

Franken, Ronald

**Working Paper**

## Ein Vergleich des binären Logit-Modells mit künstlichen neuronalen Netzen zur Insolvenzprognose anhand relativer Bilanzkennzahlen

SFB 649 Discussion Paper, No. 2007,044

**Provided in Cooperation with:**

Collaborative Research Center 649: Economic Risk, Humboldt University Berlin

*Suggested Citation:* Franken, Ronald (2007) : Ein Vergleich des binären Logit-Modells mit künstlichen neuronalen Netzen zur Insolvenzprognose anhand relativer Bilanzkennzahlen, SFB 649 Discussion Paper, No. 2007,044, Humboldt University of Berlin, Collaborative Research Center 649 - Economic Risk, Berlin

This Version is available at:

<https://hdl.handle.net/10419/25216>

**Standard-Nutzungsbedingungen:**

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

**Terms of use:**

*Documents in EconStor may be saved and copied for your personal and scholarly purposes.*

*You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.*

*If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.*

SFB 649 Discussion Paper 2007-044

# Ein Vergleich des binären Logit-Modells mit künstlichen neuronalen Netzen zur Insolvenzprognose anhand relativer Bilanzkennzahlen

Ronald Franken\*



\* Technische Universität Berlin, Germany

This research was supported by the Deutsche  
Forschungsgemeinschaft through the SFB 649 "Economic Risk".

<http://sfb649.wiwi.hu-berlin.de>  
ISSN 1860-5664

SFB 649, Humboldt-Universität zu Berlin  
Spandauer Straße 1, D-10178 Berlin



SFB 649 ECONOMIC RISK BERLIN

# Ein Vergleich des binären Logit-Modells mit künstlichen neuronalen Netzen zur Insolvenzprognose anhand relativer Bilanzkennzahlen

Ronald Franken  
Technische Universität Berlin  
Institut für Wirtschaftsinformatik und Quantitative Methoden  
FG Statistik und Ökonometrie  
Franklinstraße 28/29  
10587 Berlin

Juli 2007

## **Zusammenfassung**

Die Prognose der Insolvenzgefährdung von Unternehmen anhand statistischer Methodik war und ist eine bedeutende Aufgabe empirischer Forschung. Eine Möglichkeit der Beurteilung der finanziellen bzw. wirtschaftlichen Verfassung von Unternehmen stellt die sog. externe Bilanzanalyse anhand verschiedener relativer Kennzahlen(-systeme) dar, welche aus den veröffentlichten Jahresabschlüssen von Kapitalgesellschaften abgeleitet werden können. In der aktuellen Praxis der empirischen Insolvenz- und Risikoforschung ist nach wie vor die klassische parametrische Methode der binären logistischen Regression weit verbreitet. In der jüngeren Vergangenheit haben jedoch neue Methoden der statistischen Lerntheorie, die aus den Methoden des maschinellen Lernens hervorgegangen sind, zunehmend an Bedeutung erlangt. In der vorliegenden Arbeit wird ein künstliches neuronales Netz zur Insolvenzklassifikation anhand relativer Bilanzkennzahlen entwickelt und mit den Ergebnissen der logistischen Regressionsanalyse verglichen und evaluiert.

Keywords: Insolvenzprognose, externe Bilanzanalyse, Künstliche Neuronale Netze, Binäres Logit-Modell, logistische Regression

Diese Arbeit wurde von der Deutschen Forschungsgemeinschaft durch den SFB 649 "Ökonomisches Risiko" unterstützt.

JEL Codes: C45, G32, G33

# 1 Problemstellung: Insolvenzprognose aus Jahresabschlüssen

Ziel der hier durchzuführenden Analyse ist es, anhand der beobachteten Jahresabschlussdaten einer Auswahl von 21.000 deutschen Unternehmen Klassifikations- und damit Prognosemodelle für die zukünftige Ertragslage und damit verbunden einer Insolvenzprognose zu entwickeln. Dabei sollen das am häufigsten zu diesem Zweck eingesetzte klassischen statistische Verfahren, die binäre logistische Regression, mit den in der jüngeren Vergangenheit stark verbreiteten künstlichen neuronalen Netzwerkmodellen verglichen und evaluiert werden.

