenbindungsstrategie aktiv mit zu tragen. Gestützt werden seine Aussagen durch eine aktuelle Untersuchung des führenden amerikanischen CRM-Portals CrmIndustry.com, die zeigt, dass genau in diesem Bereich die Schwachstellen der CRM-Praxis liegen. So war bei etwa der Hälfte der untersuchten CRM-Prozesse keine explizite Kundenbindungsstrategie als Grundlage definiert. Auch war bei etwa jeweils der Hälfte der Unternehmen der CRM-Lösung keine Geschäftsprozessoptimierung vorangestellt, noch wurden aktive Maßnahmen zur Mitarbeiterqualifikation und -motivation angeboten. Damit ist es laut CRMIndustry nicht überraschend, dass auch in mehr als der Hälfte der Unternehmen für diese CRM-Prozesse keine finanzielle Rendite der getätigten Investitionen zu verzeichnen war. Andererseits zeigen empirische Untersuchungen aus den USA (Wilde, 2001b), dass Unternehmen mit besserer CRM-Kompetenz nachweislich deutlich bessere Umsatzrenditen und deutlich bessere Marktwerte erzielen. CRM-Investitionen versprechen demnach sehr wohl äußerst attraktive Renditen, aber nur unter einem kompetenten CRM-Prozessmanagement, das *Strategieentwicklung*, *Geschäftsprozessoptimierung*, *Change-Management* und *Informationstechnologie* sorgfältig aufeinander abstimmt.

Zusammenfassend zeigt sich, dass in den explorativen Studien die *kulturelle und organisatorische Reife* des Unternehmens – sich manifestierend in einer strategischen Neuausrichtung des Unternehmens, einer Unterstützung des Projektes durch das Top-Management, einer (sinnvollen) Integration des Projektes in das Unternehmen und seinen Work-Flow – und die *Qualität der Informationstechnologie* selbst als kritische Erfolgsfaktoren herausgearbeitet werden können. Im Gegensatz zur Erfolgsfaktorenforschung von IT-Systemen existieren aber noch keine wissenschaftlich geleiteten, konfirmatorischen Studien, die diese Faktoren empirisch bestätigen können.

IV. Kritische Erfolgsfaktoren von Data Warehouse Projekten

In nahezu jedem größeren Unternehmen sind in der Vergangenheit Projekte zur Gestaltung von Data Warehouse Lösungen veranlasst worden, auch wenn nicht alle initiierten Projekte zu den gewünschten Ergebnissen führ(t)en. Bzgl. der Anzahl der gescheiterten Projekte selbst herrscht allerdings Unklarheit. Spies (1998, S. 38) behauptet, dass 70% der Data Warehouse Projekte scheitern, nach einer Diebold-Schätzung (Stephan, 1998, S. 23) befinden sich zumindest die Hälfte der Projekte in einer Krise, und nach einer Studie der Meta Group können in etwa 50% der Fälle die Erwartungen nicht erfüllt werden (Hörmann, 1998, S. 3). In Anbetracht dieser Zahlen wird deutlich, wie wichtig Untersuchungen zur Erfolgsfaktorenforschung im Bereich des Data Warehousing sind; umso überraschend aber die Tatsache, dass vergleichsweise wenige Studien bislang dazu veröffentlicht wurden.

Eine dieser Studien geht auf Adelman und Moss (2000) bzw. Adelman (2001) zurück. Beide Studien sind journalistisch qualitativer Natur und basieren auf dem Erfahrungs- und logisch deduktiven Wissen der Autoren. Als besonders erfolgskritisch sehen die Autoren dabei die *interne Kommunikation*, die vor allem die Erwartungen von und an die Benutzer vermitteln muss, die *Einbeziehung der Nutzer* in den Prozess der Implementierung des Systems, das *Commitment* aus den Reihen des *Top-Managements* und das *Vorhandensein adäquater Soft- und Hardware* sowie *geeignet geschulter Mitarbeiter*. Darüber hinaus weisen Adelman und Moss auch noch auf die Tatsache hin, wie wichtig es ist, eine hohe Datenqualität vorzufinden. Des Weiteren empfehlen sie, bei einer Projektpatenschaft einen leitenden Mitarbeiter außerhalb der Linie einzusetzen, der bevorzugt nicht aus dem IT-Bereich sondern aus dem „business“ Bereich stammt. Auch

sollten die gesteckten Ziele, sowohl bzgl. der Ergebnisse als auch bzgl. der zeitlichen Restriktionen, nicht zu hoch sein. Demotivierte Mitarbeiter sind signifikant erfolgsmindernd.

Wübker und Buckler (2002), die das Thema Data Warehouse im Rahmen der Studien zu CRM-Systemen betrachten, führen als erfolgskritische Faktoren hier vor allem die (sinnvolle) *Integration in die bestehende IT-Landschaft*, die *Qualität von Hard- und Software* sowie die *Qualität der Daten* auf. Aber auch die *Integration* der Ergebnisse in den *Work-Flow Prozess* (Organisation), hier insbesondere die Umsetzung im kommunikativen CRM, sowie der Bereich *Personal* (Commitment, Schulungen und externe Berater) werden als problematisch gesehen.

Letztlich bleibt noch die Arbeit von Dittmar (1999) zu erwähnen, der eine explorativ quantitative Studie zu Erfolgsfaktoren im Data Warehouse Bereich durchgeführt hat, sich aber auf die Auswertung von 16 Interviews repräsentativ ausgewählter Unternehmen sowie von drei veröffentlichten Anwenderberichten beschränkt. Die Aussagekraft dieser Studie ist somit vor dem Hintergrund der geringen Stichprobengröße zu bewerten, kann aber ähnlich wie die oben genannten journalistisch qualitativen Studien als Grundlage zur Erarbeitung quantitativer Untersuchungen nützliche Dienste leisten. Interessant ist nun bei der Analyse dieser Studie die Tatsache, dass Dittmar (1999, S. 104) die identischen kritischen Erfolgsfaktoren identifizieren kann, wie dies bereits in den oben genannten Studien der Fall war. So kommt auch er zum Schluss, dass das Vorhandensein eines geeignet ausgestalteten Projektmanagements zur besseren *Integration* der Ergebnisse *in den Work-Flow*, die *Integration der Endanwender* selbst, die personell adäquate *Besetzung der Mitarbeiterstellen* sowie die Existenz einer *Patenschaft aus dem Top-Management* wichtige Faktoren für die Ausnutzung der Erfolgspotentiale von Data Warehouse Lösungen sind. Des Weiteren betont auch Dittmar die Wichtigkeit eines internen *Commitment der Mitarbeiter* gegenüber dem Data Warehouse sowie die Wichtigkeit einer *geeigneten Soft- und Hardwarelandschaft*. Auch die *Qualität externer Berater* beurteilt Dittmar (1999, S. 104) kritisch für den Erfolg solcher Projekte.

Zusammenfassend zeigt sich, dass sowohl in der empirischen als auch in den eher journalistischen Studien die *Unterstützung* des Projektes durch das *Top-Management*, die Reorganisation des Unternehmens zur besseren *Integration* des Projektes in den *Work-Flow*, die *Qualität von Daten, Soft- und Hardware* selbst sowie die *Qualität von Mitarbeitern* und *externen Beratern* als kritische Erfolgsfaktoren identifiziert werden können.

V. Kritische Erfolgsfaktoren von Data Mining Projekten

„Je spezieller bzw. jünger eine Fragestellung, umso weniger Arbeiten zur Thematik liegen vor.“ Diese Erkenntnis trifft auch auf die Erfolgsfaktorenforschung im Bereich des Data Mining zu. Neben einer Vielzahl von Empfehlungen, die sich unmittelbar aus dem Konzept des Data Mining selbst ableiten lassen, wie z.B. das Vorliegen einer guten Soft- und Hardware, die Mitarbeit von gutem Personal, die Sicherung einer hohen Datenqualität etc., existieren kaum Arbeiten, die sich mit diesem Thema vor dem Hintergrund der Erfolgsfaktorenforschung und ihren Zielen beschäftigen. Existieren z.B. Determinanten, bei deren Fehlen Data Mining Projekte scheitern? Oder, welche Faktoren sind kritischer als andere? Ist die Qualität der Mitarbeiter wirklich so wichtig? Fragen, die durch explorative Studien nur teilweise, mit Hilfe konfirmatorischer Studien aber adäquat gelöst werden können.

Allenfalls Hermiz (1999) versucht über die bereits bekannten „Erfolgsfaktoren“ (oder besser: notwendigen Voraussetzungen) hinaus einige Empfehlungen bzgl. wünschenswerter betriebswirtschaftlicher und organisatorischer Abläufe zu geben, die subjektiv qualitativer Natur sind und empirisch quantitativ nicht evaluiert wurden. So fordert er z.B., dass eine *klare Definition der zu meisternden Probleme* existieren muss, um eine adäquate Lösung erreichen zu können. Des Weiteren weist er auf die Notwendigkeit hin, sich im Vorfeld der Data Mining Anwendung der *Datenproblematik* bewusst zu sein, d.h. zu wissen, welche Daten in welchem Umfang in welcher Qualität auf welchem Datenniveau zur Lösung der „business mission“ benötigt werden. Auch die im Allgemeinen *zu hohen Erwartungen* von Seiten der Business-User sind nach Hermiz maßgeblich für das Scheitern vieler Data Mining Projekte verantwortlich. Aufgrund der enormen Komplexität der Projekte ist eine *entsprechende Projektplanung* unabdingbar, eine Projektplanung, die unter anderem dafür sorgt, dass der Data Mining Prozess als Ganzes in überschaubare und damit auch planbare Teilschritte zerlegt wird. Als letzten wichtigen Erfolgsfaktor nennt Hermiz schließlich Folgendes: „Plan to learn from the data mining process regardless of the outcome“ (Hermiz, 1999). Data Mining Projekte scheitern seiner Meinung nach häufig daran, dass *überzogene Erwartungen*, eben auch an die Ergebnisse, von Seiten des Management existieren. Das Ausbleiben solcher spektakulärer Resultate („Data mining is not magic and cannot produce magical results“, Hermiz, 1999) hat dann in der Regel eine *mangelnde Akzeptanz* der Lösungen und letztlich die Einstellung der Projekte zur Folge.

VI. Synopsis

Basierend auf den aus der Literatur bekannten und oben dargestellten Ergebnissen der Erfolgsfaktorenforschung in den Bereichen **IT**, **CRM**, **Data Warehouse** und **Data Mining** sollen im Folgenden erste Ansätze zur Identifikation erfolgskritischer Faktoren im Data Mining aufgezeigt werden. Dabei soll noch einmal darauf hingewiesen werden, dass die in den Arbeiten gewonnenen Erkenntnisse zumeist auf Erfahrungswissen aus der Durchführung bzw. Begleitung entsprechender Projekte und aus Literaturrecherchen basieren. Nur wenige der Arbeiten sind explorativer, empirisch quantitativer Natur, konfirmatorische Studien sind sogar nur im Bereich der Studien zur Informationstechnologie zu finden.

Eine Zusammenstellung der in den unterschiedlichen Arbeiten herausgestellten Erfolgsfaktoren zeigt deutlich, dass sich die Ergebnisse weitgehend überschneiden. Dennoch werden mitunter stark unterschiedliche, wenig präzise und von subjektivem Begriffsverständnis geprägte Formulierung gewählt, die eine Systematisierung der bislang identifizierten Erfolgsfaktoren erschweren. Im Folgenden sollen dennoch die genannten Erfolgsfaktoren nach inhaltlichen Gesichtspunkten zusammengefasst und konkretisiert werden, wobei nur solche Erfolgsfaktoren Eingang finden, die zumindest von zwei Autoren genannt und auf den Bereich des Data Mining direkt übertragbar sind.

Mental-kulturelle Faktoren (Mensch)

- Eine Vielzahl von Autoren weist auf die Wichtigkeit mentaler Faktoren zur erfolgreichen Implementierung von IT-Projekten hin. So zeigt z.B. Weitzendorf (2000, S. 133), dass die Informationstechnologie in die strategischen Überlegungen einer Unternehmung einbezogen werden sollte, um erfolgreich zu sein, Weill (1990) weist sogar auf die Wichtigkeit der Unternehmenskultur als Ganzes hin. Generell geht es wie in vielen anderen Studien („CRM beginnt im Kopf“, Brendel, 2002, S. 33) um die grundsätzliche Denkhaltung des Unternehmens, um die gelebte **Unternehmenskultur** im Umgang mit Neuem; eine Unternehmenskultur, die sich z.B. dadurch konstatiert, ob ein Unternehmen eher konservativ oder eher innovativ ist, ob die Entscheidungsträger und Mitarbeiter einem Wandel gegenüber aufgeschlossen sind und Neues akzeptieren, wie gut die interne Kommunikation im Unternehmen ist, oder ob retrograde bzw. progressive Organisationsstrukturen vorzufinden sind.

- Darüber hinaus erachten die meisten der Autoren das **Commitment**, das wichtigen Projekten einerseits sowie der Informationstechnologie, den CRM-Systemen, dem Data Warehouse oder eben dem Data Mining andererseits entgegen gebracht wird, als erfolgskritisch. Ist die Einführung neuer Technologien Chefsache (Schmidt, 2002), so wird im Unternehmen die entsprechende Wichtigkeit der Projekte dadurch zum Ausdruck gebracht. Das Engagement, die Aufmerksamkeit und die Sensibilität der Mitarbeiter sind erhöht, die Aussichten auf ein erfolgreiches Abschneiden des Projektes steigen.

Organisatorische Faktoren (Organisation)

- Neben den *menschlichen, eher weichen* Faktoren nennen fast alle der beschriebenen Studien die organisatorischen Voraussetzungen als Determinante einer erfolgreichen Implementierung der betrachteten Systeme. Wilde (2001b) spricht z.B. von der Notwendigkeit einer Geschäftsprozessoptimierung, d.h. der Anpassung des Work-Flow an die neuen Begebenheiten, bzw. von der Notwendigkeit eines existierenden **Change-Managements**. Nur wenn die organisatorischen Rahmenbedingungen an die neue Situation angepasst werden und Data Mining als Prozess voll in den Work-Flow integriert wird, kann Data Mining auch erfolgreich sein. Dazu ist es aber ebenso wichtig, dass der Endbenutzer, d.h. der Anwender, in den Prozess des Data Mining einbezogen wird, um gerade das zu lösen, was das Unternehmen benötigt („Have a clearly articulated business problem that needs to be solved and for which data mining is the proper solution technology“, Hermiz, 1999).
- Die organisatorischen Rahmenbedingungen zur Integration von Data Mining Projekten in den Work-Flow zu schaffen, sichert nicht unmittelbar auch die adäquate **Integration der Ergebnisse** selbst. Deshalb erscheint es wichtig zu sein, über aufgeschlossene Fachabteilungen und gut geschultes Personal, das um die Vorzüge der Data Mining Ergebnisse weiß, eine Umsetzung der Ergebnisse und damit auch eine inhaltliche Integration in den Fachabteilungen zu erreichen. Zu beachten ist dabei, dass diese Integration umso besser verläuft, je besser die organisatorischen Rahmenbedingungen sind und je größer das Commitment für Data Mining aus den Reihen des Top-Management ist.
- Schließlich werden nach Meinung diverser Studien die Erfolge von IT-Projekten, und damit auch von Data Mining Projekten, durch ihre **organisatorische Absiche-**

rung, d.h. durch ihre mittel- bis langfristige Plan- und Überprüfbarkeit, determiniert. Existieren z.B. feste Budgets, mit denen die Projektmanager planen können und sind eindeutige Kennzahlensysteme vorhanden, die den Erfolg der Projekte kontrollieren, so kann davon ausgegangen werden, dass die Einbindung des Data Mining im Unternehmen eher langfristiger Natur ist; unrealistische Erwartungen, innerhalb kürzester Zeit „magic results“ (Hermiz, 1999) hervor zu bringen, sind im Allgemeinen erfolgsmindernd und deshalb zu vermeiden („The most common cause of failure is an unrealistic schedule“, Adelman, 2001). Inwieweit die organisatorische Verankerung in einer Stabsstelle oder einer Fachabteilung, z.B. dem Marketing oder der Marktforschung, entscheidend für den Erfolg der Data Mining Projekte ist, wird kontrovers diskutiert und soll entsprechend durch die Studie überprüft werden.

Informationstechnische Faktoren (Informationstechnologie)

- Analysiert man die betrachteten Studien, so erkennt man, dass in keiner (implizit oder explizit) auf den Faktor Technik als Erfolgsdeterminante verzichtet wird, wobei damit sowohl die Hardware, die Software als auch das dazu benötigte Personal gemeint ist. Dementsprechend wäre auch hier – ähnlich wie in den Bereichen *Mensch* und *Organisation* – eine Aufteilung in die entsprechenden Themengebiete denkbar. Da aber andererseits dieser Faktor **Informationstechnologie** im Vergleich zu anderen Erfolgsdeterminanten als relativ unwichtig bewertet wird und eine adäquate Berücksichtigung sehr viele, z.T. zu spezifische Facetten berücksichtigen müsste, erscheint eine Unterteilung dieses Faktors nicht sinnvoll. Aspekte, die die Qualität der IT-Landschaft und die Integration des Data Mining Prozesses in die IT-Landschaft (je besser die IT, umso besser kann die Integration von Data Mining gelingen), die Qualität der zur Verfügung stehenden Daten, die gleichzeitige Verwendung alternativer Techniken wie OLAP, das Vorhandensein eines Data Warehouse bzw. eigener Data Mining Server oder die Neueinstellung geeigneter Mitarbeiter beschreiben, könnten diesen Faktor widerspiegeln.

Externe Ressourcen

- Vor allem die Studien zur Erfolgsfaktorenforschung von Data Warehouse Projekten haben gezeigt, dass der Erfolg entsprechender Projekte entscheidend von der Verwendung **externer Ressourcen** wie Beratern oder dem Zukauf von Daten abhängt (Dittmar, 1999, S. 104). Dementsprechend kann vermutet werden, dass diese Res-

sourcen auch für Data Mining Projekte, die im Allgemeinen auf Data Warehouses zurückgreifen, erfolgskritisch sein sollten. Allerdings ist die Richtung der Wirkung nicht eindeutig formulierbar. So könnte die Notwendigkeit einer Beratung bzw. des Zukaufs von Daten auf Schwächen im Unternehmen hinweisen. Andererseits beeinflusst der Umstand, dass Berater im Unternehmen eingreifen bzw. dass Daten zugekauft werden, die Qualität der Ergebnisse im Allgemeinen positiv.

Zusammenfassend ergeben sich damit die folgenden Faktoren, die auf Basis der zitierten Literatur und deduktiver Überlegungen im Rahmen von Data Mining Projekten als erfolgskritisch postuliert werden können: *Unternehmenskultur, Commitment, Change-Management, Integration der Ergebnisse, Organisatorische Absicherung, Technik, Externe Ressourcen*. Zusätzlich zu diesen sieben Faktoren, die den Erfolg eines Data Mining Projektes terminieren (können), soll in Anlehnung an Grabner-Kräuter (1993, S. 290) auch der Markt und das Umfeld eines Unternehmens im Sinne von Porter zur Erklärung der Erfolgspotentiale solcher Projekte herangezogen werden. Helm (1997, S. 88) schlägt dazu vor, die **Markt- und Konkurrenzsituation** eines Unternehmens abzubilden, da sie letztendlich als kausale Basis eines erfolgreichen Wirtschaftens einer Unternehmung angesehen werden kann. So erlauben beispielsweise attraktive Märkte, d.h. z.B. Märkte mit einer geringen Wettbewerbsintensität, tendenziell höhere Renditen, d.h. Erfolge, die sich letztendlich auch im Bereich des Data Mining niederschlagen sollten. Ebenso verhält es sich nach Helm (1997, S. 90) auch mit weiteren, aus dem Bereich der Portfolio-Methodik bekannten Kennzahlen zur Markt- und Branchenattraktivität, wie z.B. dem Marktwachstum oder der Marktgröße.

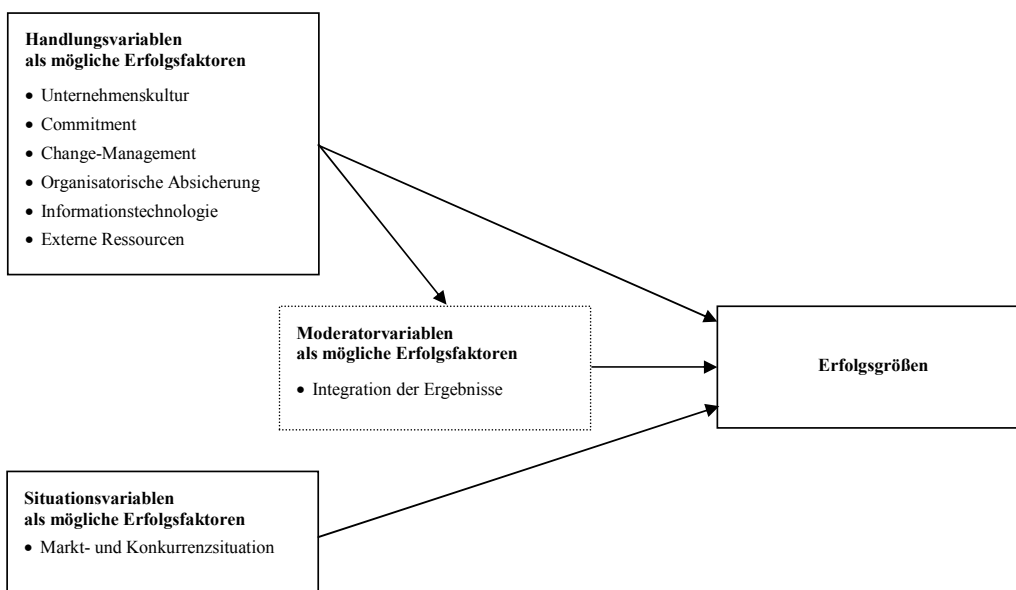
Anzumerken bleibt, dass bei den aus der Markt- und Konkurrenzsituation abgeleiteten Zusammenhängen die Richtung der Wirkung a-priori nicht eindeutig formulierbar ist. So wirkt sich z.B. die hohe Attraktivität eines Marktes eher hemmend auf den Einsatz von Data Mining Techniken aus, da für das Unternehmen keinerlei Notwendigkeit besteht, hier zu handeln. Werden dennoch entsprechende Techniken eingesetzt, sind die Erwartungen im Allgemeinen zu hoch, der (objektiv teils vorhandene) Erfolg für das Unternehmen wird subjektiv nicht empfunden. Ebenso verhält es sich aber auch bei Unternehmen, die in Märkten geringer Attraktivität agieren. Hier werden Data Mining Techniken mit hohen Erwartungen eingesetzt, die aber aufgrund der schwierigen Märkte im Allgemeinen nicht erfüllt werden können („Übertriebene Anforderungen sollten bereits im Vorfeld auf das Machbare reduziert werden“, Dittmar, 1999, S. 102).

D. Ableitung eines konzeptionellen Rahmens zur Erfolgsfaktorenforschung im Data Mining

I. Bezugsrahmen zur Erfolgsfaktorenforschung im Data Mining

Ausgehend von dem in Abbildung 3 dargestellten grundsätzlichen Zusammenhang in der Erfolgsfaktorenforschung, den Überlegungen aus den bisherigen Studien zur Erfolgsfaktorenforschung von Projekten aus den Bereichen Informationstechnologie, CRM-Systemen, Data Warehouse und Data Mining, den oben skizzierten zusammengefassten Ergebnissen und den typischen Elementen von Data Mining Projekten selbst lässt sich der in Abbildung 4 vorgestellte Bezugsrahmen für die empirische Untersuchung begründen.

Abbildung 4: Grundlegender Bezugsrahmen zur Systematisierung von Erfolgsfaktoren in Data Mining Projekten



Im Gegensatz zum Grundmodell (vgl. Abbildung 3) erscheint es nach Sichtung der Literatur nicht sinnvoll, interne Situationsvariablen in das Modell zu integrieren. Dies lässt sich damit erklären, dass interne Situationsvariablen, wie z.B. die Unternehmensgröße, die Branche oder die Rechtsform des Unternehmens, keinen *direkten* Einfluss auf die Erfolgsgrößen ausüben. Allenfalls indirekte Einflüsse dieser Faktoren über Handlungsvariablen, wie z.B. der Einfluss der Rechtsform auf die Unternehmenskultur oder der Einfluss der Unternehmensgröße auf die Ausstattung der Informationstechnologie, sind

denkbar, sollen aber zur Vermeidung eines zu komplexen und damit schwierig zu interpretierenden Modells vernachlässigt werden. Zur Rechtfertigung dieser Vorgehensweise sei auf Bornemeyer (2002, S. 107) verwiesen, die ausführt, dass „es nicht Aufgabe der Erfolgsfaktorenforschung [sein kann], ein Totalmodell sämtlicher Einflussgrößen“ zu generieren, sondern vielmehr sich auf wesentliche Erfolgsfaktoren zu konzentrieren. Die verbleibenden, externen Situationsvariablen ihrerseits sollen im Rahmen des hier betrachteten Bezugsrahmens nur direkt auf den Erfolg der Projekte einwirken. Indirekte Einflüsse über Moderatorvariablen, die sog. Zwischenziele darstellen, sind bei gesamtheitlich analysierenden Erfolgsfaktorenuntersuchungen (Müller, 1999, S. 61) möglich, erscheinen aber in diesem fokussierten Zusammenhang nicht gerechtfertigt.

II. Hypothesen

Im Folgenden werden auf Basis oben genannter theoretischer Überlegungen unter Berücksichtigung des in Abbildung 4 dargestellten Bezugsrahmens Forschungshypothesen zur Wirkung verschiedener Determinanten der Unternehmen auf den Erfolg oder Misserfolg bzgl. des Einsatzes von Data Mining Technologien formuliert, die im Rahmen einer empirischen Studie überprüft werden sollen.

Die ersten Hypothesen bezieht sich auf den Bereich der mental-kulturellen Faktoren (**Mensch**). Generell kann hier erwartet werden, dass die Innovationsfreudigkeit und Offenheit der Entscheidungsträger Neuem gegenüber positiven Einfluss auf den Erfolg neuer Technologien ausübt. Diese positive **Unternehmenskultur** begünstigt somit auch die neue Technologie Data Mining, verhindert den Aufbau von Barrieren und wirkt sich somit positiv auf den Erfolg von Data Mining Projekten aus. Konkret lautet die Hypothese:

- H₁: Die Innovationsfreudigkeit eines Unternehmens sowie die Aufgeschlossenheit der Unternehmensleitung gegenüber einem Wandel wirken sich positiv auf den Erfolg der Data Mining Projekte aus, wobei eine gute interne Kommunikation im Unternehmen den Aufbau von Barrieren verhindert und somit den Erfolg neuer Technologien, d.h. auch den Erfolg von Data Mining Projekten begünstigt.

Empirische Studien unterstützen die Hypothese, dass der Rang des MIS Verantwortlichen und damit das **Top-Management Commitment** eng mit dem Erfolg eines MIS-Systems verbunden sind (Weitzendorf, 2000, S. 114). Die entsprechende Hypothese lautet demnach:

- H₂: Das Top Management Commitment wirkt sich über ein erhöhtes Engagement und eine erhöhte Sensibilität der Mitarbeiter bzgl. der Wichtigkeit des Projektes sowie über die dadurch bedingte Freisetzung von Ressourcen positiv auf die Umsetzung und Integration und damit auch auf den Erfolg von Data Mining Projekten aus.

Einen zentralen Stellenwert bzgl. des Einflusses auf den Erfolg von Data Mining Lösung nehmen die organisatorischen Faktoren (**Organisation**) ein. Hier stützen empirische Studien (Wilde, 2001b) die These, dass ein von einem **Change-Management** begleitetes Unternehmen, das die betroffenen Mitarbeiter für die veränderten Anforderungen qualifiziert sowie motiviert und das eine Anpassung der Geschäftsprozesse (Work-Flow) initiiert, erfolgreich bei der Einführung neuer Technologien sein kann, da eine Integration des Erreichten von Seiten der Mitarbeiter akzeptiert wird. Als Konsequenz ergibt sich für das Data Mining Folgendes:

- H₃: Das Vorhandensein eines Change-Management im Unternehmen zur Integration von Data Mining Lösungen in den Work-Flow wirkt sich positiv auf die Umsetzung und Integration der Ergebnisse von Data Mining Projekten und damit auch auf deren Erfolg aus.

Des Weiteren wird dem Data Mining Projekt intern eine umso höhere Wichtigkeit beigemessen, je besser die **organisatorische Absicherung** des Projektes ist. Projekte in Fachabteilungen unterliegen der Gefahr, der Unternehmensleitung und damit der Unternehmensstrategie entzogen werden zu können, Projekte ohne feste Budgets sind stets davon bedroht, eingestellt zu werden und Projekte schließlich, die nicht kontrollt werden, können schwerlich ihren Erfolg auch betriebswirtschaftlich belegen. Dementsprechend lautet die Hypothese:

- H₄: Umso besser die organisatorische Absicherung eines Data Mining Projektes ist, desto erfolgreicher wird das Data Mining Projekt sein.

Die letzte Hypothese aus dem Bereich Organisation bezieht sich auf die **Integration und Umsetzung der Ergebnisse** des Data Mining und kann als Hypothese bzgl. eines Intermediärs (Moderatorvariablen) betrachtet werden. Sie lautet:

- H₅: Umso aufgeschlossener die Fachabteilungen den Ergebnissen des Data Mining gegenüber sind und je häufiger diese Ergebnisse auch betriebswirtschaftlich umgesetzt werden, desto erfolgreicher wird das Data Mining Projekt sein.

Das Vorhandensein einer vernünftigen informationstechnologischen Basis kann als Grundvoraussetzung für den Erfolg von Data Mining Projekten angesehen werden. Da jedoch davon auszugehen ist, dass diese Voraussetzung generell erfüllt wird, soll im Rahmen der zu formulierenden Hypothese aus dem Bereich **Informationstechnik** die Wichtigkeit des Zusammenspiels der einzelnen Komponenten einer IT-Landschaft hervorgehoben werden. Sie lautet:

- H₆: Eine gutes Zusammenspiel der im Umfeld von Data Mining Projekten vorzufindenden Hard- und Software sowie eine hohe Qualität der zur Verfügung stehenden Daten beeinflusst den Erfolg von Data Mining Projekten positiv.

Letztlich bleibt aus dem Bereich der Handlungsvariablen, d.h. der vom Unternehmen kontrollierbaren Einflussgrößen noch das Themengebiet **Externe Ressourcen**. In Anbetracht der oben skizzierten Problematik soll hier die Hypothese wie folgt formuliert werden:

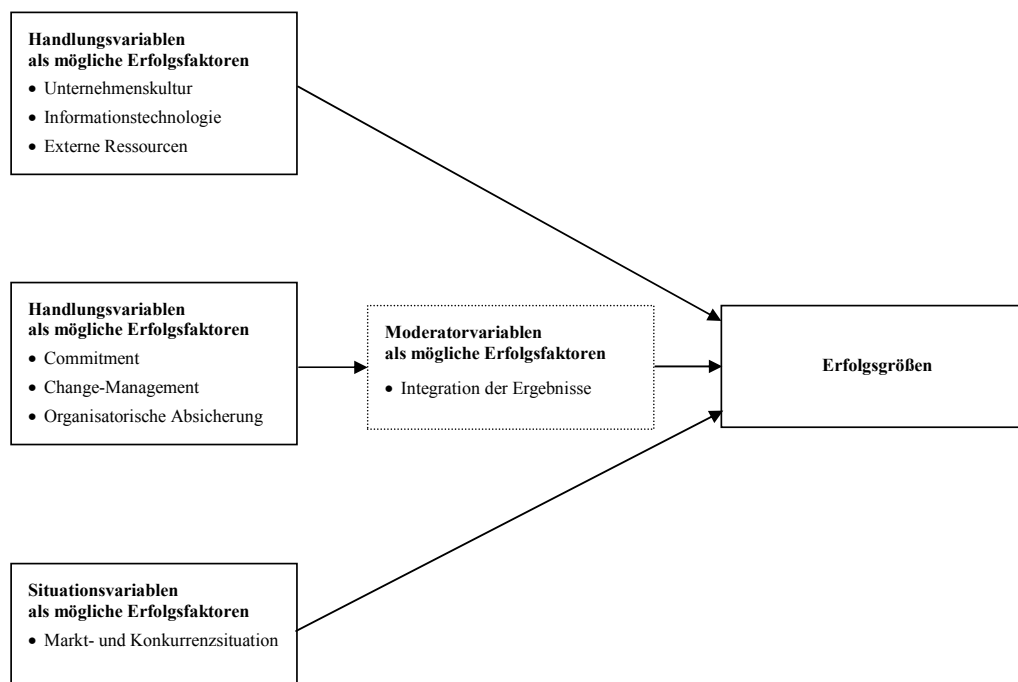
- H₇: Die Verwendung externer Ressourcen wie Berater oder externe Daten hat keinen Einfluss auf den Erfolg von Data Mining Projekten.²

Neben den Hypothesen bzgl. der potentiellen Erfolgsfaktoren auf Seiten der Handlungsvariablen soll schließlich auch noch eine Hypothese bzgl. der Wirkung einer Situationsvariablen auf den Erfolg formuliert werden. Diese bezieht sich auf die nicht kontrollierbare externe Einflussgröße der **Markt- und Wettbewerbssituation** eines Unternehmens und postuliert aufgrund der oben beschriebenen Problematik bei gleichzeitiger Vernachlässigung exogen interner Erfolgsfaktoren eine Unabhängigkeit:

- H₈: Die **Markt- und Wettbewerbssituation** übt keinen Einfluss auf den Erfolg von Data Mining Projekten aus.³

Werden die vorgestellten Hypothesen und ihre Abhängigkeiten untereinander schließlich in den in Abbildung 4 dargestellten Bezugsrahmen integriert, so ergibt sich das in Abbildung 5 konkretisierte Modell der Erfolgsfaktorenforschung von Data Mining Projekten. Dabei ist zu erkennen, dass einerseits Handlungsvariablen wie das *Commitment* des Top-Management, das *Change-Management* und die *Organisatorische Absicherung* existieren, die indirekt über die Moderatorvariable *Integration der Ergebnisse* auf den Erfolg der Projekte wirken. Andererseits üben die kontrollierbaren potentiellen Erfolgsfaktoren *Unternehmenskultur*, *Informationstechnologie* und *Externe Ressourcen* sowie die Situationsvariable *Markt- und Konkurrenzsituation* direkt Einfluss auf den Erfolg der betrachteten Projekte. Damit versucht das Modell die wichtigsten Einflussfaktoren zu identifizieren, ohne jedoch Anspruch auf Vollständigkeit oder ein Totalmodell erheben zu wollen.

Abbildung 5: Integration der potentiellen Erfolgsfaktoren in den Bezugsrahmen



Anzumerken bleibt schließlich, dass dieses hier entwickelte Modell in seiner Grobstruktur mit anderen im Bereich der Erfolgsfaktorenforschung von IT-Anwendungen entwickelten Modellen durchaus vergleichbar ist (z.B. Müller, 1999, S. 140, Daniel, 1996, S. 5 oder Weitzendorf, 2000, S. 112), auch wenn durch die hier vorliegende, sehr fokussierte Sichtweise auf einen Teilbereich der Informationstechnologie im Detail deutliche Unterschiede existieren.

E. Empirische Studie

I. Zielsetzung der Untersuchung

Die Zielsetzung der empirischen Studie folgt der Tradition der Erfolgsfaktorenforschung und soll zur Identifikation von Erfolgsfaktoren für Data Mining Projekte beitragen. Darüber hinaus wird die Ableitung eines auf den Resultaten der empirischen Erhebung basierenden Kontrollinstruments angestrebt.

Zur Erreichung dieser Ziele ist es zunächst erforderlich, die bislang abgeleiteten Erfolgsfaktoren, die als latente, d.h. nicht direkt beobachtbare Konstrukte zu verstehen sind, zu operationalisieren (Homburg und Giering, 1996, S. 6). Dieser Schritt dient einzig der Messbarkeit der Konstrukte und wird durch Aufstellung eines adäquaten Indikatorenkatalogs für jedes Konstrukt gelöst. Die Indikatoren selbst sind Merkmale bzw. Variablen von Personen, Produkten oder Unternehmen, die direkt messbar sind und in unmittelbarem Zusammenhang zu dem Konstrukt stehen, dem sie als Indikator dienen. Um inhaltliche und messtheoretische Fehler zu vermeiden, sollten bei der Auswahl Aspekte wie Objektivität, Reliabilität (Peter und Churchill, 1986, S. 4) und Validität (Churchill, 1979, S. 65) berücksichtigt werden. Des Weiteren ist neben der Behandlung der Erfolgsfaktoren auch die entsprechende Operationalisierung des Konstruktes Erfolg notwendig.

Nach diesem vorbereitenden Schritt soll eine Erhebung die ausgewählten Indikatoren auf einer umfassenden empirischen Basis erfassen. Erste deskriptive Auswertungen sollen dann die Erfahrungen der Unternehmen im Rahmen von Data Mining Projekten charakterisieren. Neben der Zusammenstellung dieser Erkenntnisse können so erste Hinweise auf Einflussgrößen des Data Mining Erfolgs gewonnen werden.

In einem zweiten Schritt wird die Erfolgswirksamkeit der postulierten Erfolgsfaktoren überprüft. Dazu wird das oben hergeleitete Erfolgsfaktorensystem des Data Mining einer kausalanalytischen Prüfung unterzogen.

II. Operationalisierung der Konstrukte

Um den Einfluss der oben erörterten Unternehmensaspekte und Zielmarktvariablen auf den Erfolg des Einsatzes von Data Mining Technologien überprüfen zu können, müssen die involvierten Konstrukte und Faktoren operationalisiert, d.h. mittels Indikatoren erfasst werden. Hierbei wird – soweit möglich – auf in der einschlägigen Literatur bereits entwickelte Vorschläge zurückgegriffen. Als Skala dient in den meisten Fällen eine fünfstufige bipolare Ratingskala, deren Endpunkte derart umschrieben werden können, dass die verwendeten Bezeichnungen eine extreme Antwortmöglichkeit auf die jeweilige Frage darstellen. Einige Indikatoren werden des Weiteren auf einer nominal-binären Skala (ja/nein Statement) erfasst.

Erfolgsfaktor Unternehmenskultur

Die Unternehmenskultur, die sich bei entsprechender Ausrichtung positiv auf den Erfolg von Data Mining Projekten ausüben soll, wird im Rahmen dieser Studie durch die Indikatoren *Unternehmenssicht* (konservativ bis modern), *Verhalten der Entscheidungsträger einem Wandel gegenüber* (aufgeschlossen bis ablehnend), *Interne Kommunikation* (schlecht bis gut) und *Hierarchische Planung* (retrograd bis progressiv) erfasst.

Erfolgsfaktor Commitment

Die Unterstützung eines Projektes durch das Top-Management, die durch Freisetzung von Ressourcen und Sensibilisierung der Mitarbeiter im Allgemeinen positive Effekte für die betrachteten Projekte zur Folge hat, wird durch die Indikatoren *Patenschaft von Seiten der Unternehmensleitung für wichtige Projekte* (nie bis immer) und *Data Mining Projektpatenschaft von Seiten der Unternehmensleitung* (ja oder nein) beschrieben.

Erfolgsfaktor Change-Management

Die *organisatorische Änderung des Work-Flow im Unternehmen* (vollkommen bis gar nicht) als Voraussetzung zur Integration des Data Mining im Unternehmen, die tatsächliche *Verankerung des Data Mining im Work-Flow* (Stand-Alone bis integriert) sowie die *Integration von Endanwendern im Data Mining Team* sollen als Indikatoren für das Change-Management im Unternehmen verwendet werden.

Erfolgsfaktor Organisatorische Absicherung

Je besser ein Projekt im Unternehmen abgesichert ist, umso effizienter kann gearbeitet werden, da z.B. keine Ressourcen für die Beschaffung von Finanzmitteln oder Personal verwendet werden (müssen) und die Projektmitarbeiter eine gewisse Planungssicherheit erfahren. Kennzeichen, die diese organisatorische Absicherung in der vorliegenden Studie erfassen sollen, sind das *Vorhandensein eines festen Jährlichen Budgets* (ja oder nein), die *organisatorische Verankerung im Unternehmen* (Stabsstelle oder Linie) sowie die *Durchführung einer Erfolgskontrolle* (immer bis nie).

Erfolgsfaktor Integration der Ergebnisse

Dieses Konstrukt soll mit Hilfe der folgenden Indikatoren erfasst werden: *Aufgeschlossenheit der Fachabteilungen gegenüber den Resultaten des Data Mining* (sehr bis gar nicht), *Umsetzung der Ergebnisse in den Fachabteilungen* (immer bis nie) und *Schulung der Mitarbeiter im Data Mining* (regelmäßig bis nie). Der letztgenannte Indikator wird vor allem deshalb gewählt, weil davon auszugehen ist, dass entsprechend geschulte Mitarbeiter um die Möglichkeiten der Anwendung der Data Mining Resultate wissen und deshalb zur besseren Integration der Ergebnisse beitragen können.

Erfolgsfaktor Informationstechnologie

Die Informationstechnologie, die sich bei adäquater Ausstattung positiv auf den Erfolg von Data Mining Projekten auswirken sollte, wird durch die Indikatoren *Integration des Data Mining Prozesses in die IT-Landschaft* (sehr gut bis schlecht), *Datenqualität* (sehr gut bis schlecht), *Existenz eines funktionsfähigen Data Warehouse* (ja oder nein), *Existenz eines Data Mining Servers* (ja oder nein), *Verwendung von OLAP Techniken* (sehr häufig bis nie) und das *Miteinander von Data Mining und OLAP* (sich unterstützend bis in Konkurrenz) beschrieben.

Erfolgsfaktor Externe Ressourcen

Die *Unterstützung der Data Mining Projekte durch externe Berater* (immer bis nie) sowie die *Wichtigkeit, extern(e) Daten zuzukaufen* (sehr wichtig bis unwichtig) sollen als Indikatoren für das Konstrukt Externe Ressourcen verwendet werden.

Erfolgsfaktor Markt- und Wettbewerbssituation

Die Operationalisierung dieses Konstruktes orientiert sich an Helm (1997) und erfasst die verschiedenen Facetten mittels der folgenden Indikatoren im Zielmarktes: *Intensität der Wettbewerbes* (schwach bis stark), *Wachstum* (schrumpfend bis expandierend), *Anzahl der Wettbewerber* (gering bis sehr hoch), *Relative Größe des Unternehmens* (klein bis sehr groß), *Preispolitischer Spielraum* (gering bis sehr groß) und *Marktpotential* (gering bis sehr groß).

Erfolgskonstrukte

In den traditionellen Anwendungsbereichen der Erfolgsfaktorenforschung werden vielfach objektive, ökonomische Kennzahlen zur Operationalisierung des Erfolgs herangezogen. Insbesondere der ROI, der Return on Investment, hat in diesem Kontext, auch aufgrund des PIMS-Projektes, hohe Bedeutung erlangt (Buzzell und Gale, 1987). Eine Systematisierung dieser ökonomischen Kennzahlen nach Kube (1991, S. 44) führt zu umsatzorientierten Erfolgsgrößen (z.B. Geschäftsvolumen oder Umsatzwachstum), zu marktleistungsorientierten Erfolgsgrößen (z.B. Marktanteil) und zu ertragsorientierten Erfolgsgrößen (z.B. ROI oder Deckungsbeitrag).

Die Verwendung solcher Kennzahlen im Rahmen dieser fokussierten Studie erscheint aber problematisch. Zwar lassen sich bei entsprechend durchgeführter Kostenrechnung die dem Data Mining zugehörigen Kosten (näherungsweise) bestimmen, aussagekräftige Zahlen bzgl. des ertragsorientierten, finanziellen Wirksamkeit der Data Mining Investition scheitern aber im Allgemeinen am Problem der Zurechenbarkeit der verschiedenen Unternehmensaktivitäten auf den Erfolg: Ist es z.B. die Umsetzung der Ergebnisse des Data Mining, die den unternehmensweit festzustellenden Gewinnanstieg erklären oder ist es die verbesserte Kommunikationsstrategie? Gleiches gilt im Übrigen auch für die umsatz- und marktleistungsorientierten Erfolgsgrößen.

In vergleichbaren anderen Studien zur Erfolgsfaktorenforschung wird deshalb die Verwendung subjektiver Erfolgsgrößen, d.h. die subjektive Erfolgsbewertung durch die Entscheidungsträger vorgeschlagen (Bornemeyer, 2002, S. 76). Obwohl der Einsatz der subjektiven Einschätzung als alleinige Erfolgsgröße zunächst zweifelhaft erscheint, sind in der Literatur durchaus positive Erfahrungen mit diesen Erfolgsgrößen dokumentiert, wobei die Nutzung der subjektiven Einschätzung nur bei Abwesenheit objektiver Erfolgsgrößen empfohlen wird (Dess und Robinson, 1984, S. 270).

Um dennoch das komplette Spektrum des Erfolgs der Data Mining Projekte auch auf Basis subjektiver Indikatoren zu messen, sollen Einschätzungen der zu Befragenden sowohl bzgl. umsatz-, marktleistungs- und ertragsorientierter Erfolgsgrößen als auch bzgl. kunden- und prozessorientierter Erfolgsgrößen abgefragt werden. Ein globales Gesamturteil soll ebenfalls als Indikator für den Erfolg der Data Mining Projekte verwendet werden. Es ergeben sich somit die folgenden Indikatoren, die den subjektiv wahrgenommenen Erfolg (nicht erfolgreich bis sehr erfolgreich) der zu Befragenden hinsichtlich des Einsatzes des Data Mining bezüglich folgender Ziele messen sollen: *Umsatzsteigerung, Höhere Marktdurchdringung, Verbesserung der Wettbewerbsposition, Deckungsbeitragssteigerung, Deckungsbeitragssteigerung pro Kunde, Kostenreduktion, Erhöhung der Kundenbindung und -zufriedenheit, Optimierung von Geschäftsprozessen*. Eine Einschätzung bzgl. des *Gesamterfolgs* (nicht erfolgreich bis sehr erfolgreich) beschließt die Liste der Indikatoren für das Konstrukt Erfolg von Data Mining Projekten.

III. Auswahl der Untersuchungseinheiten und Erhebungsmethode

Als Zielgruppe der Studie wurden 820 deutsche Unternehmen ausgewählt, die aufgrund ihrer Produkte, ihrer Kunden und aufgrund ihres Marktumfeldes als potentielle Anwender für Data Mining eingestuft wurden. Die Zusammensetzung ergibt sich, nach Branchen unterteilt, gemäß Tabelle 1.

Tabelle 1: Betrachtete Grundgesamtheit und Stichprobe der Untersuchung

Branche	Grundgesamtheit	Stichprobe	Rücklauf
Bank	150	33	22,0%
Einzel- und Großhandel	110	14	12,7%
Versicherung	100	32	32,0%
Energiewirtschaft	94	8	8,5%
Versandhandel	82	13	15,8%
Medienunternehmen/Verlage	64	13	20,3%
Telekommunikation	45	14	31,1%
Sonstige Unternehmen	175	18	10,3%

Die Datenerhebung selbst wurde mittels einer standardisierten schriftlichen Befragung im Zeitraum von Dezember 2001 bis Februar 2002 durchgeführt, wobei den Befragten

die Möglichkeit gegeben wurde, neben dem Zurücksenden des ausgefüllten Fragebogens per Fax oder Post, die Fragen auch elektronisch im Internet zu beantworten.

Der Fragebogen selbst deckt die herausgearbeiteten potentiellen Erfolgsfaktoren und verschiedene Erfolgskriterien des Data Mining sowie einige allgemeine Aspekte der Unternehmen ab und untergliedert sich wie folgt in mehrere Teile:

- **Allgemeine Daten zum Unternehmen:** Hier werden allgemeine Aspekte der Unternehmen wie Branche, Mitarbeiteranzahl oder Umsatzgrößen (Umsatz, Bilanzsumme, Beitragseinnahmen) erfragt. Zusätzlich wird die Frage gestellt, welche Funktion der Befragte selbst im Unternehmen ausübt.
- **Unternehmensumfeld:** Neben den oben geschriebenen Indikatoren zur Messung des Konstruktes Markt- und Wettbewerbssituation wird in diesem Frageblock zusätzlich noch die vorrangig verfolgte Geschäftsstrategie im Sinne von Porter (Differenzierungsstrategie, Kostenführerschaft oder Kundenfokussierung) erfragt.
- **Unternehmensorganisation und -kultur:** Dieser Bereich des Fragebogens widmet sich den Aspekten des Konstruktes Unternehmenskultur mit seinen entsprechenden Indikatoren sowie der Frage, inwieweit für wichtige Projekte im Unternehmen Partnerschaften aus der Geschäftsleitung existieren.