Die softwaregestützte Analyse erfolgt mit der Data Mining-Software *Enterprise Miner 5.2* und der Statistik-Analysesoftware *SAS Enterprise Guide 3.0* der Firma *SAS Institute GmbH Deutschland*, die im Rahmen eines Kooperationsvertrages zur Verfügung gestellt wurden.<sup>1</sup> Außerdem wird das Statistik-Paket *R Vers. 2.4.0* des *R Project for Statistical Computing*<sup>2</sup> verwendet.

Die Generierung von Aussagen über die Ertragslage von Unternehmen betrifft sowohl gesamtwirtschaftliche als auch betriebswirtschaftliche Fragestellungen. So wird eine sinnvolle Konjunkturprognose ohne die Berücksichtigung der Ertragslage der Gesamtheit der Unternehmen nicht möglich sein. Bei den betriebswirtschaftlichen Aspekten spielen insbesondere die Bereiche Risikofrüherkennung, Kreditwürdigkeitsprüfung, Ratingverfahren sowie die Insolvenzprognose eine wichtige Rolle.

Insbesondere die Prognose einer eventuellen Insolvenzgefahr ist für viele Unternehmen von unmittelbarer praktischer Bedeutung. So ist es etwa für Unternehmen, die die deutsche Rechtsform der Aktiengesellschaft (AG) besitzen, verpflichtend, ein sog. Insolvenzfrühwarnsystem in ihr internes Rechnungswesen zu integrieren. § 91 II AktG schreibt hierzu vor: "Der Vorstand hat geeignete Maßnahmen zu treffen, insbesondere ein Überwachungssystem einzurichten, damit den Fortbestand der Gesellschaft gefährdende Entwicklungen früh erkannt werden." Nach deutschem Gesellschaftsrecht kann sowohl die Zahlungsunfähigkeit der Gesellschaft als auch die Überschuldung zur Insolvenz führen.<sup>3</sup> Zahlungsunfähigkeit ist hierbei definiert als die Unfähigkeit der Unternehmung, rechtlich oder ökonomisch zwingend fällige Zahlungen leisten zu können.<sup>4</sup> Der Tatbestand der Überschuldung ist erfüllt, wenn die Verbindlichkeiten der Unternehmung den Wert der vorhandenen Aktiva übersteigen.<sup>5</sup> Bei Personengesellschaften führt lediglich die Zahlungsunfähigkeit zur Insolvenz.

Die ökonomische Bedeutung einer möglichst guten Prognose der Insolvenzgefahr ist unmittelbar ersichtlich, da die Unfähigkeit eines Unternehmens, Ver-

<sup>1</sup>Vgl. <http://www.sas.com/technologies/analytics/datamining/miner/> bzw. [http://www.sas.com/technologies/bi/query\\_reporting/guide/index.html](http://www.sas.com/technologies/bi/query_reporting/guide/index.html).

<sup>2</sup>Informationen und Download von R bzw. MatLab auf <http://www.r-project.org> bzw. <http://www.mathworks.de>.

<sup>3</sup>Vgl. § 92 II AktG.

<sup>4</sup>Vgl. § 17 InsO.

<sup>5</sup>Vgl. § 19 InsO.

bindlichkeiten zu bedienen, meist den Ausfall oder zumindest die Reduzierung der entsprechenden Forderungen des Vertragspartners zur Folge hat. Hat der Vertragspartner wiederum Verbindlichkeiten zu bedienen, könnte dieser Forderungsausfall auch ihn in Schwierigkeiten bringen. Somit kann die Insolvenz eines Unternehmens eine Kettenreaktion bezüglich der Insolvenzgefahr vieler weiterer mittelbar oder unmittelbar mit diesem Unternehmen verbundenen Unternehmen auslösen. Eine entsprechende Betrachtung der Vertragspartner hinsichtlich deren Insolvenzgefahr ist somit als essentiell wichtig einzustufen.<sup>6</sup> Des Weiteren kann die Insolvenzwahrscheinlichkeit als Risikomaß in die Kreditvertragsgestaltung einfließen, z.B. bei der Festlegung risikoabhängiger Zinssätze (Credit Scoring).

## 1.1 Externe Bilanzanalyse

Unter einer *externen Bilanzanalyse* versteht man die Analyse eines Unternehmens ausschließlich anhand publizierter Informationsquellen wie z.B. Jahresabschlüssen, Geschäftsberichten und ggf. Presseberichten. Betriebsinterne Informationsquellen werden dabei nicht herangezogen.<sup>7</sup>

Zu den grundlegenden Aufgaben des von einem Unternehmen zu verfassenen Jahresabschlusses<sup>8</sup> zählt, Aufschluss über die Vermögenslage, die Finanzlage und die Ertragslage des betreffenden Unternehmens zu geben.<sup>9</sup> Der Jahresabschluss spiegelt dabei das Ergebnis sämtlicher Geschäftsvorfälle eines Geschäftsjahres wieder.

Die Darstellung der *Vermögenslage* soll darüber informieren, wie "reich" bzw. "arm" das Unternehmen ist, d.h. wie groß der Saldo zwischen den ihm gehörenden Besitzpositionen und seinen Verbindlichkeiten im weitesten Sinne ist. Die Darstellung der *Finanzlage* soll über die Herkunft und Verwendung der im Unternehmen eingesetzten Mittel sowie über deren Fristigkeiten Auskunft geben. Letztlich soll die Darstellung der *Ertragslage* darüber informieren, in welchem Umfang und aus welchen Gründen sich das Reinvermögen (Eigenkapital) des Unternehmens innerhalb eines bestimmten Zeitraumes verändert hat. Das zentrale Instrument zur Darstellung der Ertragslage ist die zeitraumbezogene Gewinn- und Verlustrechnung (GuV). Darin sind einerseits die Quellen und das Zustandekommen des Ertrages<sup>10</sup> sowie andererseits die Aufwandsstruk-

<sup>6</sup>Dies stellt auch den Unternehmenszweck des "Verbandes der Vereine Creditreform e.V." dar, von dem die in dieser Arbeit verwendeten Jahresabschlussdaten zur Verfügung gestellt wurden, vgl. weiter unten Abschnitt 1.2.

<sup>7</sup>Vgl. [Schult 2003], S.5. Im Gegensatz dazu kann in einer internen Bilanzanalyse auf sämtliche Informationen bezüglich des Jahresabschlusses des jeweiligen Unternehmens zugegriffen werden. Dazu gehören beispielsweise das umfassend verfügbare Datenmaterial aus Kontenachweisen, der Finanzbuchhaltung und -planung, der Kostenrechnung und sonstiger Auswertungen und Plandaten.

<sup>8</sup>Der Jahresabschluss einer Kapitalgesellschaft besteht aus der Bilanz, der Gewinn- und Verlustrechnung, dem Anhang und dem Lagebericht. Dieser Jahresabschluss hat unter Beachtung der Grundsätze ordnungsmäßiger Buchführung ein den tatsächlichen Verhältnissen entsprechendes Bild der Vermögens-, Finanz- und Ertragslage zu vermitteln. (§ 264 HGB)

<sup>9</sup>Vgl. § 264 Abs.2 HGB, Generalklausel.

<sup>10</sup>Der Begriff der Ertragslage im betriebswirtschaftlichen Sinn bezieht sich auf den Ertrag,

tur aus gewöhnlicher und außergewöhnlicher Geschäftstätigkeit im abgelaufenen Geschäftsjahr ersichtlich zu machen.