Während die ersten Teile des Fragebogens für alle Unternehmen konzipiert sind, differenzieren die weiteren Teile schließlich zwischen Unternehmen, die bereits Erfahrungen mit Data Mining gewonnen haben und denjenigen Unternehmen, die noch nicht mit Data Mining in Berührung gekommen sind. Die zweite Gruppe wurde gebeten, nur noch den folgenden Frageblock zu beantworten, der von der ersten Gruppe nicht berücksichtigt werden sollte:

- **Allgemeine Fragen zur Nicht-Verwendung des Data Mining:** Diese Fragen widmen sich den Gründen, die gegen den Einsatz von Data Mining sprechen (Nutzen wird nicht gesehen, Einsatz für die Branche ungeeignet, Zeit-, Budget- oder Personalrestriktionen sprechen entgegen), erfragen, ob eine Implementierung in naher Zukunft geplant ist und welche Ansätze derzeit verfolgt werden, um Datenbestände adäquat zu analysieren (z.B. einfache Reports, OLAP, Statistische Verfahren).

Die verbleibenden Teile des Fragebogens beschäftigen sich ausschließlich mit Aspekten rund um den Einsatz des Data Mining und sind für nur solche Unternehmen konzipiert, die bereits Erfahrungen auf diesem Gebiet sammeln konnten.

- **Organisation und Integration:** Hier werden die Indikatoren der Konstrukte Change-Management, Organisatorische Absicherung und Integration der Ergebnisse erfasst. Des Weiteren wird auf die Geschäftsleitungspatenschaft für Data Mining Projekte eingegangen sowie erfragt, inwieweit externe Berater zur Unterstützung des Data Mining herangezogen werden.
- **Personal:** Neben der Anzahl neu eingestellter Mitarbeiter im Data Mining Bereich werden in diesem Block zusätzlich noch Fragen zur Zusammensetzung des Data Mining Team (Statistiker, Endanwender) sowie zur Schulung der Mitarbeiter erfragt.
- **Informationstechnologie:** Dieser Teil erhebt die Meinung der Befragten zu Aspekten der Informationstechnologie, d.h. bzgl. der Indikatoren des entsprechenden Konstruktes, sowie zur im Unternehmen verwendeten Data Mining Software.
- **Data Mining Erfolg:** Die Fragen widmen sich schließlich den Indikatoren eines erfolgreichen Data Mining Einsatzes. Neben der Frage, ob der Data Mining Einsatz insgesamt als erfolgreich bezeichnet werden kann, wird auch erfasst, inwieweit der Einsatz bzgl. unterschiedlicher Ziele wie z.B. einer Deckungsbeitragsteigerung oder einer höheren Kundenbindung als erfolgreich beurteilt werden kann. Abschließend wird der Unternehmensvertreter gebeten, Faktoren aufzuführen, die seiner Meinung nach ausschlaggebend für einen erfolgreichen bzw. nicht erfolgreichen Einsatz des Data Mining sind.

Das Anschreiben wurde jeweils an die Leitung der Marketing- bzw. der Marktforschungsabteilung eines Unternehmens mit der Bitte gerichtet, den Fragebogen ggf. an die für Data Mining zuständige Stelle weiterzuleiten. Damit sollte sichergestellt werden, dass der Fragebogen von einer kompetenten Person bearbeitet wird. Von den angeschriebenen Unternehmen antworteten insgesamt 145, davon 55 im Internet und 90 auf herkömmlichem Weg per Post oder Fax. Die nach Branchen differenzierte Rücklaufquote kann ebenfalls Tabelle 1 entnommen werden. Da nach Green und Tull (1988, S. 178) Rücklaufquoten bei Marktforschungsuntersuchungen generell zwischen 10% und 40% liegen und nach Lang (1997, S. 150) bei empirischen Studien zur Erfolgsfaktorenforschung von 25% bis 35% Rücklauf ausgegangen werden kann, lässt sich die vorliegende Studie mit 17,7% als angemessen bezeichnen. Mit einem Rücklauf von 145 Antworten allerdings kann sie auf die bislang im Kontext der Erfolgsfaktorenforschung von Data Mining Projekten wohl umfangreichste Datengrundlage in Deutschland zurückgreifen.

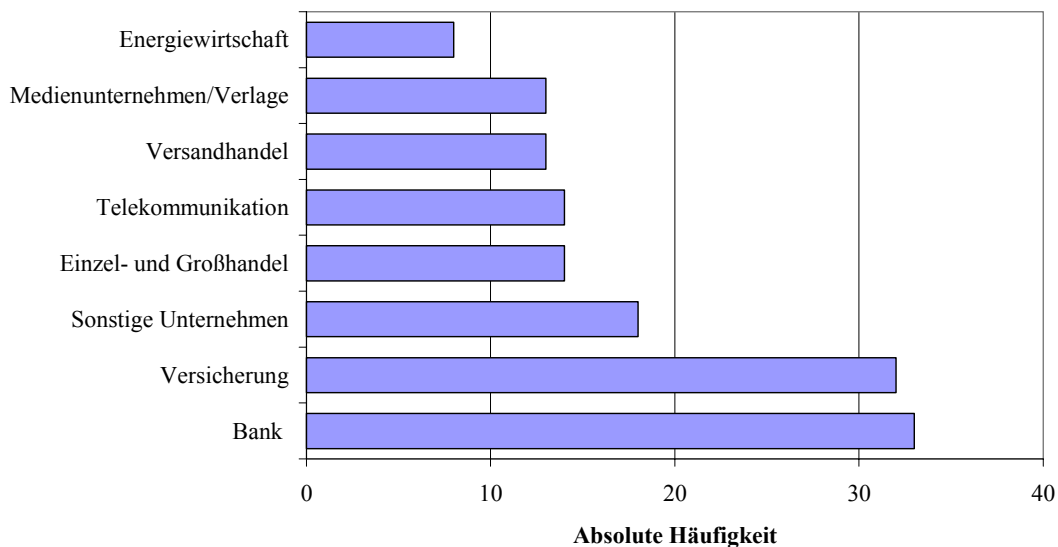
IV. Deskriptive Datenanalyse und Interpretation der Ergebnisse

1. Charakterisierung der befragten Unternehmen

Um einen ersten Eindruck darüber zu erhalten, welche Unternehmen geantwortet haben, d.h. in welcher Branche sie tätig sind, wie viele Mitarbeiter sie beschäftigen, wie groß wichtige betriebswirtschaftliche Kenngrößen sind und welche Position die befragte Person innehat, soll im Folgenden eine deskriptive, univariate Analyse der entsprechenden Variablen durchgeführt werden.

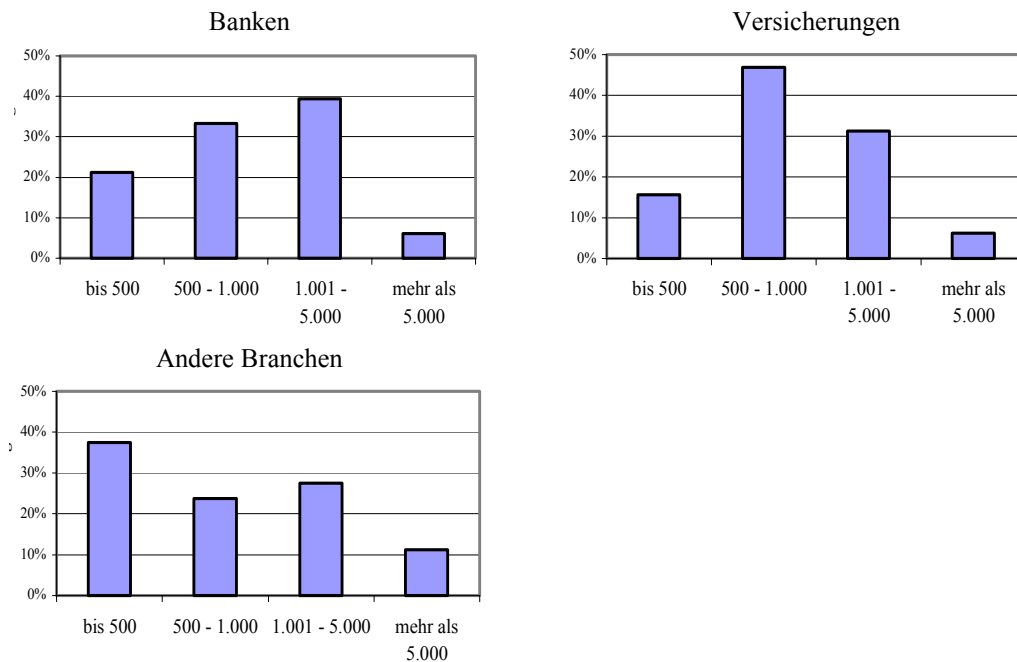
Die Analyse der Branchenzugehörigkeit der 145 antwortenden Unternehmen in Abbildung 6 zeigt, dass vor allem Unternehmen aus dem Bereich Bank und Versicherung an der Umfrage teilgenommen haben. Dies ist ebenso die der vergleichsweise hohe Anteil an Unternehmen aus den Branchen Handel und Telekommunikation mit den Erwartungen konform. Überraschend bleibt letztlich nur die geringe Beteiligung von Unternehmen aus der Energiewirtschaft, bei denen – auch relativ betrachtet – nur etwa 8,5% Rücklauf zu verzeichnen ist.

Abbildung 6: Rücklauf in den einzelnen Branchen



Differenziert man im Folgenden die Untersuchungen zur Mitarbeiteranzahl im Unternehmen und zur betriebswirtschaftlichen Erfolgskennzahl Umsatz bzw. Bilanzsumme bzw. Beitragszahlungen nach den Branchen Bank und Versicherung einerseits und fasst die verbleibenden Branchen aufgrund ihrer Vergleichbarkeit zusammen, so ergibt sich die in Abbildung 7 dargestellte Situation. Es ist deutlich zu erkennen, dass in allen Branchen der Schwerpunkt der Analyse auf Unternehmen mit mittlerer bis großer Mitarbeiterzahl liegt (500 – 5.000).

Abbildung 7: Mitarbeiterzahl der verschiedenen Hauptbranchen



Einzig im Bereich des Branchenmix ist ein erhöhter Anteil kleinerer Unternehmen (bis 500 Mitarbeiter) zu verzeichnen, was sich aber bei genauerer Untersuchung durch die strukturell bedingten geringen Mitarbeiterzahlen vor allem in den Branchen Dienstleistung und Energiewirtschaft begründet.

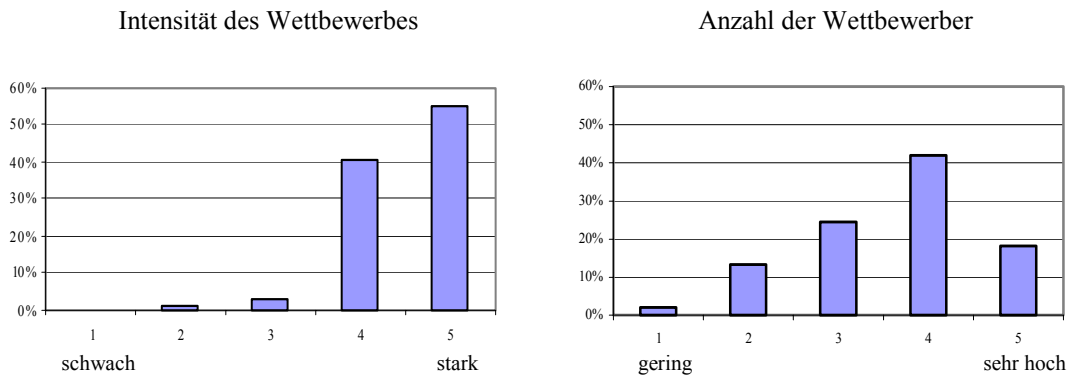
Auf eine inferentiell-statistische Untersuchung der Repräsentativität der Stichprobe soll verzichtet werden, da diese Analyse die Kenntnis der Verteilung der entsprechenden Größen in der Grundgesamtheit voraussetzt, im Rahmen dieser Studie aber bereits das Problem der exakten Abgrenzung der Grundgesamtheit nur theoretisch, aber nicht praktisch gelöst werden kann. Allerdings kann davon ausgegangen werden, dass der Großteil der Unternehmen, die als potentielle Kunden und damit Nutzer von Data Mining in Frage kommen, im Rahmen dieser Stichprobe adäquat repräsentiert wird und die Ergebnisse somit auf die Gesamtheit der Unternehmen, die Data Mining verwenden (werden), übertragbar ist.

Bei der Auswertung der offenen Frage zur Aufgabe bzw. Position der Befragten ergibt sich ein erfreuliches Bild: Von den insgesamt 111 Personen, die diese Frage beantworteten, gaben 61, d.h. etwa 55% an, in einer leitenden Position im Bereich Marketing (31), Marktforschung (10), Database Marketing (8), CRM (6), Projektmanagement (3) oder Vertrieb (2) zu sein. Die verbleibenden Antworten stammten von Mitarbeitern in diesen Bereichen, fachfremde Antworten wurden nicht gezählt. Insgesamt kann somit davon ausgegangen werden, dass der Fragebogen von kompetenten Personen bearbeitet wurde.

2. Die Markt- und Wettbewerbssituation

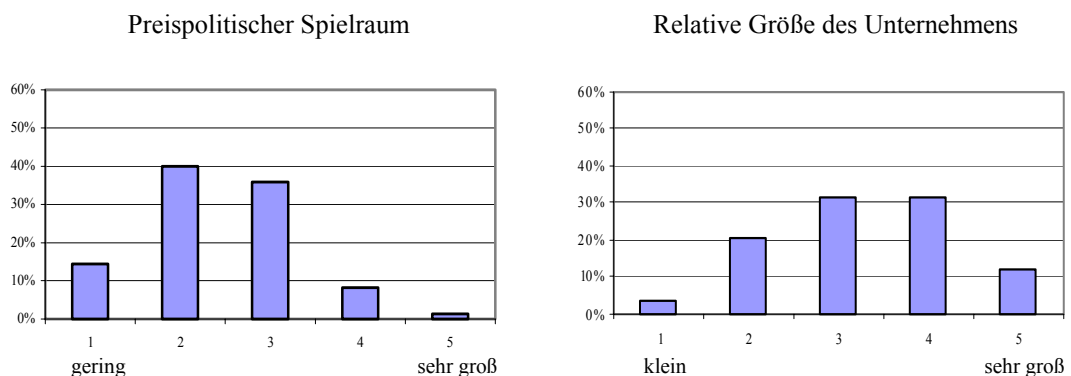
Bzgl. des unternehmerischen Umfeldes, in dem die befragten Unternehmen derzeit agieren, lassen sich folgende Aussagen treffen: Die meisten Unternehmen sehen die Intensität des Wettbewerbes als stark an, was sich auch an der Anzahl der im direkten Wettbewerb stehenden Konkurrenten erkennen lässt (Abbildung 8).

Abbildung 8: Wettbewerbssituation



Ähnlich schlecht ist die Ausgangssituation der befragten Unternehmen, wenn man den preispolitischen Spielraum für Marketingaktivitäten betrachtet. Ein Großteil der Unternehmen sieht sich in Märkten, in denen der Handlungsspielraum bei der Preisfestlegung als ein Mittel der Marketingpolitik eher klein ist. Da zusätzlich viele der befragten Unternehmen auch noch zu den im Vergleich zu den übrigen Marktteilnehmern der Branche kleineren Anbietern gehören, besteht auch keine Möglichkeit, durch die *economy of scale* auf der Kostenseite Einsparungen zu erwirtschaften, die dem geringen preispolitischen Spielraum entgegen wirken könnten.

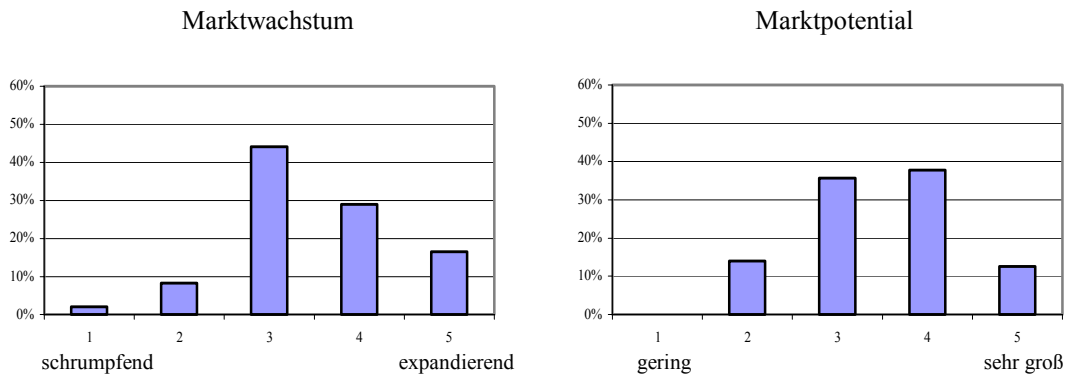
Abbildung 9: Preispolitischer Spielraum im Markt und Größe der Unternehmen



Obwohl also das Umfeld der Unternehmen in vielen Fällen eher gegen eine Aufrechterhaltung der Geschäftsaktivitäten spricht, zeigt die Abbildung 10 doch deutlich, warum

Unternehmen dennoch in diesen Märkten agieren: Sowohl das Marktwachstum als auch das Marktpotential ist als überwiegend positiv zu beurteilen und die Chancen, die den Unternehmen in diesen Märkten damit offen stehen, sind als gut zu bezeichnen.

Abbildung 10: Marktwachstum und Marktpotential




Schließlich bleibt festzuhalten, dass 61,4% der befragten Unternehmen als vorrangige Geschäftsstrategie (Mehrfachnennungen waren möglich) die Differenzierungsstrategie (Hervorhebung z.B. durch bessere Qualität) verfolgen, während nur 26,9% z.B. die Kostenführerschaft bevorzugen. Eine Kundenfokussierung, wie sie ein modern ausgerichtetes Unternehmen im Sinne des Customer Relationship Managements betreiben sollte, wurde immerhin noch von 60,7% der Unternehmen genannt.

3. Unternehmensorganisation und –kultur der Unternehmen


Bei der Analyse der hier erhobenen Indikatoren fällt auf, dass der Großteil der an der Befragung teilnehmenden Personen, die i.a. nicht der Geschäftsleitung angehören, ihr Unternehmen als modern und aufgeschlossen bezeichnen (Abbildung 11).

Abbildung 11: Modernität und Aufgeschlossenheit der Unternehmen



Betrachtet man gleichzeitig die Organisationsstruktur der Unternehmen, so kann diese Aussage bestätigt werden. Nur 28,5% der Unternehmen weisen nach Aussagen der Befragten eine retrograde Organisationsstruktur auf, d.h. eine Organisationsstruktur, die als top-down Variante bezeichnet wird und durch Vorgabe der Aufgaben von *oben* charakterisiert ist. Im Allgemeinen gelten solche Unternehmen eher als konservativ und einem Wandel gegenüber eher weniger aufgeschlossen. Demgegenüber sind die meisten der Unternehmen organisatorisch eher progressiv (23,6%) oder zumindest gegenläufig (47,9%) ausgerichtet. Umso mehr verwundert es aber, dass die Übernahme von Projektpatenschaften durch Mitglieder der Geschäftsleitung vergleichsweise häufig vernachlässigt wird, obwohl gerade dies für eine moderne Ausrichtung eines Unternehmens sprechen würde. Bzgl. der internen Kommunikation in den Unternehmen zeichnet sich eine recht erfreuliche Situation ab.

Abbildung 12: Projektpatenschaften und interne Kommunikation




4. Charakterisierung der auf Data Mining verzichtenden Unternehmen

Von den 145 Unternehmen, die den Fragebogen zurücksandten, gaben 41 (28,3%) davon an, noch keinerlei Erfahrungen mit Data Mining zu besitzen. Diese Unternehmen wurden dennoch gebeten, einige Fragen zusätzlich zu beantworten. So interessierte zunächst, ob die Unternehmen über funktionsfähige Data Warehouse Lösungen verfügen, die unabhängig von den operativen Systemen als Basis für komplexe Datenauswertungen dienen könnten. Hier zeigte sich, dass bei knapp mehr als der Hälfte der Firmen (21) ein Data Warehouse vorhanden ist, und somit die technischen Grundlagen für einen Data Mining Einsatz generell geschaffen wären.

Interessant ist des Weiteren, dass diese Unternehmen durch den Verzicht des Einsatzes von Data Mining Techniken die Möglichkeit, wichtige Informationen aus ihren Daten

herauszufiltern, nicht völlig ausschließen. Vielmehr finden vor allem einfache Reports, Verfahren der klassischen Statistik und der Datenanalyse sowie Visualisierungstechniken Anwendung bei der Auswertung komplexer Datenbestände (Abbildung 13).

Abbildung 13: Ansätze zur Auswertung komplexer Datenbestände



Da nun in vielen Unternehmen die technischen Voraussetzungen zur Implementierung eines Data Mining Systems erfüllt sind und Ansätze zur Auswertung komplexer Datenbestände vorhanden sind und auch genutzt werden, stellt sich die Frage, welche Gründe bisher gegen den Data Mining Einsatz sprechen.

Abbildung 14: Gründe gegen den Einsatz von Data Mining

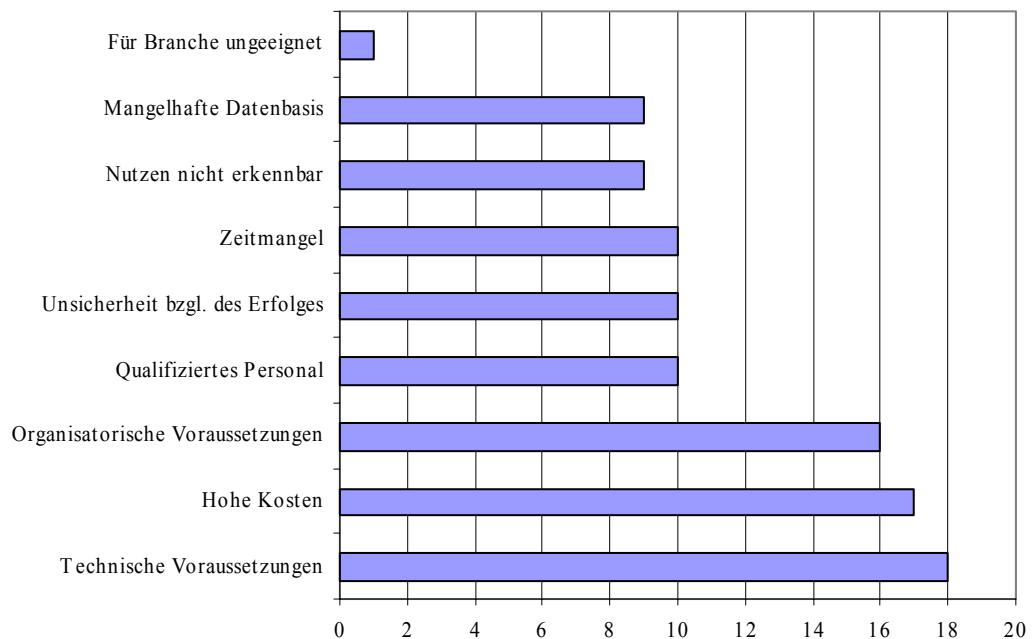


Abbildung 14 zeigt, dass vor allem die mit der Implementierung anfallenden hohen Kosten und das Nichtvorhandensein der technischen Voraussetzungen Hemmnisse für den Einsatz von Data Mining Techniken darstellen. Dass das Data Mining für ihre Branche durchaus geeignet wäre, erkennen nahezu alle Unternehmen; allerdings besteht auch bei vielen Unternehmen nach wie vor eine große Unsicherheit bzgl. des Erfolges dieser Technik und viele Unternehmen können keinen direkten Nutzen in der Anwendung des Data Mining für Ihr Geschäftsfeld erkennen. Trotzdem gaben 18 der 41 befragten Unternehmen an, dass die Einführung von Data Mining in naher Zukunft geplant sei.

5. Aspekte zur Organisation und Integration von Data Mining Projekten

Von den 145 Unternehmen, die den Fragebogen beantworteten, gaben 104 (71,7%) an, heute bereits Data Mining Techniken im betrieblichem Umfeld zu verwenden. Um die Wichtigkeit dieser Data Mining Projekte zu erfassen, wurden die Unternehmen im Folgenden gebeten, anzugeben, ob die Geschäftsleitung eines ihrer Mitglieder mit der Verantwortung für das Data Mining Projekt betraut hat. Ein Projektpate aus den Reihen der Geschäftsleitung würde den Stellenwert des Projektes im Unternehmens aufwerten und so dazu beitragen, dem erfolgreichen Einsatz Vorschub zu leisten. Erstaunlich – und nach der Analyse der generellen Projektpatenschaften in der Höhe schwer nachvollziehbar – ist allerdings, dass dies bei nur 45,7% der befragten Unternehmen der Fall ist.