Somit kann der Jahresabschluss eine Grundlage für die Schätzung der Ertragslage des Unternehmens unter Berücksichtigung der finanziellen Stabilität des Unternehmens bilden.<sup>11</sup> Unter dem Begriff der finanziellen Stabilität wird insbesondere die nachhaltige Sicherung der Liquidität, d.h. der Zahlungsfähigkeit des Unternehmens verstanden. Beide Aspekte sind voneinander abhängig, denn die finanzielle Stabilität ist Voraussetzung für das Erreichen von nachhaltigen Gewinnen und Wachstum eines Unternehmens.

Allgemein ist die Aussagekraft der externen Bilanzanalyse durch verschiedene Faktoren begrenzt. Einige davon sollen im Folgenden angesprochen werden.

Die wichtigste Beschränkung liegt in der Mangelhaftigkeit der Informationsquelle Jahresabschluss. Diese hat verschiedene Ursachen. Zum Einen sind Bilanzgrößen durch Ausübung von Bilanzierungs- und Bewertungsrichtlinien in gewissem Umfang beeinflussbar. Es ist davon auszugehen, dass diese Spielräume genutzt werden, da ein Unternehmen bei negativer Geschäftslage einen Anreiz hat, diese gegenüber den Anteilseignern besser darzustellen, um seinen Marktwert nicht negativ zu beeinflussen. Andererseits besteht bei positiver Geschäftslage evtl. ein Anreiz, die Situation z.B. gegenüber der Steuerbehörde oder den Anteilseignern schlechter darzustellen, um Zahlungsansprüche niedrig zu halten. Hinzu kommt, dass diese Bilanzierungs- und Bewertungsspielräume zwischen den verschiedenen Rechnungslegungsnormen variieren. So ist beispielsweise im deutschen Handelsrecht der Gläubigerschutz das bestimmende Prinzip. Daher sind die Wertansätze für Vermögensgegenstände eher niedrig zu wählen. In den IAS/IFRS<sup>12</sup> hingegen ist es gestattet, Vermögensgegenstände neu zu bewerten und so stille Reserven aufzudecken.<sup>13</sup> Dies führt dazu, dass die Wertansätze auf der Aktivseite der Unternehmen, die nach HGB bilanzieren, tendenziell niedriger sein werden als die der nach IAS/IFRS bilanzierenden Unternehmen.

Des Weiteren resultieren die Positionen der Bilanz und der GuV aus der Periodenabgrenzung von Aufwendungen und Erträgen. Es handelt sich hierbei also nicht um reine Zahlungsstromgrößen, wie sie für eine sinnvolle Analyse der Liquidität nötig wären. Weiterhin ist unklar, in welchem Umfang die Jahresabschlussdaten Einflüsse konzerninterner Verflechtungen enthalten, die die Vergleichbarkeit der Daten hinsichtlich der Ertragskraft beeinflussen könnten.

Schließlich können im Rahmen der hier durchzuführenden unternehmensübergreifenden externen Bilanzanalyse keine zeitlichen Entwicklungen der Unternehmen beobachtet werden. Im Folgenden wird daher eine statische Bilanzanalyse durchgeführt.

---

der den Wert aller während einer Periode erbrachten Leistungen umfasst. Dieser setzt sich aus Erträgen, die durch die typischen Leistungen des Betriebes entstanden sind und aus neutralen Erträgen wie Gewinne aus außerordentlicher, betriebs- und periodenfremder Leistung zusammen, vgl. [Coenenberg 1993], S.597 ff.

<sup>11</sup>Vgl. [Jerschensky 1998], S.80.

<sup>12</sup>International Accounting Standards / International Financial Reporting Standards, internationale Standards und Interpretationen zur externen Rechnungslegung von Unternehmen, vgl. <http://www.iasifrs.de>.

<sup>13</sup>Vgl. [Pellens et al. 2004], S.290 ff.