Die Analyse der organisatorischen Verankerung der Data Mining Projekte zeigt, dass eine klare Tendenz zur Verankerung in einer Fachabteilung vorherrscht. Konkret unterstellen 70 Unternehmen (67,3%) das Data Mining Projekt einer Fachabteilung, wobei 30 Unternehmen dies noch einmal genauer spezifizierten: So gehört das Data Mining in 16 Unternehmen zur Marketing-Abteilung, bei 7 ist das Database Management, bei 3 das Direktmarketing, bei weiteren 3 die Marktforschung und schließlich bei 2 Unternehmen das Vertriebsmanagement für das Data Mining zuständig. Lediglich bei 34 Unternehmen (32,7%) ist das Data Mining in einer Stabsstelle verankert und kann ohne organisatorische Umwege direkt als Dienstleister für alle Fachabteilungen auftreten.

Bedingt durch die in vielen Unternehmen vorzufindende Verankerung/Integration der Data Mining Projekte in Fachabteilungen ist auch zu erklären, warum nach Aussage der Befragten mehrheitlich der Work Flow des Unternehmens nicht geändert wurde (Abbildung 15); eine Tatsache, die die Effizienz der Projekte durchaus in Frage stellen kann. Bzgl. der Integration des Data Mining im Work Flow herrscht hingegen eine starke He-

terogenität unter den befragten Unternehmen (Abbildung 15). Eine schwache Mehrheit setzt verstärkt auf eine Integration des Data Mining in den normalen Work Flow, während ein nicht unerheblicher Teil der Unternehmen die Rolle des Data Mining im Work Flow als eher stand-alone sieht. Man erkennt somit eindrucksvoll die Unsicherheit bei den Unternehmen, die zurzeit nicht wissen, wo das Data Mining im Work Flow einzuordnen ist und inwieweit dieser Work Flow dem Data Mining anzupassen wäre. Generell kann man aber davon ausgehen, dass eine völlige Integration und eine Änderung des normalen Arbeitsablaufes die Erfolg versprechendste Lösung auf dem Gebiet der Einordnung des Data Mining im Unternehmensalltag ist.

Abbildung 15: Data Mining und der Work Flow

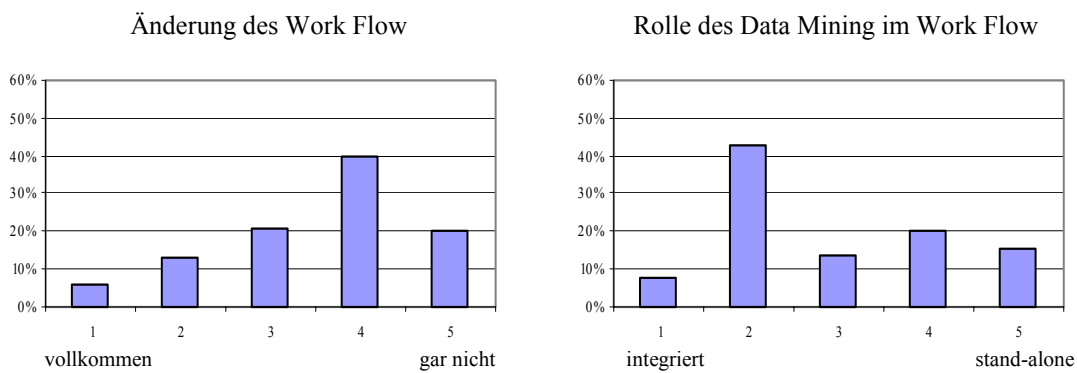
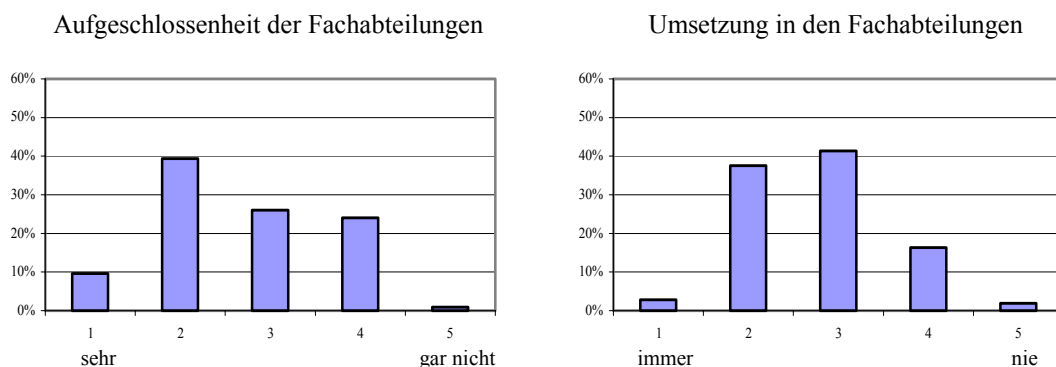


Abbildung 16 zeigt darüber hinaus ein weiteres Problem bei der Anwendung von Data Mining Techniken: die Akzeptanz und Umsetzung der Ergebnisse in den Fachabteilungen. Häufig ist davon die Rede, dass das Data Mining bei den involvierten Abteilungen nicht akzeptiert wird und als Folge die Ergebnisse in die Praxis entweder selten umgesetzt oder nur von mangelnder Qualität sind. Inwieweit dies in einem kausalen Zusammenhang zur Integration des Data Mining im Work Flow steht, kann an dieser Stelle allerdings nicht beantwortet werden.


Abbildung 16: Kooperationsbereitschaft der Fachabteilungen



Fakt ist vielmehr, dass bei den befragten Unternehmen die Aufgeschlossenheit der Fachabteilungen den Ergebnissen des Data Mining gegenüber eher positiv ist, auch wenn die Ergebnisse nach wie vor relativ häufig nicht oder nur selten umgesetzt werden.

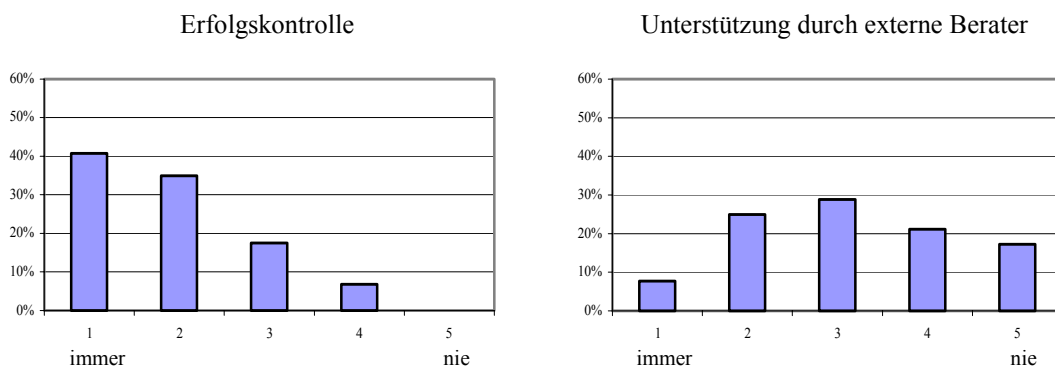
Die Umsetzung der Ergebnisse, die von Mitarbeitern in der Vergangenheit unter Verwendung von Data Mining Techniken erzielt wurden, steht in Abbildung 17 im Mittelpunkt; Mehrfachnennungen waren dabei möglich.

Abbildung 17: Umsetzung der Data Mining Ergebnisse



Es ist auffällig, dass die Definition neuer Zielgruppen und die Steigerung der Kundenzufriedenheit sehr häufig genannt wurden. Zusätzlich zu diesen im Fragebogen vorgegebenen Antwortmöglichkeiten wiesen einige Befragte noch auf weitere Umsetzungsmöglichkeiten wie z.B. die Konkurrenzbeobachtung und Potentialanalyse, die Identifikation Storno gefährdeter Personen sowie die Steigerung des Pro-Kopf-Umsatzes hin.

Abbildung 18: Erfolgskontrolle und externe Berater




Anzumerken bleibt im Übrigen, dass bei 61 der befragten Unternehmen (58,7%) das Data Mining über ein festes jährliches Budget verfügt, und dass 78 (75,7%) angeben, dass die Ergebnisse des Data Mining und deren Umsetzungen immer oder fast immer einer Erfolgskontrolle unterzogen werden. Des Weiteren führen sogar 90% der Unternehmen mit Budgetzuweisung eine Erfolgskontrolle durch, was darauf hinweist, dass in diesen Unternehmen die organisatorische Verankerung und das Commitment des Data Mining durch die Managementschritte Planung und Kontrolle vergleichsweise fest ist.

Schließlich zeigt Abbildung 18 noch, dass die Data Mining Projekte häufig, aber bei Weitem nicht immer durch Consultants, d.h. durch externe Berater, unterstützt werden (müssen).

6. Personaleinsatz im Data Mining Projekten

Da das Data Mining – bedingt durch seine Komplexität und Schwierigkeit – einen völlig neuen Arbeitsbereich für viele Unternehmen darstellt, stellt sich die Frage, wie viele neue Mitarbeiter zur komplexen Datenanalyse eingestellt wurden bzw. werden müssen, um den zusätzlichen Bedarf an Know-How und Arbeitsleistung zu decken. Abbildung 19 zeigt die Anzahl der Neueinstellungen.

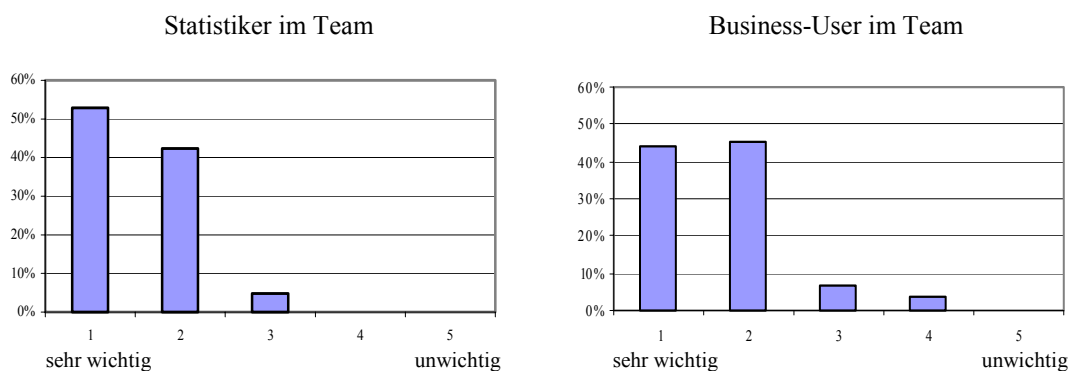
Abbildung 19: Neueinstellung und Schulung der Mitarbeiter



Verwunderlich ist, dass 34 Unternehmen (33,1%) angeben, keinen neuen Mitarbeiter für das Data Mining eingestellt zu haben. Dies kann so interpretiert werden, dass der für die komplexe Datenauswertung benötigte Zeitaufwand so gering gehalten wird, dass er noch von den bisher in der Abteilung tätigen Mitarbeitern kompensiert werden kann. Das hierfür nötige Know-How mag in der Abteilung schon vorhanden sein, oder ist mit der Anschaffung eines Data Mining Tools und den damit einhergehenden Schulungen

aufgebaut worden. Die Tatsache, dass nur vier Firmen angeben, schon über 10 Mitarbeiter für das Data Mining eingestellt zu haben, verwundert an dieser Stelle ebenfalls nicht, da vielfach die Zahl der betriebswirtschaftlich sinnvoll erscheinenden Analysen begrenzt sind, und dementsprechend auch nur eine begrenzte Anzahl an Mitarbeitern hierfür benötigt wird. Der Großteil der Unternehmen hat ein bis fünf neue Mitarbeiter mit der Durchführung des Data Mining betraut, um einen Einstieg in ein für sie noch neues Feld vorsichtig anzugehen und zu analysieren, ob weitere Investitionen, d.h. eventuell weitere Neueinstellung sinnvoll erscheinen. Um im Übrigen das notwendige, qualitativ hohe Niveau der Mitarbeiter schaffen oder halten zu können, werden die Mitarbeiter eines Großteils der befragten Unternehmen (67,0%) regelmäßig geschult (Abbildung 19).

Abbildung 20: Zusammensetzung des Data Mining Team




Da aber nicht nur die Quantität und Qualität der einzelnen, in den Data Mining Projekten eingesetzten Mitarbeiter entscheidend für den Erfolg der Projekten sein kann, muss sichergestellt werden, dass das Team in seiner Zusammensetzung alle notwendigen Qualifikationen aufweist. So ist ein fundiertes statistisches Wissen für viele Unternehmen ebenso unabdingbar (Abbildung 20) wie betriebswirtschaftliches Know-How, das durch sog. Business-User im Team repräsentiert wird. Interessant ist dabei allerdings, dass die Notwendigkeit von Statistikern im Team von 99 der 104 Unternehmen als sehr wichtig oder wichtig eingestuft wird, dass aber etwas weniger Unternehmen dies auch bei Business-Usern so sehen.

7. Informationstechnologie im Zusammenspiel mit Data Mining

Da der reibungslose Ablauf des Data Mining Prozesses im Allgemeinen nur dann zu gewährleisten sei wird, wenn eine erfolgreiche Einbettung dieses Prozesses in die vorhandene Informationstechnologie erreicht wird, interessierte zunächst die Integration des Data Mining in die bestehende IT-Landschaft. Die befragten Unternehmen gaben hier an, dass diese Integration durchschnittlich bis gut gelungen ist (Abbildung 21).

Abbildung 21: Data Mining Integration in die bestehende IT-Landschaft

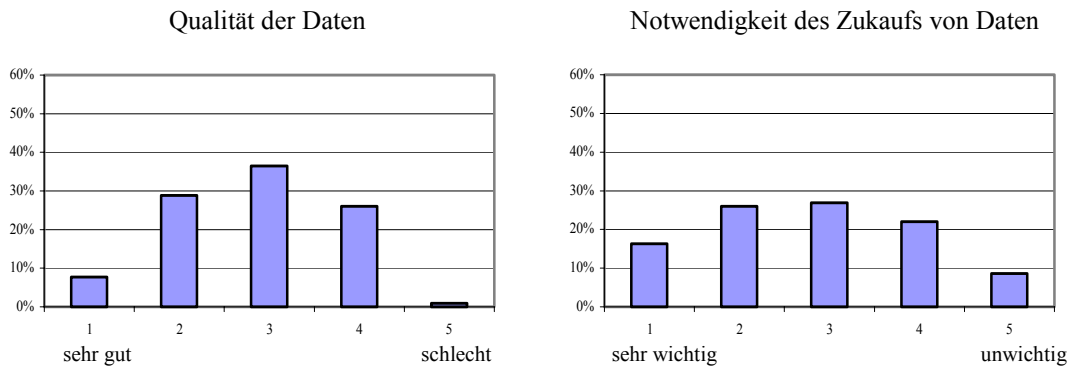


Eine Speicherung der von den Unternehmen vorgehaltenen Daten in einem Data Warehouse, der wohl modernsten Alternative der Datenhaltung, ist bei 75 der befragten Unternehmen (72,2%) vorzufinden. Um die Data Mining Prozesse auch schnell durchführen zu können, d.h. geringe Zugriffs- und Transformationszeiten zu haben, besteht technisch die Möglichkeit, einen Server zu installieren, der ausschließlich mit den im Rahmen des Data Mining notwendigen Prozessen betraut ist. Diese Alternative wird allerdings nur bei 59 der Antwortenden (57,8%) realisiert. Betrachtet man des Weiteren diese beiden Merkmale gleichzeitig, so erkennt man, dass 88,1% der Unternehmen, die über einen selbständigen Data Mining Server verfügen, auch eine unternehmensweite Datenbank in Form eines Data Warehouses unterhalten.

Das Kriterium der Datenqualität war Thema weiterer Fragen. Die Qualität der dem Data Mining aus den operativen Systemen zur Verfügung gestellten Daten wurde dabei überwiegend als durchschnittlich bezeichnet (Abbildung 22); die Spanne reicht sowohl von sehr guten Daten bis hin zu sehr schlechten Daten. Haben die Unternehmen selbst schlechte Daten in ihrer Datenbank vorliegen, liegt die Vermutung nahe, dass vermehrt auf die Möglichkeit der externen Zukaufs von Daten zurückgegriffen wird. Dies wird an dieser Stelle als relativ wichtige Option von den Unternehmen bewertet, allerdings nicht

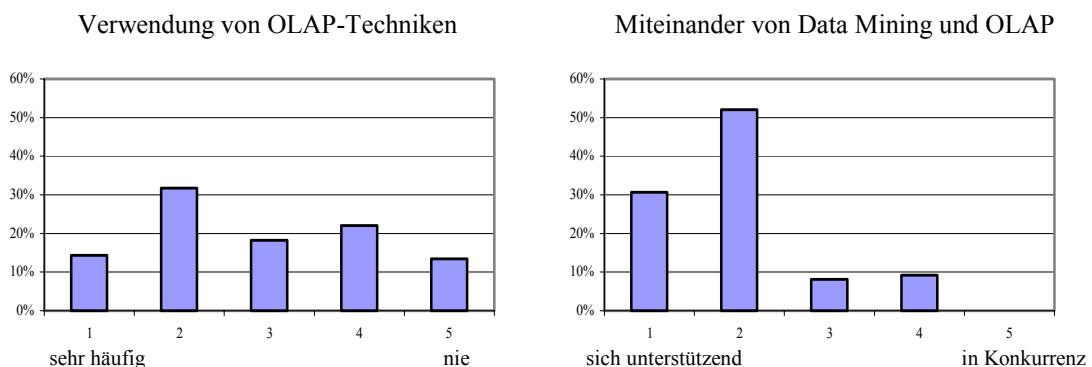
signifikant oft von den Unternehmen, die angaben, über Daten schlechter Qualität zu verfügen. Abbildung 22 verdeutlicht die univariate Verteilung der beiden Antworten.

Abbildung 22: Data Mining und das Datenproblem



Der Zugriff auf die Daten selbst, die bei 72,2% der Unternehmen in Form eines Data Warehouses gespeichert sind, kann nicht nur mit Data Mining Techniken sondern auch mittels OLAP-Techniken erfolgen. Obwohl diese Techniken also auf Basis multidimensionaler Zugriffe zur Klärung anstehender Aufgaben betragen können, verwenden nur 46,2% der Unternehmen diese Möglichkeit häufig oder sehr häufig, der Großteil gab an, OLAP selten oder nie zu verwenden. Dass dieser doch recht geringe Wert daran begründet wird, dass OLAP und Data Mining in Konkurrenz zueinander gesehen werden, konnte allerdings nicht bestätigt werden; denn 82,7% der Unternehmen gaben an, dass OLAP und Data Mining sich im Unternehmen eher unterstützen als in Konkurrenz zueinander zu stehen.

Abbildung 23: Data Mining und OLAP



Der letzte Punkt in diesem Abschnitt beschäftigt sich mit den in den Unternehmen verwendeten Data Mining Softwaretools. Bei den insgesamt 69 Antworten dieser offen gestellten Frage wurden die Programme der Firmen SAS, SPSS, IBM und Prudential Sys-

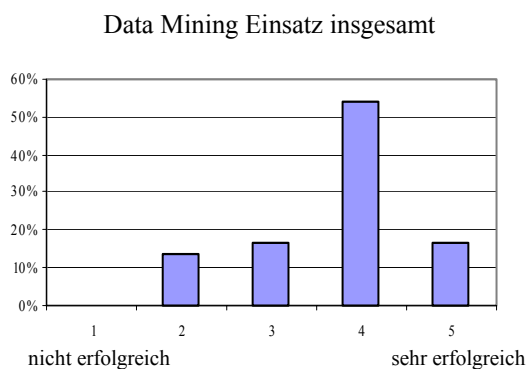
tems am häufigsten genannt. Konkret verwenden 26 Unternehmen den Enterprise Miner von SAS, 22 Befragten gaben an, Clementine oder AnswerTree der Firma SPSS zu verwenden, während der Intelligent Miner von IBM 13mal und der prudsys Discoverer von Prudential Systems 5mal Verwendung findet.

8. Erfolgseinschätzung von Data Mining Projekten

Neben den Fragen zum Unternehmensumfeld, zur Organisation und Kultur der Unternehmen, zur Integration des Data Mining im Unternehmen und zur Personal- und IT-Ausstattung, die alle als potentielle Determinanten eines erfolgreichen Einsatzes von Data Mining Techniken betrachtet werden können, interessierte auch noch, inwieweit die Unternehmen auch mit den Resultaten des Data Mining zufrieden sind. Dazu wurden den 104 Unternehmen, die bereits Erfahrungen in diesem Bereich vorweisen können, Fragen zum Erfolg des Data Mining Einsatzes gestellt.

Bemerkenswert ist dabei zunächst, dass der überwiegende Teil der Befragten mit dem Erfolg des Data Mining Einsatzes insgesamt zufrieden bis sehr zufrieden (Abbildung 24) ist. Da diese mehrdimensionale Einschätzung aber gewisse Risiken birgt (Selbstüberschätzung, Nicht-Eingestehen von Fehlern, etc.) wurden die Unternehmen zusätzlich gebeten, den Erfolg des Data Mining Einsatzes auch bzgl. verschiedener Ziele zu beurteilen (Abbildung 25). Hier zeigt sich deutlich, dass der Erfolg bei den monetären Zielen *Deckungsbeitrags-* und *Umsatzsteigerung* also gut bis

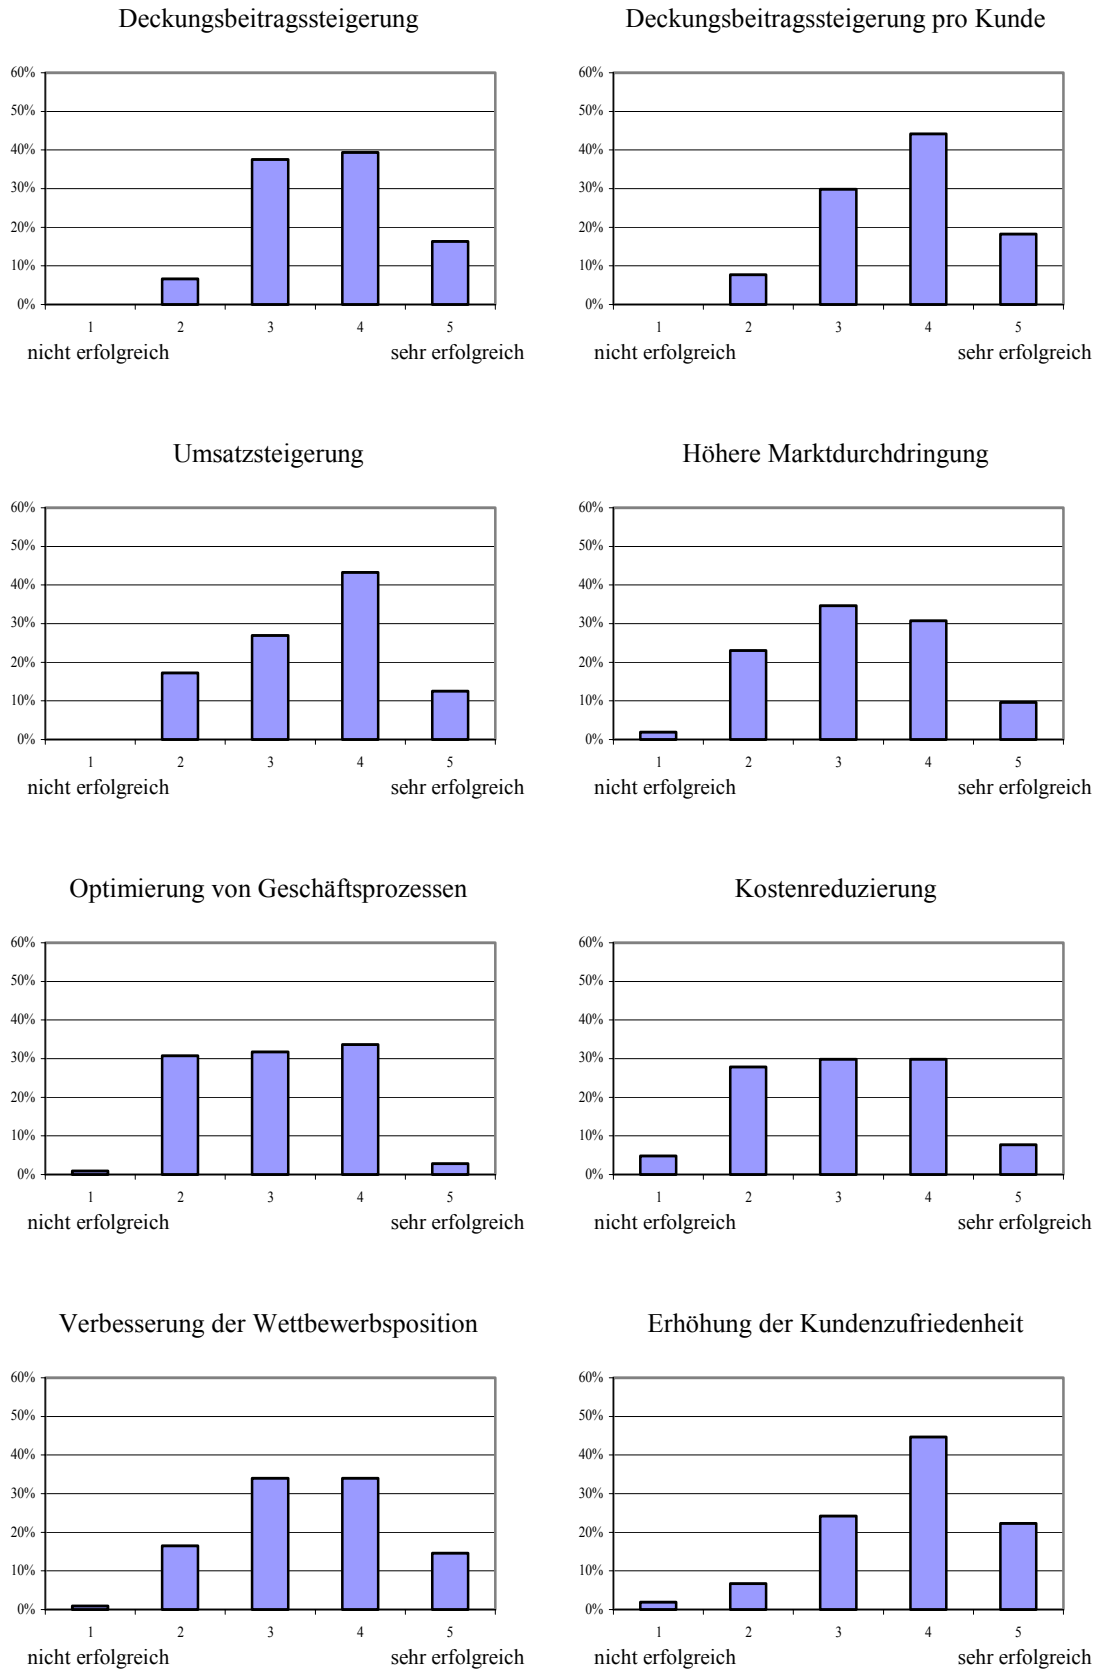
Abbildung 24: Data Mining Erfolg (insgesamt)



schätzung, Nicht-Eingestehen von Fehlern, etc.) wurden die Unternehmen zusätzlich gebeten, den Erfolg des Data Mining Einsatzes auch bzgl. verschiedener Ziele zu beurteilen (Abbildung 25). Hier zeigt sich deutlich, dass der Erfolg bei den monetären Zielen *Deckungsbeitrags-* und *Umsatzsteigerung* also gut bis

sehr gut bezeichnet werden kann, ebenso wie der Erfolg bzgl. des Zieles der *Steigerung der Kundenbindung und -zufriedenheit*. Etwas kritischer wird hingegen der Erfolg des Data Mining bzgl. der Ziele *erhöhte Marktdurchdringung*, *Optimierung von Geschäftsprozessen*, *Kostenreduzierung* und *Verbesserung der Wettbewerbsposition* gesehen, auch wenn man nicht sagen kann, dass die Data Mining Techniken hier versagen.

Abbildung 25: Data Mining Erfolg bzgl. verschiedener Ziele



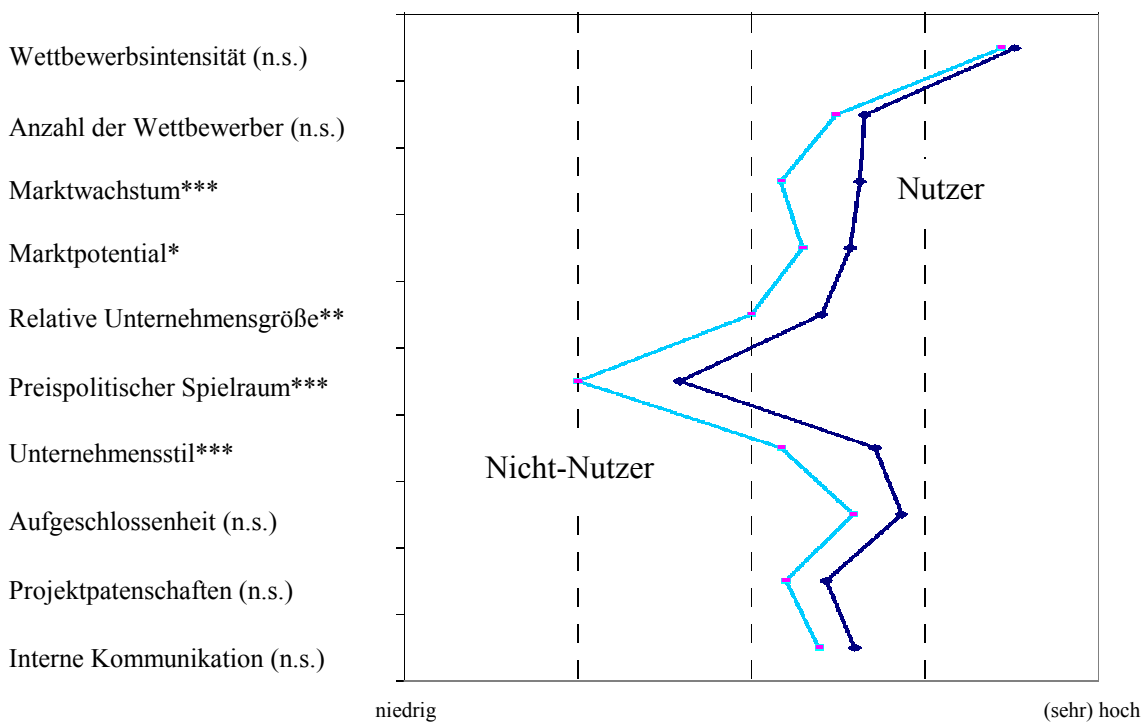
Insgesamt zeigt sich aber, dass die meisten Unternehmen mit dem Data Mining Einsatz zufrieden bis sehr zufrieden sind, auch wenn nicht alle Erwartungen erfüllt werden.

9. Determinanten des Einsatzes von Data Mining Techniken

Nach der bislang erfolgten Darstellung der unternehmensspezifischen Merkmale für alle 145 Unternehmen und der Darstellung der nur von einem Teil der Unternehmen zu beantwortenden Items soll im Folgenden der Frage nachgegangen werden, ob es Unterschiede in den Charakteristika der Unternehmen gibt, die Data Mining Techniken anwenden und denjenigen, die auf die Anwendung solcher Techniken verzichten.

Die Analyse der Merkmale der entsprechenden Themenbereiche *Markt- und Wettbewerbssituation* sowie *Unternehmensorganisation und –kultur* (Anhang 1, Abbildungen A1.1 bis A1.10) zeigt deutlich, dass die Unternehmen, die Data Mining einsetzen, sich einem tendenziell schärferen Wettbewerb mit einer höheren Anzahl von Wettbewerbern stellen müssen als solche, die derzeit noch auf den Einsatz von Data Mining verzichten. Auf der anderen Seite sehen die Nutzer der Data Mining Technologie die Märkte, auf denen sie sich betätigen, deutlich lukrativer, gemessen am Marktwachstum und Marktpotential. Überraschend ist allerdings, dass der preispolitische Spielraum der Data Mining Nutzer deutlich größer ist als der der Nicht-Nutzer.

Abbildung 26: Nutzer- und Nicht-Nutzer-Profile



Bzgl. der Indikatoren zur Unternehmensorganisation und –kultur lässt sich feststellen, dass der Führungsstil der Data Mining Nutzer wesentlich moderner und die Aufge-

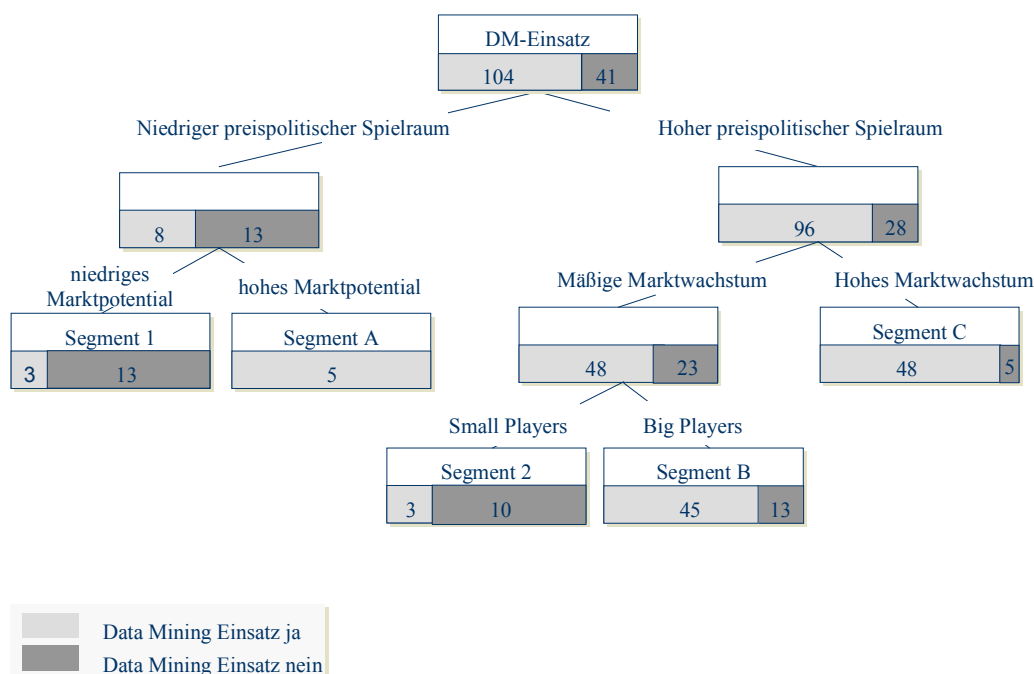
geschlossenheit der Geschäftsleitung einem Wandel gegenüber etwas größer ist. Die Unterschiede bei der Übernahme von Projektpatenschaften und bei der internen Kommunikation sind hingegen nicht so deutlich.

Betrachtet man die Indikatoren – trotz ihrer Ordinalskala-Eigenschaft – im Folgenden als intervall-skaliert (Hilbert, 1998, S. 14) und berechnet auf Basis der Antworten Mittelwerte für die Indikatoren, so ergeben sich die in Abbildung 26 dargestellten Profile für die Gruppe der Nutzer der Data Mining Technologie und für die Gruppe der Nicht-Nutzer, die die oben getätigten Aussagen noch einmal bestätigen können. Auch eine inferentiell-statistische Überprüfung mit Hilfe eines approximativen Zweistichproben-Gaußtests (Bamberg, Baur, 2002, S. 193) kommt zu identischen Aussagen. So existiert z.B. ein hoch signifikanter Unterschied (Irrtumswahrscheinlichkeit $\alpha < 0,01$) beim Marktwachstum zwischen den Nutzer und den Nicht-Nutzer von Data Mining. Generell sind hoch signifikante Unterschiede in Abbildung 26 dabei mit ***, signifikante Unterschiede ($\alpha < 0,05$) mit ** und schwach signifikante Unterschiede ($\alpha < 0,10$) mit * gekennzeichnet. Alle anderen Unterschiede sind nicht signifikant (n.s., $\alpha > 0,10$). Man erkennt also, dass die Wettbewerbssituation – trotz der deskriptiv vorhandenen Unterschiede – nicht trennend ist, ebenso wie die Indikatoren der Projektpatenschaften und der internen Kommunikation, bei denen sich diese Tendenz aber bereits bei der deskriptiven Analyse angedeutete. Überprüft man im Übrigen die Unterschiede der Merkmale auf Basis ihrer ordinalen Ausprägungen direkt mit Hilfe des verteilungsfreien Mann-Whitney-Tests, so ergeben sich identische Aussagen bzgl. der Gruppenunterschiede. Die p-values der entsprechenden Teststatistiken unterscheiden sich nur minimal von denen des oben dargestellten Gaußtests, was auch als Indiz für die Richtigkeit der Intervallskalierung der Daten angesehen werden kann.

Sollen im Folgenden die bislang durchgeführten univariaten Studien zur Diskriminierung von Nutzern und Nicht-Nutzern der Data Mining Technologie durch multivariate Untersuchungen ergänzt werden, so bieten sich alle Verfahren der Identifikation einer binären Zielvariablen wie z.B. die logistische Regression (Hamerle et al., 1984, S. 211), die multivariate Diskriminanzanalyse (Fahrmeir et al., 1984, S. 301), aber auch die Verfahren zur Induktion von Entscheidungsbäumen (Säuberlich, 2000, S. 79) an. Wesentlicher Vorteil der letztgenannten Verfahren ist die Unabhängigkeit der Ergebnisse von den Verteilungsvoraussetzungen der Daten. Gerade die multivariate Diskriminanzanalyse benötigt die Voraussetzung der multivariaten Normalverteilung der involvierten Da-

ten, möchte man über eine rein deskriptive Auswertung hinausgehen. Des Weiteren zeigt sich auch eine gewisse Instabilität der Ergebnisse bei Verletzung dieser Voraussetzung. Ähnliches gilt im Übrigen auch für die logistische Regression. Als relativ stabil kann hingegen die Induktion von Entscheidungsbäumen bezeichnet werden, die im Folgenden auch zur Anwendung kommen soll. Ziel dieser Induktion ist die Erzeugung eines hierarchischen Entscheidungsbaumes, der – beginnend mit einer Wurzel (stellvertretend für die zu betrachtende Gesamtmenge der Objekte) – solange eine Splittung der Menge vornimmt, bis adäquate Gütemaße eine weitere Aufteilung der Objekte als nicht zielführend ablehnen. Schließlich ergibt sich ein Baum, dessen Blätter hinsichtlich der Gütemaße, bei denen es sich im Allgemeinen um Heterogenitätsmaße wie die Entropie oder das Gini-Maß handelt, deutlich besser, d.h. homogener sind als die Gesamtobjektmenge in der Wurzel. Abbildung 27 zeigt das Ergebnis einer solchen Induktion unter Verwendung des CART-Algorithmus von Breiman et al. (1984), der nicht nur die trennfähigsten Merkmale bestimmt, sondern gleichzeitig auch noch die optimale Dichotomisierung ordinaler Indikatoren vornimmt.

Abbildung 27: Entscheidungsbaum zur Erklärung der Nutzer und Nicht-Nutzer



Man erkennt, dass der preispolitische Spielraum der Märkte, auf denen das Unternehmen agiert, am trennfähigsten ist. Existieren nur geringe Spielräume (Antwortmöglichkeit 1), so besteht die Vermutung, dass Data Mining eher nicht zur Anwendung kommt, wohingegen bei größeren Spielräumen (Antwortmöglichkeiten 2 – 5) Data Mining sehr

wohl eingesetzt wird. Ebenso verhält es sich bei Betrachtung der anderen lokal-wirksamen Splitkriterien. So ist z.B. ein sehr großes Marktpotential (Antwortmöglichkeiten 5) für Unternehmen mit sehr geringem preispolitischen Spielraum ein Grund, entgegen dem allgemeinen Trend vergleichbarer Unternehmen doch nicht auf den Einsatz von Data Mining zu verzichten. Bei Unternehmen mit höherem preispolitischen Spielraum erkennt man, dass 90,6% der Unternehmen (48 von 53) mit großem oder sehr großem Marktwachstum (Antwortmöglichkeiten 4 und 5) Data Mining Technologien anwenden, während ein geringeres Marktwachstum eine solch eindeutige Aussage noch nicht zulässt. Betrachtet man aber diese Unternehmen mit höherem preispolitischen Spielraum und geringerem Marktwachstum, so zeigt sich schließlich, dass der Indikator Relative Unternehmensgröße nun eine adäquate Trennung der verbleibenden 71 Unternehmen gestattet. Während die kleineren Unternehmen (Antwortmöglichkeiten 1 und 2) zu 76,9% (10 von 13) auf die Anwendung des Data Mining verzichten, wenden immerhin 77,6% der größeren Unternehmen bereits Data Mining Techniken an.

Zusammenfassend kann festgehalten werden, dass auf Basis des vorliegenden Entscheidungsbaumes bei einer Fehlklassifikationsrate von 20,6% folgende Nicht-Nutzer-Segmente identifiziert werden können:

- **Nicht-Nutzer-Segment 1:** Unternehmen mit sehr geringem preispolitischen Spielraum und höchstens normalem Marktpotential verzichten derzeit auf eine Anwendung von Data Mining.
- **Nicht-Nutzer-Segment 2:** Kleinere Unternehmen mit geringem bis hohem preispolitischen Spielraum und maximal mäßigem Marktwachstum verzichten derzeit ebenfalls auf eine Anwendung der Data Mining Techniken.

Des Weiteren lassen sich bei einer Fehlklassifikationsrate von 15,5% auch folgende Nutzer-Segmente identifizieren, für die zusätzlich noch der durchschnittliche Gesamterfolg bzgl. des Data Mining Einsatzes wiedergegeben ist:

- **Nutzer-Segment A:** Unternehmen mit sehr geringem preispolitischen Spielraum, aber sehr hohem Marktpotential sehen heute bereits Vorteile in der Anwendung von Data Mining und bringen dementsprechend diese Technologie mit einem durchschnittliche Gesamterfolg von nur 2,8 zum Einsatz.
- **Nutzer-Segment B:** Größere Unternehmen mit mäßigem bis hohem preispolitischen Spielraum und maximal mäßigem Marktwachstum erkennen Chancen in der Data

Mining Technologie und verwenden überwiegend diese Technik bereits heute mit einem durchschnittliche Gesamterfolg von 3,8.

- **Nutzer-Segment C:** Unternehmen, die auf Märkten mit mäßigem bis hohem preispolitischen Spielraum und hohem bis sehr hohem Marktwachstum agieren, verwenden fast ausnahmslos die neue Technologie mit einem durchschnittliche Gesamterfolg von 3,75.

Man erkennt, dass die Unternehmen auf Märkten mit höherem preispolitischen Spielraum (Segmente B und C) den Erfolg des Data Mining Einsatzes höher einschätzen als diejenigen, die sich auf Märkten mit sehr geringem marketing-politischen Spielraum bei der Preisgestaltung befinden (Segment A). Dass in diesen Märkten vor allem auch die Nicht-Nutzer der Data Mining Technologie zu finden sind, lässt zudem die Vermutung aufkommen, dass diese Märkte von den Marktteilnehmern als eher ungeeignet für die Anwendung des Data Mining betrachtet werden. Des Weiteren lässt diese Analyse den Schluss zu, dass darüber hinaus diejenigen Unternehmen, die es entgegen dieser Basismeinung dennoch mit Data Mining versuchten, auf gravierende Schwierigkeiten bei der Umsetzung dieser neuen Technologie gestoßen sind und dass sich dementsprechend der Erfolg nicht in der Art eingestellt hat, wie dies erwartet wurde. Eine genaue Untersuchung dieser Zusammenhänge und insbesondere auch der Frage, ob die Märkte Ursache der Zurückhaltung beim Data Mining Einsatz oder Ursache des Misserfolges des Einsatzes sind, kann an dieser Stelle allerdings nicht erfolgen. Die Antwortung dieser Frage bedingt vielmehr die Existenz einer Kontrollgruppe mit gleichen Markt Voraussetzungen, was aber aufgrund der eingangs geschilderten Problematik der Neuartigkeit der Data Mining Technologie im Unternehmensumfeld derzeit noch an der schwachen Verbreitung dieser Technik in den Unternehmen scheitert.

V. Konfirmatorische Datenanalyse und Interpretation der Ergebnisse

Für die Ableitung eines Kausalmodells für den Erfolg von Data Mining Projekten wird zunächst ein Messmodell der oben vorgestellten potentiellen Erfolgsfaktoren des Data Mining formuliert. Die Berücksichtigung aller erhobenen Indikatoren zur Messung der potentiellen Erfolgsfaktoren im Rahmen des Kausalmodells erscheint aufgrund des vorliegenden Stichprobenumfangs nicht sinnvoll. Es wird daher angestrebt, ein kompaktes Modell des Data Mining Erfolgs abzuleiten und einer Kausalanalyse zu unterziehen.

1. Das exogene Messmodell der Erfolgsdeterminanten

Ausgehend von einer explorativen Faktorenanalyse der Handlungs- und Situationsvariablen sowie der Moderatorvariablen sollen zunächst die Indikatoren für das exogene Messmodell der Erfolgsfaktorenforschung ausgewählt werden (Lang, 1997, S. 209). Die Extraktion der Faktoren erfolgt im Rahmen von zwei getrennten Faktorenanalysen, um die Trennung zwischen den a-priori als Moderatorvariablen definierten und den übrigen Handlungs- und Situationsvariablen beizubehalten (Bornemeyer, 2002, S. 169).

In der explorativen Faktorenanalyse der Handlungs- und Situationsvariablen werden basierend auf dem kumulierten Varianzerklärungsanteil zunächst sieben Faktoren extrahiert, die gemeinsam 65,3% der Varianz in den Daten erklären. Das Kaiser-Meyer-Olkin-Kriterium (MSA) beträgt 0,657, d.h., die Daten sind zur Durchführung einer Faktorenanalyse geeignet. Allerdings ist zu beachten, dass eine Reihe von Indikatoren aufgrund eines zu niedrigen MSA-Wertes aus der Analyse ausgeschlossen werden. Hierbei handelt es sich um die Indikatoren zur *Wettbewerbsituation des Unternehmens*, um die Wichtigkeit der *Einbeziehung von Statistikern im Data Mining Team* sowie um die *Verwendung von OLAP Techniken*. Alle Variablen weisen hier Werte deutlich unter 0,4 vor, so dass auf eine weiteren Verwendung im Rahmen der Konstruktion eines Messmodells verzichtet werden soll. Kritisch sind die MSA-Werte der Indikatoren zu den Konstrukte *Commitment* und *Externe Ressourcen*. Eine weitere Überprüfung und ggf. erneute Entscheidung bzgl. der Verwendung der Indikatoren in einem Messmodell zur Erfolgsfaktorenforschung wird im Rahmen der weiteren Betrachtung erfolgen. Tabelle 2 zeigt die oblimin-rotierten Faktorladungen auf Basis der verbleibenden Indikatoren.

Zur Interpretation dieser Faktoren werden die gekennzeichneten Indikatoren mit einer Faktorladung größer 0,4 herangezogen (Tabachnik und Fidell, 1996, S. 677). Indikato-

ren, die auf mehr als einen Faktor laden, werden bei der Interpretation nicht berücksichtigt, da für das abzuleitende Messmodell in der Kausalanalyse eine eindeutige Zuordnung der Indikatoren zu den Faktoren respektive Konstrukten angestrebt wird.