## 1.2 Datenbasis

Bei den zu analysierenden Rohdaten handelt es sich um eine vom SFB 649 "Ökonomisches Risiko" der Humboldt Universität zu Berlin für Forschungszwecke zur Verfügung gestellte Stichprobe des *Verbandes der Vereine Creditreform e.V.*<sup>14</sup> im Umfang von 21.000 in Deutschland ansässigen Unternehmen, welche jeweils durch die in Tab. 1 aufgelisteten Jahresabschlusspositionen charakterisiert sind, die in Positionen der Bilanz und der GuV untergliedert werden können. Darüber hinaus sind in dem Datensatz Informationen über die Branchenzugehörigkeit der Unternehmen und ihre Größe enthalten. Rechtsform, Rechtskreis und die Regulierungsvorschrift, nach der die Unternehmen bilanzieren, werden ebenfalls benannt. Das Merkmal 'Insolvenz Kriterium' beinhaltet die Information, ob das entsprechende Unternehmen innerhalb der nach dem Erhebungszeitpunkt liegenden 2 folgenden Jahre insolvent wurde (KRIT= 1) oder nicht (KRIT= 0). Dabei sind genau 1.000 Unternehmen in der Stichprobe insolvent und 20.000 Unternehmen nicht insolvent geworden.

Einige Merkmale des Rohdatensatzes weisen sehr hohe Anteile fehlender Werte (zum Teil mehr als 50%) auf. Dies betrifft die Merkmale GRSTBA, IMMA, FORDBET, VERBBET, PRST, GESDAHR, VERW und MA, weshalb diese aus Gründen der möglichen Ergebnisverzerrung aus der weiteren Analyse ausgeschlossen werden. Alle Unternehmen des Datensatzes haben einen Einzelabschluss nach deutschem Handelsrecht in Euro erstellt, weshalb auch die Merkmale REK und ABSCHLUSS aus dem Datensatz entfernt werden, da alle Objekte die gleiche Ausprägung "HGB" bzw. "Einzelabschluss" aufweisen. Ebenso werden das Jahr des beobachteten Jahresabschlusses, die Rechtsform und die Identifikationsnummer nicht in die weitere Analyse einbezogen. Die Branchenzugehörigkeit der Unternehmen wird zu Wirtschaftszweigen in Form von Dummyvariablen verdichtet und so bei den Modellschätzungen berücksichtigt.

## 1.3 Aufbereitung der Positionen der Bilanz und GuV

Die Datenbasis ist nun so aufzubereiten, um die für die Abbildung der Vermögens-, Finanz- und Ertragslage notwendigen Kennzahlen zu erhalten. Dazu sind die Jahresabschlüsse in die sog. Strukturbilanz und in die Erfolgsspalung zu überführen.

Für die Bilanzerstellung von Kapitalgesellschaften ist das je nach Größe der Gesellschaft gesetzlich vorgeschriebene Gliederungsschema nach § 266 HGB maßgebend. Für kleine Kapitalgesellschaften beschränkt sich die Gliederungstiefe auf die in Abb. 1 dargestellte Form. Aufgrund der im hier zur Verfügung stehenden Datensatz enthaltenen Variablen ist diese Darstellung für die weitere Bilanzanalyse dieser Arbeit ausreichend.

<sup>14</sup>Zu den Aufgaben der Creditreform vgl. das Internetangebot des "Verbandes der Vereine Creditreform e.V." unter <http://www.creditreform.de>.

<sup>15</sup>Klassifikation der Wirtschaftszweige in der Fassung von 2003 (WZ 2003) des Statistischen Bundesamtes Deutschland.