Tabelle 2: Rotierte Faktorladungen der Handlungs- und Situationsvariablen

	Faktor							MSA
	1	2	3	4	5	6	7	
Relative Unternehmensgröße	-0,302	-0,379	0,143	0,167	-0,350	0,214	-0,209	0,771
Marktwachstum	-0,153	0,067	-0,062	-0,148	0,014	0,007	0,691	0,683
Marktpotential	0,013	0,057	-0,034	0,041	-0,007	0,040	0,832	0,629
Innovation GL	0,614	-0,026	-0,307	-0,113	-0,006	-0,201	0,160	0,729
Aufgeschlossenheit GL	0,735	-0,135	0,039	0,077	-0,131	-0,028	0,115	0,658
Kommunikation	0,349	-0,140	-0,064	-0,186	0,143	-0,182	0,116	0,675
Planungshierarchie	0,676	0,086	0,041	-0,047	0,001	-0,005	-0,111	0,735
Projekt Paten	0,133	-0,927	0,223	-0,214	0,161	-0,108	-0,117	0,457
Data Mining Paten	-0,086	-0,585	-0,303	-0,041	-0,060	0,045	-0,059	0,556
Änderung Work Flow	-0,153	0,151	0,067	0,439	0,155	-0,020	-0,195	0,721
Integration Work Flow	-0,046	0,120	-0,017	0,903	-0,029	-0,031	-0,109	0,672
Endanwender Integration	-0,187	0,022	0,343	-0,261	-0,217	-0,340	0,156	0,580
Festes Budget	0,087	-0,013	0,746	0,026	0,057	-0,030	-0,114	0,689
Erfolgskontrolle	-0,161	0,109	0,483	-0,018	0,298	0,059	-0,041	0,718
Integration in IT	-0,146	-0,022	0,019	0,163	0,556	0,061	0,010	0,800
Datenqualität	-0,380	0,099	0,206	-0,103	0,633	-0,078	-0,096	0,707
Data Warehouse	0,105	-0,068	0,084	-0,030	0,645	0,221	0,034	0,614
DM/OLAP	-0,195	0,104	-0,104	-0,094	0,107	0,550	-0,146	0,545
Data Mining Server	0,114	-0,243	0,413	0,262	0,097	0,632	0,190	0,574
Neue Mitarbeiter	-0,078	0,018	-0,003	-0,293	-0,388	0,260	-0,052	0,565
Zukauf externer Daten	0,220	0,111	0,013	-0,061	-0,044	0,162	-0,047	0,521
Externe Berater	0,156	0,167	0,073	-0,013	0,051	-0,011	0,141	0,482
Erklärte Varianz	19,3%	11,9%	8,7%	8,3%	6,6%	6,0%	4,8%	

Der erste Faktor umfasst die verschiedenen Indikatoren zur Unternehmenskultur und soll dementsprechend auch als **Unternehmenskultur** bezeichnet werden. Zu beachten ist allerdings, dass der Indikator *Interne Kommunikation* aufgrund seiner geringen Ladung eher zu vernachlässigen ist. Faktor zwei steht für das **Commitment der Unternehmensleitung**, Faktor drei wird vor allem durch die Indikatoren zur **organisatorischen Absicherung** erklärt. Auf den vierten Faktor laden die Variablen, die im Bezug zum Work Flow stehen, so dass dieser Faktor als **Change-Management** bezeichnet wird. Die *Integration der Endanwender*, die gemäß oben dargestellten Überlegungen ebenfalls Rückschlüsse auf die Qualität eines funktionierten Change-Management zu-

lässt, muss aufgrund der nicht eindeutig zuzuordnenden Ladungen aus der Analyse ausgeschlossen werden. Die auf den fünften und sechsten Faktor hoch ladenden Indikatoren beziehen sich auf die informationstechnologischen Aspekte des Data Mining. Faktor fünf steht dabei eher für die Hard- und Software Aspekte der IT-Landschaft, während Faktor sechs die Integration des Data Mining in die bisherigen Überlegungen des Unternehmens widerspiegelt. Zum Ausdruck wird dies dadurch gebracht, dass bei Faktor sechs vor allem das *Zusammenspiel von OLAP und Data Mining* sowie die *Existenz eines Data Mining Servers* und eingeschränkt auch noch die *Integration von Endanwendern* eine Rolle spielen. Somit deckt der sechste Faktor die betriebswirtschaftlich orientierte Integrationsbereitschaft der Informationstechnologie ab, sozusagen die Denkhaltung der IT. Bei genauer Betrachtung fällt allerdings auf, dass sowohl die Verwendung des Indikators *Integration von Endanwendern* als auch die der *Existenz eines Data Mining Servers* aufgrund der nicht eindeutig zuzuordnenden Faktorladungen im Hinblick auf die Konstruktion eines Messmodells problematisch erscheint. Da auch die oben dargestellte Problematik der Vielschichtigkeit des Konstruktes Informationstechnologie und die in der Literatur eher ausgewiesene geringere Wichtigkeit gegen eine Aufspaltung des Konstruktes Informationstechnologie sprechen, sollen die Faktoren fünf und sechs zum Faktorkomplex **Informationstechnologie** zusammengefasst werden. Faktor sieben beschreibt zuletzt die **Marktsituation des Unternehmens** in seinem Umfeld.

Tabelle 3: Rotierte Faktorladungen der Moderatorvariablen

	Faktor 1	MSA
Aufgeschlossenheit FA	0,689	0,617
Umsetzung in FA	0,876	0,592
Schulung Mitarbeiter	0,500	0,740
Erklärte Varianz	64,3%	

Im Rahmen der zweiten Faktorenanalyse, die die Untersuchung der Indikatoren zur Integration der Ergebnisse im Unternehmen beinhaltet, ergibt sich die in Tabelle 3 dargestellte Situation. Das Kaiser-Meyer-Olkin Kriterium für diese Daten beträgt 0,63 und kann damit als zufrieden stellend bezeichnet werden. Des Weiteren muss keine der betrachteten Indikatoren aufgrund ungeeigneter MSA-Werte aus der Analyse ausgeschlossen werden.

Die Ergebnisse der vorgeschalteten explorativen Faktorenanalysen bilden die Basis des exogenen Messmodells für das abzuleitende Kausalmodell. Dieses wird im Folgenden einer konfirmatorischen Faktorenanalyse unterzogen. Während die Bedeutung der explorativen Faktorenanalyse zunächst in der Erkennung noch nicht bekannter Faktorstrukturen zu sehen ist, soll mittels konfirmatorischer Faktorenanalyse die ermittelte Faktorstruktur überprüft werden (Leeflang et al., 2000, S. 450). Die konfirmatorische Faktorenanalyse liefert zudem Anpassungsmaße zur Beurteilung des Messmodells sowie einzelner Modellkomponenten und bietet die Möglichkeit, die Parameter auf Signifikanz zu testen (Homburg und Pflesser, 2000a, S. 416).

Für diese konfirmatorische Faktorenanalyse als Spezialfall der Kausalanalyse gilt es zunächst, ein geeignetes Schätzverfahren zu wählen. Im vorliegenden Fall erscheint einerseits die Anwendung der Unweighted Least Squares Schätzung (ULS-Schätzung) geboten, da die zugrunde liegenden Daten nicht (multivariat) normalverteilt sind und die ULS-Schätzung unabhängig von der Verteilungsstruktur anwendbar ist. Zudem stellt dieses Schätzverfahren vergleichsweise geringe Anforderungen an den Stichprobenumfang (Homburg und Sütterlin, 1990, S. 186). Auf die Anwendung einer Maximum Likelihood Schätzung (ML-Schätzung), die nach einer Studie von Homburg und Baumgartner (1995, S. 1101) das international am häufigsten verwendete Verfahren darstellt (während die ULS-Schätzung lediglich in Deutschland einen hohen Stellenwert aufweist), soll im Übrigen aufgrund der unbekanntenen Verteilungsstruktur der Daten verzichtet werden. Zwar wird die ML-Schätzung als das klassische Schätzverfahren der Kausalanalyse bezeichnet (Bollen, 1989, S. 107), jedoch basiert sie auf der Annahme der Normalverteilung der Indikatorvariablen, die hier nicht zu rechtfertigen ist.

Zunächst wird eine konfirmatorische Faktorenanalyse des Messmodells durchgeführt, das sich direkt aus den Ergebnissen der explorativen Faktorenanalyse ergibt. Dazu werden für die extrahierten Faktoren jeweils alle Indikatorvariablen mit einer Ladung größer als 0,40 verwendet, die nicht auf mehr als einen Faktor hoch laden. Diese Indikatoren sind in Tabelle 2 durch Fettdruck hervorgehoben, während alle der in Tabelle 3 angegebenen Indikatoren berücksichtigt werden. Die Anzahl der Indikatoren je Faktor weicht in einzelnen Fällen von der empfohlenen Anzahl von drei Indikatoren ab (Hatcher, 1998, S. 260), die Durchführung und die Ergebnisse der folgenden Analyse weisen jedoch nicht auf Probleme bei der Identifikation oder der Konvergenz hin, die bei Verwendung einer geringeren Anzahl von Indikatoren je Faktor auftreten könnten. Ausgewählte globale Anpassungsmaße dieses Ausgangsmodells sowie der im Folgenden vor-

genommenen Modifikation sind in Tabelle 4 zusammengestellt. Zudem sind in der Literatur genannte Anspruchsniveaus für die gewählten Anpassungsmaße angegeben (Hatcher, 1998, S. 393 oder Homburg und Pflesser, 2000b, S. 651).

Tabelle 4: Ausgewählte globale Anpassungsmaße alternativer Modelle

	Ausgangsmodell	Alternativmodell	Anspruchsniveau
GFI	0,925	0,968	$\geq 0,90$
AGFI	0,892	0,941	$\geq 0,80$
RMR	0,084	0,062	$\leq 0,10$
χ^2/df	1,815	1,532	$\leq 2,50$
RMSEA	0,089	0,072	$\leq 0,05$
CFI	0,989	1,000	$\geq 0,90$
NFI	0,842	0,928	$\geq 0,90$

Im betrachteten Ausgangsmodell, das zunächst bei Betrachtung der Globalmaße als durchaus gut bezeichnet werden kann, können fünf Indikatoren nicht adäquat berücksichtigt werden. Es handelt sich dabei um die Variablen *Planungshierarchie*, *Data Warehouse*, *Zusammenspiel von Data Mining und Data Warehouse*, die *Existenz eines eigenen Data Mining Servers* sowie um die *Schulung der Mitarbeiter*. Alle Indikatoren weisen bei einer Gesamtbetrachtung zu geringe Faktorladungen auf, dass der Ausschluss dieser Variablen zur Verbesserung der Güte des Gesamtmessmodells (im Sinne der Validität) angezeigt ist. Im nun modifizierten Modell sind alle standardisierten Faktorladungen größer 0,5 und hoch signifikant ($\alpha < 0,01$), so dass mit Hilfe der Globalmaße im Folgenden eine Überprüfung der Anpassungsgüte des Modells erfolgen kann.

Bei den in Tabelle 4 angegebenen Gütemaßen handelt es sich zunächst ausschließlich um globale Anpassungsmaße, mittels derer das Modell insgesamt beurteilt werden kann. Zu unterscheiden sind hier Stand-Alone und inkrementelle Anpassungsmaße. Die Stand-Alone Anpassungsmaße können in deskriptive und inferenzstatistische Anpassungsmaße unterschieden werden. Der Goodness-of-Fit Index (GFI) als deskriptives Anpassungsmaß gibt den Anteil der Varianz und Kovarianz in der Stichprobe an, der durch die reproduzierte Kovarianzmatrix abgebildet wird (Bollen, 1989, S. 276). Der GFI berücksichtigt die Freiheitsgrade nicht, während der Adjusted Goodness-of-Fit Index (AGFI) diese einbezieht. Maße unter Einbeziehung der Freiheitsgrade, wie der AGFI oder das Verhältnis des Chi²-Wertes zu den Freiheitsgraden, führen dazu, dass Modelle mit weniger Parametern bei sonst gleicher Anpassung besser bewertet werden. Das Root Mean Residual (RMR) betrachtet die Residuen zwischen den Elementen der Kovarianzmatrix auf Basis der Stichprobe und den Elementen der vom Modell reproduzierten Kovari-

anzmatrix (Bollen, 1989, S. 257). Freiheitsgrade werden bei diesem Maß nicht berücksichtigt. Für die vorliegenden Modelle werden die Anspruchsniveaus für den GFI und den AGFI deutlich übertroffen. Auch das Verhältnis des Chi²-Wertes zu den Freiheitsgraden und das RMR erreichen das Anspruchsniveau für beide Modelle.

Inferenzstatistische Stand-Alone Anpassungsmaße beurteilen das vorliegende Modell ausgehend von einem statistischen Signifikanztest. Das bekannteste dieser Maße ist der Chi²-Anpassungstest mit der Nullhypothese, dass das spezifizierete Modell richtig ist (Homburg und Baumgartner, 1998, S. 353). Die Angemessenheit dieses Tests wird jedoch in der Literatur generell in Frage gestellt, so dass dieses Anpassungsmaß nicht weiter betrachtet wird. Als besser geeignet kann der Root Mean Squared Error of Approximation (RMSEA) bezeichnet werden. Der RMSEA ermöglicht es zu testen, ob das Modell die Realität gut approximiert (Homburg und Pflesser, 2000a, S. 427). Das Anspruchsniveau für den RMSEA wird in der Literatur mit 0,05, in einigen Fällen aber auch mit 0,08 angegeben. Für das Alternativmodell wird dieses Anspruchsniveau erfüllt, während das Ausgangsmodell dieses Niveau knapp nicht erfüllt.

Inkrementelle Anpassungsmaße beurteilen das vorliegende Modell, anders als die Stand-Alone Anpassungsmaße, in Relation zu einem Basismodell (Nullmodell), das z.B. die Unabhängigkeit aller verwendeten Indikatoren unterstellt. Zu diesen Maßen zählen der Normed Fit Index (NFI) sowie der Comparative Fit Index (CFI), der im Unterschied zum NFI die Freiheitsgrade berücksichtigt. Die Indizes lassen sich unter Verwendung des Verhältnisses der Chi²-Werte des vorliegenden und des Basismodells bestimmen. Werte nahe bei Eins deuten auf eine gute Modellanpassung des vorliegenden Modells hin. Tabelle 4 zeigt, dass das Anspruchsniveau für die vorliegenden Messmodelle sehr gut erfüllt werden kann. Insgesamt kann somit das modifizierte Messmodell gemäß der aufgeführten globalen Anpassungsmaße als sehr gut bezeichnet werden.

Im Folgenden werden lokale Anpassungsmaße für dieses Modell betrachtet, d.h., die Reliabilität und die Validität der Konstrukte bzw. Faktoren und Indikatoren werden beurteilt. Die Reliabilität beschreibt dabei „the degree to which measures are free from random error and thus reliability coefficients estimate the amount of systematic variance in a measure“ (Peter und Churchill, 1986, S. 4). Validität ist gegeben, "when the differences in observed scores reflect true differences on the characteristic one is attempting to measure and nothing else" (Churchill, 1979, S. 65). Tabelle 5 fasst die standardisier-

ten Faktorladungen, die Indikator- sowie die Faktorreliabilitäten und die durchschnittlich erfasste Varianz zusammen.

Tabelle 5: Reliabilität der Indikatoren und Konstrukte

Faktor	Indikator	Stand. Faktorladung	Indikatorreliabilität	Faktorreliabilität	Durchschn. erkl. Varianz
Markt (F1)	Marktwachstum	0,711	0,506	0,741	0,590
	Marktpotential	0,821	0,674		
Unternehmenskultur (F2)	Innovation GL	0,99	0,980	0,800	0,679
	Aufgeschlossenheit GL	0,615	0,378		
Commitment (F3)	Projekt Paten	0,567	0,321	0,675	0,519
	Data Mining Paten	0,847	0,717		
Change-Management (F4)	Änderung Work Flow	0,824	0,679	0,745	0,594
	Integration Work Flow	0,714	0,510		
Organisatorische Absicherung (F5)	Festes Budget	0,524	0,275	0,650	0,500
	Erfolgskontrolle	0,846	0,716		
Informations-Technologie (F6)	Integration in IT	0,529	0,280	0,620	0,460
	Datenqualität	0,800	0,640		
Integration der Ergebnisse (F7)	Aufgeschlossenheit FA	0,625	0,391	0,786	0,658
	Umsetzung in FA	0,962	0,925		

Die Indikatorreliabilitäten, hier gemessen durch die quadrierten Faktorladungen, geben den Anteil der Varianz des Indikators wieder, der durch den zugrunde liegenden Faktor erklärt wird (Homburg und Giering, 1998, S. 124). Die Varianzerklärungsanteile liegen entsprechend der Höhe der Faktorladungen zwischen 27,5% für die Erklärung der Varianz des Indikators *Festes jährliches Budget* durch den Faktor **Organisatorische Absicherung** und 98% für die Erklärung der Varianz des Indikators *Innovationsfreudigkeit des Unternehmens* durch den Faktor **Unternehmenskultur**. Die Werte liegen weitgehend in der Nähe oder über dem in der Literatur definierten Anspruchsniveau von 0,4 (Homburg und Pflesser, 2000a, S. 430).

Die Faktorreliabilität und die durchschnittlich erfasste Varianz eines Faktors geben an, wie gut der Faktor durch die ihm zugeordneten Indikatoren insgesamt gemessen wird (Homburg und Giering, 1998, S. 124). Für die Faktorreliabilität wird ein minimal akzeptabler Wert von 0,6 bis 0,7 in der Literatur angegeben (Hatcher, 1998, S. 329). Für das vorliegende Messmodell liegt die Faktorreliabilität für alle Faktoren über 0,6, so dass das Ergebnis als zufrieden stellend beurteilt werden kann.

Das Anspruchsniveau für die durchschnittlich erfasste Varianz beträgt 0,5, da Werte unter 0,5 bedeuten, dass die Varianz aufgrund von Messfehlern größer ist als die durch den Faktor erfasste Varianz (Fornell und Larcker, 1981, S. 46). Dieses Kriterium wird im vorliegenden Modell für alle Faktoren bis auf F6 (leicht unterschritten) erfüllt. Die Faktorreliabilität nimmt jedoch auch für diese beiden Faktoren einen zufrieden stellenden Wert an.

Tabelle 6: Quadrierte Korrelationen der exogenen Faktoren

	F1	F2	F3	F4	F5	F6	F7
F1	1,000						
F2	0,125	1,000					
F3	0,055	0,010	1,000				
F4	0,174	0,198	0,063	1,000			
F5	0,026	0,147	0,049	0,084	1,000		
F6	0,023	0,295	0,031	0,212	0,585	1,000	
F7	0,000	0,015	0,021	0,183	0,129	0,094	1,000

Bezüglich der Validität lassen sich Hinweise auf die Konvergenzvalidität der Indikatoren aus den t-Werten ableiten. Konvergenzvalidität beschreibt dabei "the degree to which two or more attempts to measure the same concept are in agreement" (Bagozzi und Phillips, 1982, S. 468). Sind die Faktorladungen für alle Indikatoren, die das gleiche Konstrukt messen (wie im vorliegenden Fall) signifikant, so kann dies als Anzeichen von Konvergenzvalidität betrachtet werden (Hatcher, 1998, S. 332). Die Diskriminanzvalidität der Indikatoren, die "the degree to which measures for distinct concepts differ" (Bagozzi und Phillips, 1982, S. 469) beschreibt, kann z.B. anhand des Fornell-Larcker-Kriteriums überprüft werden (Anderson und Gerbing, 1988, S. 416). Das Fornell-Larcker-Kriterium fordert, dass für jedes Faktorenpaar in einem Messmodell die durchschnittlich erfassten Varianzen der Faktoren (siehe Tabelle 5) jeweils größer sind als die quadrierten Korrelationen (siehe Tabelle 6) zwischen den entsprechenden Faktoren (Homburg und Pflesser, 2000a, S. 429). Einzig beim Faktorenpaar Informationstechnologie (F6), Organisatorische Absicherung (F5) wird das Kriterium knapp nicht erfüllt, so dass auch von Seiten der Diskriminanzvalidität das vorliegende Messmodell als adäquat bezeichnet werden kann.

Insgesamt weisen die in Tabelle 4 und 5 zusammengestellten Maße zur Beurteilung der Ergebnisse der konfirmatorischen Faktorenanalyse auf eine generelle Eignung des abgeleiteten Messmodells hin, so dass dieses in ein Kausalmodell überführt werden kann.

2. Das endogene Messmodell der Erfolgsgrößen

Die Ableitung eines endogenen Messmodells der Erfolgsgrößen verläuft analog zur Ableitung des exogenen Messmodells und soll deshalb nur noch in Kürze dargestellt werden. Die explorative Faktorenanalyse der Erfolgsvariablen führt zur Extraktion zweier Faktoren, die gemeinsam 68,7% der Varianz in den Daten erklären. Das Kaiser-Meyer-Olkin-Kriterium (MSA) beträgt 0,839, d.h., die Daten sind zur Durchführung einer Faktorenanalyse sehr gut geeignet. Keiner der Indikatoren musste aufgrund zu geringer individueller MSA-Werte aus der Analyse ausgeschlossen werden. Bzgl. der varimaxrotierten Faktorladungen auf Basis aller Indikatoren sei auf Tabelle 7 verwiesen.

Zur Interpretation der Faktoren werden ebenfalls die Indikatoren mit einer Faktorladung größer 0,4 herangezogen, die eindeutig auf einen Faktor laden. Dementsprechend werden die *Kostenreduktion* und die *Erhöhung der Kundenbindung und -zufriedenheit* nicht weiter berücksichtigt. Der erste Faktor des Modells umfasst schließlich die verschiedenen Indikatoren zu finanzorientierten Zielgrößen und soll dementsprechend auch als **Finanzorientierter Erfolg** bezeichnet werden. Faktor zwei steht für Vorteile, die sich direkt am Markt gegenüber den Konkurrenten ergeben und soll dementsprechend als **Wettbewerbsvorteil** bezeichnet werden.

Tabelle 7: Rotierte Faktorladungen der Erfolgsindikatoren

	Faktor 1	Faktor 2	MSA
Deckungsbeitrag	0,737	0,344	0,839
Deckungsbeitrag pro Kunde	0,818	0,189	0,790
Umsatz	0,732	0,319	0,885
Kosten	0,454	0,535	0,838
Prozessoptimierung	0,218	0,851	0,795
Marktdurchdringung	0,230	0,680	0,791
Wettbewerbsposition	0,393	0,640	0,854
Kundenbindung und -zufriedenheit	0,523	0,457	0,933
Erklärte Varianz	55,8%	12,9%	

Die Ergebnisse dieser vorgeschalteten explorativen Faktorenanalyse bilden auch hier die Basis des endogenen Messmodells für das abzuleitende Kausalmodell. Dieses wird analog zur oben beschriebenen Vorgehensweise einer konfirmatorischen Faktorenanalyse unterzogen, wobei als Schätzverfahren wiederum die ULS-Schätzung verwendet werden soll. Des Weiteren werden nur solche Indikatoren berücksichtigt, die nicht auf mehr als einen Faktor hoch laden. Ausgewählte globale Anpassungsmaße dieses Modells sind

ebenfalls in Tabelle 8 zusammengestellt. Man erkennt deutlich, dass das Modell als Ganzes in allen Bereichen als sehr gut bezeichnet werden kann.

Tabelle 8: Ausgewählte globale Anpassungsmaße des endogenen Messmodells

	Ausgangsmodell	Anspruchsniveau
GFI	0,993	$\geq 0,90$
AGFI	0,981	$\geq 0,80$
RMR	0,049	$\leq 0,10$
χ^2/df	2,701	$\leq 2,50$
RMSEA	0,128	$\leq 0,05$
CFI	1,000	$\geq 0,90$
NFI	0,988	$\geq 0,90$

Darüber hinaus kann auch die Beurteilung der Reliabilität und Validität der Indikatoren bzw. Faktoren (Tabelle 9) als sehr gut bezeichnet werden. Da des Weiteren die quadrierte Korrelation zwischen den beiden Faktoren den Wert 0,4624 annimmt und somit kleiner als die durchschnittlich erklärten Varianzen der beiden Faktoren ist, sind die Konstrukte auch diskriminanzvalide, womit das endogene Messmodell insgesamt als geeignet zur Verwendung im Rahmen eines kausalanalytischen Erfolgsfaktorenmodells bezeichnet werden kann.

Tabelle 9: Reliabilität der endogenen Indikatoren und Konstrukte

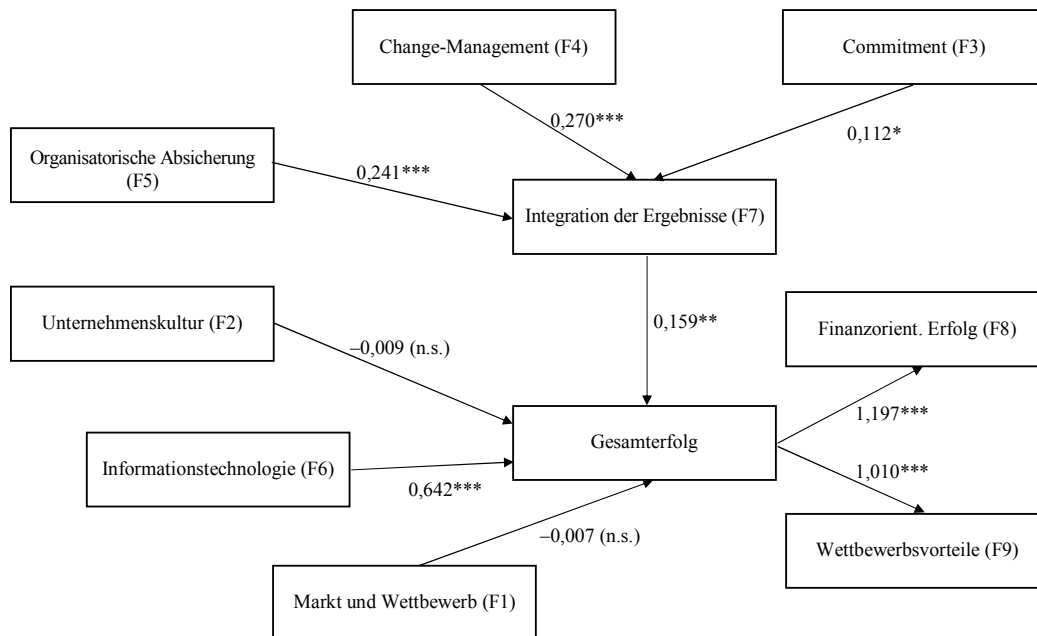
Faktor	Indikator	Stand. Faktorladung	Indikatorreliabilität	Faktorreliabilität	Durchschn. erkl. Varianz
Finanzorientierte Erfolge (F8)	Deckungsbeitrag (DB)	0,848	0,719	0,851	0,655
	DB pro Kunde	0,773	0,598		
	Umsatz	0,806	0,650		
Wettbewerbsorientierte Erfolge (F9)	Prozessoptimierung	0,773	0,598	0,813	0,592
	Marktdurchdringung	0,736	0,542		
	Wettbewerbsposition	0,798	0,637		

3. Das Strukturgleichungsmodell

Die zugrunde liegenden Strukturen basieren auf dem oben abgeleiteten Hypothesensystem. Allerdings ist zu beachten, dass aus Gründen der Komplexitätsminderung des Modells keine direkte Verbindung der endogenen Erfolgsgrößen und der exogenen Erfolgsdeterminanten erfolgt. Vielmehr wird dem endogenen Messmodell ein hierarchisch übergeordnetes Konstrukt des *Gesamterfolgs*, gemessen mit Hilfe des Indikators Gesamterfolg, vorangestellt. Eine entsprechende Überprüfung auf Basis explorativer

und konfirmatorischer Faktorenanalysen und auf Basis inhaltlicher Überlegungen bestätigt die Angemessenheit dieser Vorgehensweise. Die Verknüpfung der beiden Messmodelle erfolgt schließlich mit Hilfe dieses Konstruktes.

Abbildung 28: Strukturmodell basierend auf dem Hypothesenkatalog



Das sich daraus ergebende Strukturmodell ist (der Übersichtlichkeit halber) ohne die enthaltenen Messmodelle in Abbildung 28 dargestellt. Zudem sind ausgewählte Gütemaße des als sehr gut zu bezeichneten Modells mit 164 Freiheitsgraden in Tabelle 10 angegeben. Man erkennt, dass das Modell bzgl. dieser globalen Gütemaße als sehr gut bezeichnet werden kann. Die standardisierten Pfadkoeffizienten selbst resultieren wiederum aus einer ULS-Schätzung, die bereits nach 60 Iterationen konvergiert. Hoch signifikante Pfadkoeffizienten ($\alpha < 0,01$) sind mit ***, signifikante Ladungen ($\alpha < 0,05$) mit ** und schwach signifikante Pfadkoeffizienten ($\alpha < 0,10$) mit * gekennzeichnet. Alle anderen Koeffizienten sind nicht signifikant (n.s., $\alpha > 0,10$).

Tabelle 10: Ausgewählte globale Anpassungsmaße des Kausalmodells

	Ausgangsmodell	Anspruchsniveau
GFI	0,955	$\geq 0,90$
AGFI	0,937	$\geq 0,80$
RMR	0,074	$\leq 0,10$
χ^2/df	1,259	$\leq 2,50$
RMSEA	0,048	$\leq 0,05$
CFI	0,999	$\geq 0,90$
NFI	0,929	$\geq 0,90$

Bei Betrachtung des Modells erkennt man, dass das handlungsorientierte endogene Konstrukt *Unternehmenskultur (F2)* sowie das situationsorientierte exogene Konstrukt *Markt- und Wettbewerb (F1)* keinen signifikanten Einfluss auf den Erfolg eines Data Mining Projekt in den betrachteten Unternehmen haben. Beim Konstrukt F1 ist dieser nicht signifikante (direkte) Effekt der Markt- und Wettbewerbssituation aufgrund der oben geschilderten Problematik einer fehlenden Kontrollgruppe und der Schwierigkeit bei der Beurteilung des Erfolges im Vergleich zum Markt durchaus nachvollziehbar. Das Ergebnis für den Faktor F2 allerdings ist eher überraschend, zudem in der Literatur immer wieder auf die Wichtigkeit der Unternehmenskultur für den Erfolg solcher Projekte hingewiesen wird. In diesem Zusammenhang drängt sich die Frage auf, inwieweit die generelle Denkhaltung eines Unternehmens, die Unternehmenskultur, und die tatsächliche operative Umsetzung dieser Denkhaltung, z.B. durch Projektpatenschaften oder das Vorhandensein eines Change-Managements, differieren. Denn es ist durchaus denkbar, dass auch Unternehmen, die keine innovative und aufgeschlossene Unternehmensleitung vorzuweisen haben, aufgrund betriebswirtschaftlicher Überlegungen willens und in der Lage sind, die organisatorischen und mental-kulturellen Rahmenbedingungen zu schaffen, die den Erfolg eines solchen Projektes begünstigen. Nicht die Denkhaltung, sondern die tatsächliche Ausgestaltung ist wichtig, was eindrucksvoll durch die Resultate dieser Kausalanalyse belegt werden kann.

Hinsichtlich der lokalen Anpassungsmaße bzgl. des Messmodells liegen die Indikatorreliabilitäten wie bereits bei der isolierten Betrachtung der Messmodelle in der überwiegenden Zahl der Fälle über dem Anspruchsniveau von 0,4. Die Faktorreliabilitäten übertreffen für alle Faktoren den Wert 0,6 und mit zwei Ausnahmen (F3 und F6) auch das höhere Anspruchsniveau 0,7. Bzgl. der durchschnittlich erfassten Varianz wird das Kriterium ebenfalls von zwei Faktoren F3 und F6 knapp nicht erfüllt. Wird zur Beurteilung der Angemessenheit des Modells zusätzlich noch das Strukturmodell alleine betrachtet, so kann die quadrierte multiple Korrelation (qmk) der Konstrukte zur Bewertung herangezogen werden (Bornemeyer, 2002, S. 182). Diese Korrelationen ähneln dem Bestimmtheitskoeffizienten der multiplen linearen Regression und beschreiben den Anteil der Varianz eines Konstruktes, der durch die anderen Konstrukte erklärt werden kann. Im vorliegenden Strukturmodell variieren die Werte der qmk der endogenen Messkonstrukte zwischen 0,501 für das Konstrukt *Gesamterfolg* und 0,962 für das Konstrukt *Finanzorientierter Erfolg*. Lediglich das Moderatorikonstrukt *Integration der Ergebnisse*, das im Rahmen dieses Kausalmodells auch als endogen behandelt werden muss, aber

nicht das Hauptkenntnisziel dieser Studie darstellt, weist bei der quadrierten multiplen Korrelation einen geringen Wert von 0,226 auf. Das Modell kann somit insgesamt als gut bis sehr gut bezeichnet werden. Die Reduktion des Modells auf die signifikanten Einflussfaktoren, d.h. nach Streichung der Faktoren Markt- und Wettbewerb sowie Unternehmenskultur, ergibt ein ähnliches Bild bei Betrachtung der globalen und lokalen Anpassungsmaße. Auch die Pfadkoeffizienten sind vergleichbar, so dass auch vor diesem Standpunkt von einem guten und stabilen Modell gesprochen werden kann.

Bei inhaltlicher Betrachtung des Strukturmodells ergibt sich Folgendes: Die *Organisatorische Absicherung*, das *Top-Management Commitment*, das *Change-Management*, die Ausgestaltung der *Informationstechnologie* sowie die *Integration der Ergebnisse* in den Fachabteilungen eines Unternehmen haben deutlich signifikante, direkte oder indirekte Einflüsse auf den Erfolg von Data Mining Projekten. Damit können die im Vorfeld aufgestellten Hypothesen H₂ bis H₆ bzgl. dieser Erfolgsfaktoren unterstützt werden. Das unternehmerische Umfeld in Form der *Markt- und Wettbewerbssituation* zeigt, ebenfalls wie in Hypothese H₈ erwartet, keine signifikanten Einflüsse auf den Erfolg von Data Mining Projekten. Dies kann dahingehend interpretiert werden, dass sowohl Unternehmen, die sich auf expandierenden Märkten als auch solche Unternehmen, die auf eher schrumpfenden bis stagnierenden Märkte zugehen sind, Erfolge mit Data Mining haben können. Bzgl. des Einflusses der *Unternehmenskultur* auf den Data Mining (H₁) Erfolg gilt Vergleichbares. Nur die Hypothese H₂ des Einflusses *Externer Ressourcen* konnte im Rahmen der vorliegenden Studie nicht überprüft werden, da die verwendeten Indikatoren der Reliabilitäts- und Validitätsprüfung nicht stand hielten.

F. Schlussbetrachtung

In der vorliegenden Studie konnte gezeigt werden, dass die hier ausgewählten unternehmensinternen Faktoren Einfluss auf den Erfolg von Data Mining Projekten in deutschen Unternehmen ausüben. Speziell ergab sich, dass besonders in den Fällen, in denen die Unternehmensleitung durch Projektpatenschaften die Wichtigkeit der Projekte unterstreicht, ein Change-Management im Unternehmen die organisatorischen Rahmenbedingungen zur Integration des Data Mining in das Unternehmen geschaffen und den Work Flow entsprechend angepasst hat, die organisatorische Absicherung, hier vor al-

lem in finanzieller Sicht in Form fester Budgets, gegeben ist und die Informationstechnologie im Unternehmen eine reibungslose Integration des Data Mining in die IT-Landschaft ermöglicht und die zu verarbeitenden Daten entsprechend hoher Qualität sind, Data Mining Projekte zur Erreichung sowohl finanzorientierter als auch wettbewerbsorientierter Ziele beitragen können. Diese Ergebnisse waren aufgrund der theoretischen Vorüberlegungen auch erwartet worden.

Ebenso mit den theoretischen Überlegungen konform geht die Erkenntnis, dass das Unternehmensumfeld und seine Wettbewerbssituation (zumindest empirisch) keinen Einfluss auf den Erfolg von Data Mining Projekten haben. Hier ergeben sich allerdings Ansatzpunkte weiterer Forschungsbemühungen, da die Untersuchung dieses Zusammenhangs nur dann empirisch validiert werden kann, wenn eine Kontrollgruppe in die Untersuchung aufgenommen wird. Die Aufnahme einer solchen Gruppe, die bei ansonst identischen Ausprägungen im Gegensatz zur Untersuchungsgruppe keinen Erfolg mit der Anwendung von Data Mining hat, erscheint jedoch aufgrund der momentan noch recht jungen Technologie und der dadurch zu geringen Grundgesamtheit nicht möglich.

Als weiteres interessantes Ergebnis der Studie lässt sich die Tatsache werten, dass die Unternehmenskultur eines Unternehmens, d.h. die Innovationsfreudigkeit und Aufgeschlossenheit der Geschäftsleitung, keinen Einfluss auf den Erfolg solcher Projekte hat. Dies ist zunächst erstaunlich, jedoch bei genauer Betrachtung durchaus erklärbar. Während die Unternehmenskultur eher einer allgemeinen Denkweise entspricht, kann deren operative Umsetzung bei identischer Denkweise sehr unterschiedlich sein. So kann z.B. ein Unternehmen, dessen Unternehmensleitung eher als konservativ und wenig aufgeschlossen Neuen gegenüber bezeichnet werden kann, dennoch erfolgreich Data Mining anwenden, wenn ein modernes Change-Management oder das Commitment des Top-Management die organisatorischen Rahmenbedingungen schaffen (können). Es wird somit deutlich, dass nicht das Denken sondern das Handeln der Unternehmensleitung entscheidend für den Erfolg solcher und ähnlicher Projekte ist.

Letztlich lässt sich damit die Empfehlung ableiten, dass Unternehmen vor allem in den Bereichen Mensch (Commitment), Organisation (Change-Management, feste Budgets) und Informationstechnologie (Integration in IT-Landschaft, Datenqualität) adäquate Rahmenbedingungen schaffen müssen, um im Data Mining erfolgreich zu sein.

Anmerkungen

- ¹ Vgl. Wilde (2001a, S. 15); eine ausführliche Darstellung und Beschreibung dieses Prozesses findet sich auch in Hippner, Wilde (2001c, S. 21) oder Küsters (2001, S. 97).
- ² Es sei an dieser Stelle noch einmal betont, dass entsprechende Erklärungsansätze auch in diesem Zusammenhang denkbar sind, die Komplexität des Modells aber derart erhöhen, dass auf eine solche Modellierung verzichtet werden soll.
- ³ Bei Berücksichtigung exogen interner Erfolgsfaktoren, wie z.B. der Unternehmensgröße oder der Branche, ist eine Modellierung dieses Zusammenhang denkbar; aber auch hier würde sich die Komplexität des Modells derart erhöhen, dass auf eine solche Vorgehensweise verzichtet werden soll.

Anhang 1

Deskriptive Analyse der Nutzer und Nicht-Nutzer

Abbildung A1.1: Intensität des Wettbewerbssituation

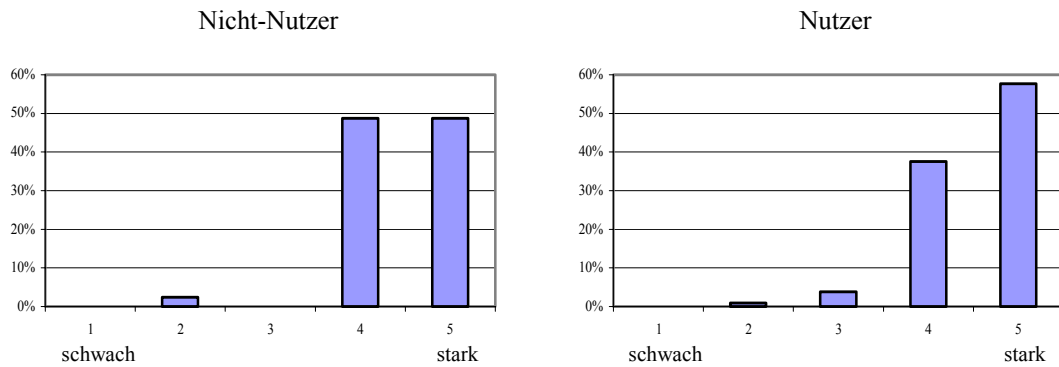


Abbildung A1.2: Anzahl der Wettbewerber

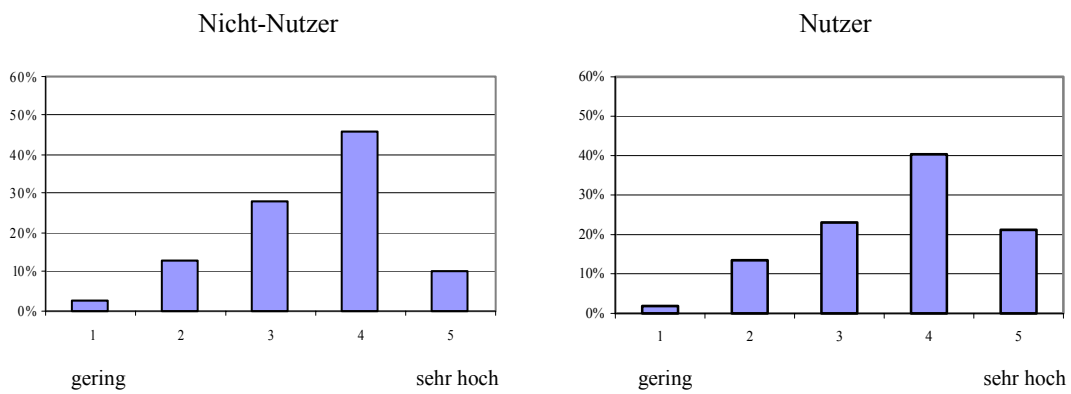


Abbildung A1.3: Marktwachstum




Abbildung A1.4: Marktpotential




Abbildung A1.5: Relative Größe des Unternehmens




Abbildung A1.6: Preispolitischer Spielraum




Abbildung A1.7: Unternehmensstil

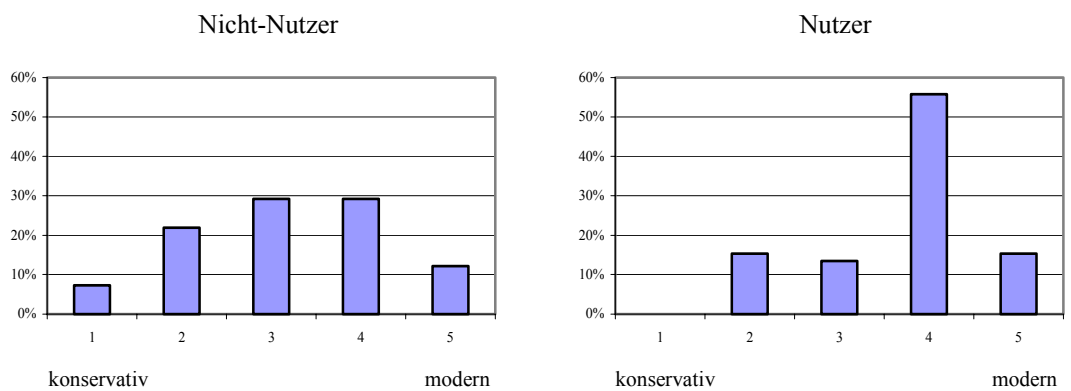


Abbildung A1.8: Verhalten der Geschäftsleitung einem Wandel gegenüber

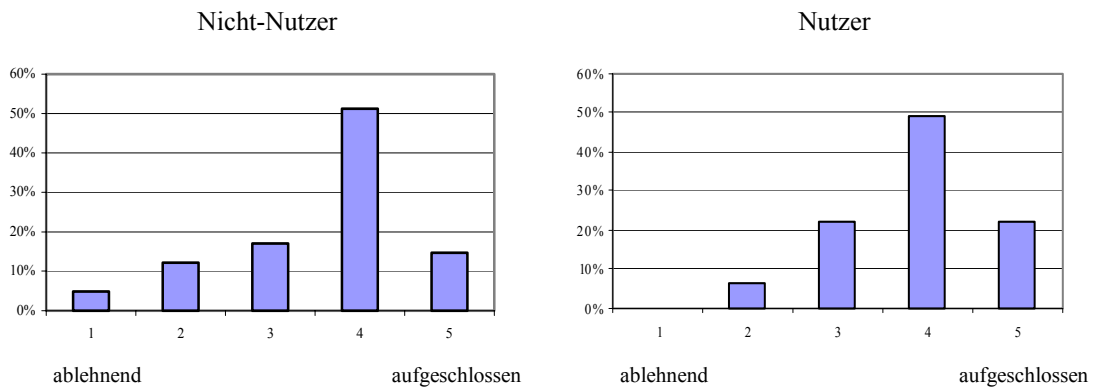


Abbildung A1.9: Projektpatenschaften der Geschäftsleitung

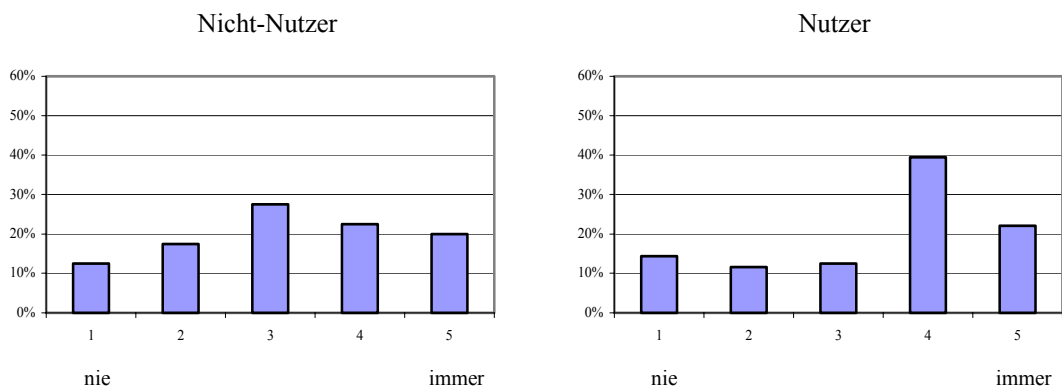



Abbildung A1.10: Interne Kommunikation



Anhang 2:

Fragebogen

Lehrstuhl für Mathematische Methoden
der Wirtschaftswissenschaften
Universität Augsburg
Dr. Andreas Hilbert, Mathias Prähofer



FRAGEBOGEN ZUM THEMA

ERFOLGSFAKTOREN

IM DATA MINING

(Auch elektronisch unter www.erfolgsfaktoren-datamining.de, login: Gast, Passwort: start)

A. UNTERNEHMENSMERKMALE

1. Welche Funktion üben Sie in Ihrem Unternehmen aus ?

2. Welcher Hauptbranche rechnen Sie Ihr Unternehmen zu ?

- Banken
- Versicherungen
- Versandhandel
- Einzel- oder Großhandel
- Telekommunikation
- Energieversorgung
- _____

3. Wie viele Mitarbeiter hat Ihr Unternehmen ?

- bis 500
- 1.001 - 5.000
- 501 - 1.000
- mehr als 5.000

4. Wie hoch war(en) der Umsatz bzw. die Bilanzsumme bzw. die Beitragseinnahmen Ihres Unternehmens im Jahre 2000 ?

In MIO. DM _____

A. WETTBEWERBS- UND MARKTSITUATION: DAS UNTERNEHMENSUMFELD

1. Wie intensiv ist der Wettbewerb in den Märkten, in denen Ihr Unternehmen hauptsächlich tätig ist ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
schwach				stark
2. Wie stark ist das Wachstum in diesen Märkten ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
schrumpfend				expandierend
3. Wie hoch ist die Anzahl existierender oder zukünftiger Wettbewerber in diesen Märkten ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
gering				sehr hoch
4. Wie würden Sie die Größe Ihres Unternehmens zu den Wettbewerbern Ihrer Branche im Vergleich sehen ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
klein				sehr groß
5. Wie groß ist der preispolitische Spielraum in diesen Märkten ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
gering				sehr groß
6. Wie groß ist das Marktpotential in diesen Märkten ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
gering				sehr groß
7. Welche Geschäftsstrategie verfolgt Ihr Unternehmen vorrangig ?
 - Differenzierungsstrategie**
(Abheben von der Konkurrenz durch bessere Qualität)
 - Kostenführerschaft**
(Kostenvorsprung gegenüber der Konkurrenz)
 - Kundenfokussierung**
(Individualisierung der Kundenbeziehungen)
 -

B. DIE UNTERNEHMENSORGANISATION UND -KULTUR

1. Wie würden Sie Ihr Unternehmen als Ganzes bezeichnen ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
konservativ				modern
2. Wie kann man das Verhalten der Entscheidungsträger Ihres Unternehmens einem Wandel gegenüber bezeichnen ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
ablehnend				aufgeschlossen
3. Inwieweit gibt es für wichtige Projekte in Ihrem Unternehmen einen Projektpaten aus der Geschäftsleitung ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
nie				immer
4. Wie würden Sie die interne Kommunikation in Ihrem Unternehmen bezeichnen ?

<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
1	2	3	4	5
schlecht				gut
5. Wie würden Sie die Planung in Ihrer Organisationsstruktur bezeichnen ?
 - eher retrograd, d.h. top-down**
(Vorgaben von oben)
 - eher progressiv, d.h. bottom-up**
(Vorschläge von unten)
 - gegenläufig**
(Vorgaben von oben mit Vorschlägen von unten)

A. INTEGRATION DES DATA MINING IM UNTERNEHMEN

1. Hat Ihr Unternehmen bereits <u>Erfahrungen mit Data Mining</u> ? (Falls Nein, bitte weiter mit Frage H1.)	<input type="checkbox"/>	<input type="checkbox"/>	ja	nein								
2. Gibt es in Ihrem Unternehmen ein Mitglied der Geschäftsleitung, das für das Data Mining verantwortlich zeichnet (<u>Projektdate</u>) ?	<input type="checkbox"/>	<input type="checkbox"/>	ja	nein								
3. Verfügt das Data Mining über ein <u>festes jährliches Gesamt-Budget</u> ?	<input type="checkbox"/>	<input type="checkbox"/>	ja	nein								
4. Inwieweit wurde zur <u>Integration</u> des Data Mining im Unternehmen der <u>Work-Flow Prozess</u> geändert ?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	1	2	3	4	5	vollkommen	gar nicht
5. Wie ist das Data Mining in Ihrem Unternehmen <u>organisatorisch verankert</u> ?	<input type="checkbox"/> in einer Stabsstelle (d.h. als Dienstleister im Unternehmen) <input type="checkbox"/> in einer Fachabteilung (z.B. als Teil des Marketings oder als Teil des Vertriebs) welche: _____											
6. Wie würden Sie die <u>Rolle</u> des Data Mining im <u>Work-Flow Prozess</u> bezeichnen ?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	1	2	3	4	5	Stand-Alone	integriert
7. Wie <u>aufgeschlossen</u> sind die involvierten Fachabteilungen des Unternehmens gegenüber den <u>Resultaten des Data Mining</u> ?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	1	2	3	4	5	sehr	gar nicht
8. <u>Inwieweit setzen</u> die involvierten Fachabteilungen die <u>Resultate des Data Mining</u> auch <u>um</u> ?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	1	2	3	4	5	immer	nie
9. <u>Wie</u> wurden in der Vergangenheit die <u>Resultate des Data Mining umgesetzt</u> ? (Mehrfachnennungen möglich)	<input type="checkbox"/> Entwicklung eines neuen Marketing-Konzeptes <input type="checkbox"/> Definition neuer Zielgruppen <input type="checkbox"/> Neuorientierung der Marketing-Strategie <input type="checkbox"/> Aufdeckung vorhandener Marktnischen <input type="checkbox"/> Steigerung der Kundenzufriedenheit <input type="checkbox"/> Identifikation neuer Kundensegmente <input type="checkbox"/> _____ <input type="checkbox"/> _____ <input type="checkbox"/> _____											
10. Inwieweit werden die <u>Ergebnisse des Data Mining</u> und deren <u>Umsetzungen einer Erfolgskontrolle</u> unterzogen ?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	1	2	3	4	5	immer	nie
11. Inwieweit werden zur <u>Unterstützung des Data Mining</u> auch <u>externe Berater</u> hinzugezogen ?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	1	2	3	4	5	immer	nie

A. PERSONAL UND DATA MINING

1. **Wie viele Mitarbeiter** wurden seit Einführung des **Data Mining** in Ihrem Unternehmen zur Unterstützung dieser Tätigkeit eingestellt ?
- keiner
 1 - 5
 6 - 10
 11 - 15
 mehr als 15
2. Inwieweit erachten Sie es als wichtig, dass **statistisch fundiert** ausgebildete **Mitarbeiter** im **Data Mining Team** vorhanden sind ?
- 1
 2
 3
 4
 5
 sehr wichtig
 unwichtig
3. Inwieweit erachten Sie es als wichtig, dass **nicht nur Statistiker** im **Data Mining Team** vorhanden sind ?
- 1
 2
 3
 4
 5
 sehr wichtig
 unwichtig
4. Inwieweit werden die involvierten **Mitarbeiter** im **Data Mining geschult** ?
- 1
 2
 3
 4
 5
 regelmäßig
 nie

B. INFORMATIONSTECHNOLOGIE UND DATA MINING

1. Wie würden Sie die **Integration** des **Data Mining-Prozesses** und seiner **Hard- und Software** in die bestehende **IT-Landschaft** bezeichnen ?
- 1
 2
 3
 4
 5
 sehr gut
 schlecht
2. Wie würden Sie die **Qualität** der dem **Data Mining** aus den operativen Systemen zur Verfügung gestellten Daten bezeichnen ?
- 1
 2
 3
 4
 5
 sehr gut
 schlecht
3. Inwieweit es ist notwendig, **externe Daten** zur Durchführung Ihrer **Data Mining-Aufgabe**, d.h. Ihres analytischen Prozesses, **hinzuzukaufen** ?
- 1
 2
 3
 4
 5
 sehr wichtig
 unwichtig
4. Existiert in Ihrem Unternehmen ein funktionsfähiges **Data Warehouse**, d.h. eine analytische Datenbank, die losgelöst von operativen Systemen als Basis für komplexe Datenauswertungen dient ?
- ja
 nein
5. Inwieweit wird in Ihrem Unternehmen **OLAP**, das **Online Analytical Processing**, zur Klärung anstehender Aufgaben verwendet ?
- 1
 2
 3
 4
 5
 sehr häufig
 nie
6. Wie würden Sie die beiden Ansätze **OLAP** und **Data Mining** in der Verwendung in Ihrem Unternehmen bezeichnen ?
- 1
 2
 3
 4
 5
 sich unterstützend
 in Konkurrenz
7. Existiert in Ihrem Unternehmen ein **Server**, der ausschließlich mit den im Rahmen des **Data Mining** notwendigen Prozessen betraut ist ?
- ja
 nein
8. Welche **Data Mining Software-Tools** verwenden Sie hauptsächlich ?
- _____

A. INDIKATOREN EINES ERFOLGREICHEN DATA MINING EINSATZES

- | | |
|--|--|
| 1. Wie würden Sie den Data Mining-Einsatz bezüglich des Zieles der <u>Deckungsbeitragssteigerung</u> bezeichnen ? | <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/>
1 2 3 4 5
nicht erfolgreich sehr erfolgreich |
| 2. Wie würden Sie den Data Mining-Einsatz bezüglich des Zieles der <u>Deckungsbeitragssteigerung pro Kunde</u> bezeichnen ? | <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/>
1 2 3 4 5
nicht erfolgreich sehr erfolgreich |
| 3. Wie würden Sie den Data Mining-Einsatz bezüglich des Zieles der <u>Umsatzsteigerung</u> bezeichnen ? | <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/>
1 2 3 4 5
nicht erfolgreich sehr erfolgreich |
| 4. Wie würden Sie den Data Mining-Einsatz bezüglich des Zieles der <u>Kostenreduzierung</u> bezeichnen ? | <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/>
1 2 3 4 5
nicht erfolgreich sehr erfolgreich |
| 5. Wie würden Sie den Data Mining-Einsatz bezüglich des Zieles der <u>Optimierung von Geschäftsprozessen</u> bezeichnen ? | <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/>
1 2 3 4 5
nicht erfolgreich sehr erfolgreich |
| 6. Wie würden Sie den Data Mining-Einsatz bezüglich des Zieles einer <u>höheren Marktdurchdringung</u> bezeichnen ? | <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/>
1 2 3 4 5
nicht erfolgreich sehr erfolgreich |
| 7. Wie würden Sie den Data Mining-Einsatz bezüglich des Zieles der <u>Verbesserung der Wettbewerbsposition</u> bezeichnen ? | <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/>
1 2 3 4 5
nicht erfolgreich sehr erfolgreich |
| 8. Wie würden Sie den Data Mining-Einsatz bezüglich des Zieles der <u>Erhöhung der Kundenbindung und -zufriedenheit</u> bezeichnen ? | <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/>
1 2 3 4 5
nicht erfolgreich sehr erfolgreich |

- | | |
|--|--|
| 9. Wie würden Sie den Data Mining-Einsatz <u>insgesamt</u> bezeichnen? | <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/>
1 2 3 4 5
nicht erfolgreich sehr erfolgreich |
|--|--|

10. Welche Faktoren sind Ihrer Meinung nach ausschlaggebend für einen erfolgreichen Einsatz von Data Mining ?

- _____
- _____
- _____

11. Welche Faktoren sind Ihrer Meinung nach ausschlaggebend für einen nicht-erfolgreichen Einsatz von Data Mining ?

- _____
- _____
- _____

A. DATA MINING WIRD IN IHREM UNTERNEHMEN NICHT EINGESETZT

Haben Sie bei Frage D1. mit **NEIN** geantwortet, bitten wir Sie trotzdem, uns folgende Informationen zu überlassen.

1. Existiert in Ihrem Unternehmen ein funktionsfähiges **Data Warehouse**,
d.h. eine analytische Datenbank, die losgelöst von operativen Systemen als
Basis für komplexe Datenauswertungen dient ? ja nein
2. **Welche Ansätze** zur Auswertung (komplexer) Datenbestände
verwenden Sie ? (Mehrfachnennungen möglich)
- Einfache Reports
 - Visualisierungstechniken
 - Verfahren der Klassischen Statistik
 - Multivariate Verfahren der Datenanalyse
 - Online Analytical Processing (OLAP)
 - _____
 - _____
 - _____
3. **Welche Gründe** sprechen bisher gegen den Einsatz von Data Mining in
Ihrem Unternehmen ? (Mehrfachnennungen möglich)
- Für Branche ungeeignet
 - Unsicherheit bezüglich des Erfolgs
 - Nutzen nicht erkennbar
 - Technische Voraussetzungen fehlen
 - Organisatorische Voraussetzungen fehlen
 - Mangelhafte Datenbasis
 - Mangel an qualifiziertem Personal
 - Hohe Kosten
 - Zeitmangel
 - _____
 - _____
 - _____
4. Sind in Ihrem Unternehmen Data Mining-Projekte in **naher Zukunft**
geplant ? ja nein

**Zum Abschluss bedanken wir uns sehr herzlich
für die Beantwortung unserer Fragen !**

Literatur

Adelman, S. (2000): Critical Success Factors for Data Warehousing Projects. *InformIT*, Februar 2001.

Adelman, S. und Moss, L.T. (2000): Data Warehouse Project Management. Addison-Wesley, Boston.

Aldrich, H.E. (1992): Methods in our Madness? Trends in Entrepreneurship Research. In: D.L. Sexton und J.D. Kasarda (Hrsg.): *The State of the Art of Entrepreneurship*. PWS-Kent Publishing Company, Boston, S. 191 – 213.

Ahlemeyer-Stubbe, A. (2001): Datenmanagement & CRM. *Direkt Marketing*, Nr. 7, S. 26 – 28.

Anderson, J.C. und Gerbing, D.W. (1988): Structural Equation Modeling in Practice: A Review and Recommended Two-Step Approach. *Psychological Bulletin*, Nr. 3, S. 411 – 423.

Bagozzi, R.P. und Phillips, L. (1982): Representing and Testing Organizational Theories: A Holistic Approach. *Administrative Science Quarterly*, Nr. 3, S. 459 – 489.

Bamberg, G. und Baur, F. (2002): Statistik. Oldenbourg, München.

Bamberger, I. (1988): Strategische Ausrichtung kleiner und mittlerer Unternehmen. Duncker & Humblot, Berlin.

Bollen, K.A. (1989): Structural Equations with Latent Variables. Wiley, New York.

Bornemeyer, C. (2002): Erfolgskontrolle im Stadtmarketing. Eul. Lohmar.

Brendel, M. (2002): CRM für den Mittelstand. Gabler, Wiesbaden.

Bruhn, M. und Homburg, C. (2000): Kundenbindungsmanagement – Eine Einführung. In: C. Homburg und M. Bruhn (Hrsg.): *Handbuch Kundenbindungsmanagement*. Gabler, Wiesbaden.

Buzzell, R.D. und Gale, B.T. (1987): The PIMS Principles, Free Press, New York.

Chamoni, P. und Zeschau, D. (1996): Management Support Systeme und Data Warehousing. In: H. Mucksch und W. Behme (Hrsg.): *Das Data Warehouse Konzept: Architektur – Datenmodelle – Anwendungen*. Gabler, Wiesbaden.

- Churchill, G. (1979):** A Paradigm for Developing Better Measures of Marketing Constructs. *Journal of Marketing Research*, Nr. 2, S. 64 – 73.
- Codd, E.; Codd, S. und Sally, C. (1993):** Providing OLAP (Online Analytical Processing) to User-Analysts. An IT mandate, White Paper, E.F. Codd & Associates.
- Daniel, R. (1961):** Management Information Crisis. *Harvard Business Review*, September/October, S. 111 – 121
- Daniel, D.R. (1996):** Erfolgsfaktoren für die Einführung von Informationstechnologien in internationalen Unternehmen in Indonesien. Dissertation, Freiburg.
- Daschmann, H.A. (1994):** Erfolgsfaktoren mittelständischer Unternehmen: ein Beitrag zur Erfolgsfaktorenforschung. Schäffer-Poeschel, Stuttgart.
- Dess, G.G. und Robinson, R.B. (1984):** Measuring Organizational Performance in the Absence of Objective Measures: The Case of the Privately-Held Firm and Conglomerate Business Unit. *Strategic Management Journal*, Nr. 3, S. 265 – 273.
- Dittmar, C. (1999):** Erfolgsfaktoren für Data Warehouse Projekte – eine empirische Studie aus Sicht der Anwendungsunternehmen. Institut für Unternehmensführung und Unternehmensforschung, Arbeitsbericht Nr. 78, Universität Bochum.
- Fahrmeir, L; Häußler, W. und Tutz, G. (1984):** Diskriminanzanalyse. In: L. Fahrmeir und A. Hamerle: *Multivariate statistische Verfahren*. de Gruyter, Berlin, S. 301 – 370.
- Fayyad, U.M.; Piatetsky-Shapiro, G.; Smyth, P. und Uthurasamy, R. (1996):** Advances in Knowledge Discovery and Data Mining. MIT Press, Menlo Park.
- Fornell, C. und Larcker, D.F. (1981):** Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, Nr. 1, S. 39 – 50.
- Frese, E. (1985):** Exzellente Unternehmungen – Konfuse Theorien. Kritisches zur Studie von Peters und Waterman. *Die Betriebswirtschaft*, Nr. 5, S. 604 – 606.
- Frielitz, C.; Hippner, H.; Martin, S. und Wilde, K.D. (2000):** CRM 2000: Aufklärung tut Not. *Absatzwirtschaft*, Nr. 7, S. 100 – 104.
- Fritz, W. (1990):** Marketing – ein Schlüsselfaktor des Unternehmenserfolges? Eine kritische Analyse vor dem Hintergrund der empirischen Erfolgsfaktorenforschung. *Marketing*, Nr. 2, S. 91 – 110.

- Gentsch, P. (2000):** Data Mining – Text Mining – Web Mining. Datenberge intelligent sortieren. *Computerwoche Extra, Nr. 4, S. 40 – 42.*
- Göttgens, O. (2000):** Customer Relationship Management. BBDO Group Germany, Düsseldorf.
- Grabner-Kräuter, S. (1993):** Diskussionsansätze zur Erforschung von Erfolgsfaktoren. *Journal für Betriebswirtschaft, Nr. 6, S. 278 – 300.*
- Green, P.E. und Tull, S.D. (1988):** Research für Marketing Decision. Prentice Hall, Englewood Cliffs.
- Hamerle, A.; Kemény P. und Tutz, G. (1984):** Kategoriale Regression. In: L. Fahrmeir und A. Hamerle: *Multivariate statistische Verfahren.* de Gruyter, Berlin, S. 211 – 256.
- Hatcher, L. (1998):** A Step-by-Step Approach to Using the SAS System for Factor Analysis and Structural Equation Modeling. SAS Institute Inc., Cary.
- Heinrich, L.J. (1998):** Wirtschaftsinformatik-Lexikon. Oldenbourg, München.
- Hermiz, K.B. (1999):** Critical Success Factors for Data Mining Projects. *DM Review, Februar 1999.*
- Hilbert, A. (1998):** Zur Theorie der Korrelationsmaße. Eul, Lohmar.
- Hildebrandt, L. und Trommsdorff, V. (1989):** Anwendungen der Erfolgsfaktorenanalyse im Handel. In: V. Trommsdorff (Hrsg.): *Handelsforschung 1989.* Gabler, Wiesbaden, S. 15 – 26.
- Hippner, H. und Wilde, K.D. (2000):** Den Kunden verstehen. *Marketing und Kommunikation, Nr. 8, S. 16 – 18.*
- Hippner, H. und Wilde, K.D. (2001a):** CRM – Ein Überblick. In: S. Helmke und W. Dangelmaier (Hrsg.): *Effektives Customer Relationship Management.* Gabler, Wiesbaden, S. 3 – 38.
- Hippner, H. und Wilde, K.D. (2001b):** Data Mining im CRM. In: S. Helmke und W. Dangelmaier (Hrsg.): *Effektives Customer Relationship Management.* Gabler, Wiesbaden, S. 211 – 231.
- Hippner, H. und Wilde, K.D. (2001c):** Der Prozess des Data Mining im Marketing. In: H. Hippner, U. Küsters, M. Meyer und K.D. Wilde (Hrsg.): *Handbuch Data Mining im Marketing.* Vieweg-Gabler, Wiesbaden, S. 22 – 94.

- Hörmann, N. (1998):** Editorial. *computerwoche focus*, Nr. 2, S. 3.
- Holzer, M.; Bölscher, A. und Gräther, M. (2000):** Welchen Stellenwert hat CRM? Ein Vergleich des Einsatzes von Customer Relationship Management-Systemen bei deutschen Autobanken und Kfz-Leasinggesellschaften. Managementteam Unternehmensberatung, Wiesbaden.
- Homburg, C. und Baumgartner, H. (1995):** Die Kausalanalyse als Instrument der Marketingforschung. *Zeitschrift für Betriebswirtschaft*, Nr. 10, S. 1091 – 1108.
- Homburg, C. und Giering, A. (1996):** Konzeptionalisierung und Operationalisierung komplexer Konstrukte: Ein Leitfaden für die Marketingforschung. *Marketing ZFP*, Nr. 1, S. 5 – 24.
- Homburg, C. und Giering, A. (1998):** Konzeptionalisierung und Operationalisierung komplexer Konstrukte: Ein Leitfaden für die Marketingforschung. In: L. Hildebrandt und C. Homburg (Hrsg.): *Die Kausalanalyse*. Schäffer-Poeschel, Stuttgart, S. 111 – 146.
- Homburg, C. und Pflesser, C. (2000a):** Konfirmatorische Faktorenanalyse. In: A. Herrmann und C. Homburg (Hrsg.): *Marktforschung*. Gabler, Wiesbaden, S. 413 – 437.
- Homburg, C. und Pflesser, C. (2000b):** Strukturgleichungsmodelle mit latenten Variablen: Kausalanalyse. In: A. Herrmann und C. Homburg (Hrsg.): *Marktforschung*. Gabler, Wiesbaden, S. 633 – 659.
- Homburg, C. und Sütterlin, S. (1990):** Kausalmodelle in der Marketingforschung. *Marketing ZFP*, Nr. 3, S. 181 – 192.
- Hummeltenberg, W. (1995):** Realisierung von Management-Unterstützungssystemen mit Planungssprachen und Generatoren für Führungsinformationssysteme. In: R. Hichert und M. Moritz (Hrsg.): *Management-Informationssysteme*. Springer, Berlin, S. 258 – 279.
- Kast, F.E. und Rosenzweig, J.E. (1973):** Contingency Views of Organization and Management. Science Research Association, Chicago.
- Kube, C. (1991):** Erfolgsfaktoren in Filialsystemen: Diagnose und Umsetzung im strategischen Controlling. Gabler, Wiesbaden.
- Küpper, H.-U. (1994):** Erfolgsfaktoren mittelständischer Unternehmen. In: H.J. Pleitner (Hrsg.): *Strukturen und Strategien in Klein- und Mittelunternehmen als Wegbereiter des Aufschwungs: Beiträge zu den „Rencontres de St. Gall“*. IGW, St. Gallen. S. 115 – 124.

- Küsters, U. (2001):** Data Mining Methoden: Einordnung und Überblick. In: H. Hippner, U. Küsters, M. Meyer und K.D. Wilde (Hrsg.): *Handbuch Data Mining im Marketing*. Vieweg-Gabler, Wiesbaden, S. 95 – 130.
- Lang, H. (1997):** Erfolgsfaktoren privater Krankenanstalten. Eul, Lohmar.
- Leeflang, P.S.H.; Wittink, D.R.; Wedel, M. und Naert, P.A. (2000):** Building Models for Marketing Decisions. Kluwer, Dordrecht.
- Lusti, M. (1999):** Data Warehousing und Data Mining. Springer, Berlin.
- Meyer, M. (2001):** Data Mining im Marketing: Einordnung und Überblick. In: H. Hippner, U. Küsters, M. Meyer und K.D. Wilde (Hrsg.): *Handbuch Data Mining im Marketing*. Vieweg/Gabler, Wiesbaden, S. 563 – 588.
- Müller, R. (1999):** Erfolgsfaktoren schnell wachsender Software-Startups: eine lebenszyklische Untersuchung von Softwareunternehmen des Produktionsgeschäfts. Lang, Frankfurt.
- Patt, P.-J. (1990):** Strategische Erfolgsfaktoren im Einzelhandel. Lang, Frankfurt.
- Peter, J. und Churchill, G. (1986):** Relationships among Research Design Choices and Psychometric Properties of Rating Scales: A Meta-Analysis. *Journal of Marketing Research*, Nr. 5, S. 133 – 145.
- Poloni, M. und Beilke, S. (2000):** Data Mining und CRM – eine gute Partnerschaft? *Database Marketing*, Nr. 2, S. 14 – 15.
- Pümpin, C. (1986):** Management strategischer Erfolgspositionen. Das SEP-Konzept als Grundlage wirkungsvoller Unternehmensführung. Haupt, Stuttgart.
- Raab, G. und Lorbacher, N. (2002):** Customer Relationship Management: Aufbau dauerhafter und profitabler Kundenbeziehungen. Sauer, Heidelberg.
- Resch, C. (2001):** Faktoren für erfolgreiche CRM-Projekte: Customer Relationship Management beginnt in den Köpfen. *SAP-Info*. Dezember 2001.
- Rockart, J. (1979):** Chief Executive Define Their Own Data Needs. *Harvard Business Review*, March/April, S. 81 – 93.
- Rosemann, M.; Rochefort, M. und Behnck, W. (1999):** Customer Relationship Management. *HMD – Praxis der Wirtschaftsinformatik*, Nr. 208, S. 105 – 116.

- Rosenbauer, C.C. (1994):** Strategische Erfolgsfaktoren des Familienunternehmens im Rahmen seines Lebenszyklus. Ein eignerorientiertes Konzept zur Steigerung der Lebens- und Entwicklungsfähigkeit des Familienunternehmens. Dissertation, St. Gallen.
- Rust, R.T.; Zeithaml, V.A. und Lemon, K.N. (2000):** Driving Customer Equity: How Customer Lifetime Value is Reshaping Corporate Strategy. Free Press, New York.
- Säuberlich, F. (2000):** KDD und Data Mining als Hilfsmittel zur Entscheidungsunterstützung. Lang, Frankfurt.
- Schmidt, M. (2002):** Customer Relationship Management: Die Einführung ist Chefsache. *SAP-Info, Mai 2002*.
- Schneider, P. (1991):** Erfolgsfaktoren des Managements technologischer Produktinnovationen. Dissertation, St. Gallen.
- Schober, F. (1996):** Interdependenzen von Unternehmensstrategien und Informations- und Kommunikationsstrategien. *Zeitschrift für Betriebswirtschaft, Nr. 1, S. 29 – 48*.
- Schulze, T. (2001):** Erfolgsorientiertes Customer Relationship Management (CRM) auf Basis von Business Intelligence (BI)-Lösungen. In: S. Helmke und W. Dangelmaier (Hrsg.): *Effektives Customer Relationship Management*. Gabler, Wiesbaden, S. 233 – 255.
- Schweizer, A. (1999):** Data Mining, Data Warehousing: Datenschutzrechtliche Orientierungshilfen für Privatunternehmen. Orell Füssli, Zürich.
- Spies, R. (1998):** Es scheitern weniger Projekte als angenommen. *computerwoche focus, Nr. 2, S. 38 – 39*.
- Steffenhagen, H. (1998):** Erfolgsfaktorenforschung für die Werbung – Bisherige Ansätze und deren Beurteilung. In: M. Bruhn und H. Steffenhagen: *Marktorientierte Unternehmensführung*. Gabler, Wiesbaden, S. 323 – 350.
- Stengl, B.; Sommer, R. und Ematinger R. (2001):** CRM mit Methode: Intelligente Kundenbindung in Projekt und Praxis mit iCRM. Galileo Press, Bonn.
- Stephan, B. (1998):** Data Warehouses richtig aufbauen. *Diebold Management Report, Nr. 4, S. 23 – 26*.
- Tabachnik, B.G. und Fidell, L.S. (1996):** Using Multivariate Statistics. Harper Collins, New York.

Ulrich, H. und Probst, G. (1988): Anleitung zum ganzheitlichen Denken und Handeln. Haupt, Stuttgart.

Weill, P. (1990): The Relationship between Investment in Information Technology and Firm Performance: A Study of the Valve Manufacturing Sector. Working Paper, Nr. 19. The Graduate School of Management, The University of Melbourne.

Weitzendorf, T. (2000): Der Mehrwert der Informationstechnologie: eine empirische Studie der wesentlichen Erfolgsfaktoren auf den Unternehmenserfolg. Gabler, Wiesbaden.

Wilde, K.D. (2001a): Data Warehouse, OLAP und Data Mining im Marketing – Moderne Informationstechnologien im Zusammenspiel. In: H. Hippner, U. Küsters, M. Meyer und K.D. Wilde (Hrsg.): *Handbuch Data Mining im Marketing*. Vieweg-Gabler, Wiesbaden, S. 1 – 19.

Wilde, K.D. (2001b): Return on Investment: Erfolgsfaktoren im Customer Relationship Management. *absatzwirtschaft online*, Oktober 2001.

Wilde, K.D. und Hippner, H. (2000): CRM2000 – Customer Relationship Management. Verlagsgruppe Handelsblatt, Düsseldorf.

Wilde, K.D. und Hippner, H. (2002): Data Mining – Mehr Gewinn aus Ihren Kundendaten. Verlagsgruppe Handelsblatt, Düsseldorf.

Wübker, G. und Buckler, F: (2002): Customer Relationship Management (CRM): Worauf kommt es an? *Direkt Marketing*, Nr. 4.