Label	Variable bzw. Variablenbedeutung
ID	Unternehmens-Identifikationsnummer
KRIT	Insolvenzkriterium
JAHR	Bilanzjahr des beobachteten Jahresabschlusses
BRANCHE	Branchenschlüssel <sup>15</sup>
REF	Rechtsform
REK	Rechtskreis
ABSCHLUSS	Abschlussart
SAV	Sachanlagevermögen
GRSTBA	Grundstücke und Bauten
IMMA	Immaterielle Vermögensgegenstände
KASSE	Kassenbestand, Zahlungsmittelbestand
FLL	Forderungen aus Lieferung und Leistung
FORDBET	Forderungen gegenüber Unt. mit denen Beteiligungsverhältnis besteht
VOR	Vorräte
UV	Umlaufvermögen
BILS $\equiv$ GK	Bilanzsumme $\equiv$ Gesamtkapital
EK	Eigenkapital
PRST	Pensionsrückstellungen und andere Aufwendungen für Alterssicherung
KVERB	Kurzfristige Verbindlichkeiten (gesamt)
LVERB	Langfristige Verbindlichkeiten (gesamt)
BAVERB	Bankschulden in den kurz- und langfristigen Verbindlichkeiten
VERBBET	Verbindlichkeiten gegenüber Unt. mit denen Beteiligungsverhältnis besteht
GESDAHR	Gesellschafterdarlehen
VLL	Verbindlichkeiten aus Lieferung und Leistung
U	Umsätze
VERW	Vertriebs- und Verwaltungsaufwand
AFA	Abschreibungen
EBIT	Earnings before Interest and Taxes (Betriebsergebnis)
ZINS	Zinsaufwand
EBT	Earnings before Taxes (Gewinn aus ordentlicher Geschäftstätigkeit)
JE	Jahresergebnis
LAGV	(Lager)- Bestandsveränderung
VERBV	Veränderung der kurz- und langfristigen Verbindlichkeiten
KASSEV	Veränderung Kassenbestand
MA	Anzahl Mitarbeiter

**Tabelle 1:** Im Creditreform-Datensatz enthaltene Jahresabschlussvariablen

Bilanz	
Aktiva	Passiva
A. Anlagevermögen:	A. Eigenkapital
I. Immaterielle Vermögensgegenstände	B. Rückstellungen
II. Sachanlagen	C. Fremdkapital:
III. Finanzanlagen	I. kurzfristige Verbindlichkeiten
B. Umlaufvermögen:	II. langfristige Verbindlichkeiten
I. Vorräte	III. sonst. Verbindlichkeiten
II. Forderungen und sonst. Verm.-gegenstände	
III. Wertpapiere	
IV. Kassenbestand, Schecks, Bankguthaben	
C. Rechnungsabgrenzungsposten	D. Rechnungsabgrenzungsposten
= Bilanzsumme	= Gesamtkapital

**Abbildung 1:** Gliederungsschema der Strukturbilanz für die kleine Kapitalgesellschaft

Auf der *Aktivseite* der Strukturbilanz ist das Vermögen des Unternehmens ausgewiesen. Diese wird untergliedert in die drei Hauptposten Anlagevermögen (AV), Umlaufvermögen (UV) und aktive Rechnungsabgrenzungsposten. Das Anlagevermögen setzt sich aus den Posten Immaterielle Vermögensgegenstände (IMMA), Sach- und Finanzanlagen zusammen. In den Sachanlagen (SAV) sind die evtl. vorhandenen Grundstücke und Bauten (GRSTBA) enthalten. Unter dem Umlaufvermögen werden die Positionen Vorräte (VOR), Forderungen - (darunter Forderungen aus Lieferung und Leistung (FLL) und Forderungen gegen Unternehmen, mit denen ein Beteiligungsverhältnis besteht (FORDBET)) und sonstige Vermögensgegenstände, Wertpapiere, Kassenbestand (KASSE), Schecks und Bankguthaben aufgeführt.

Auf der *Passivseite* ist das dem Unternehmen zur Verfügung stehende Kapital ausgewiesen. Dieses wird unterteilt in Eigenkapital (EK), evtl. Rückstellungen (u.a. Pensionsrückstellungen (PRST)) und das von Dritten befristet zur Verfügung gestellte Fremdkapital (FK). Das Eigenkapital umfasst die Mittel, über die das Unternehmen unbeschränkt verfügen kann, insbesondere das eingebrachte Grund- und Stammkapital.<sup>16</sup> Das Fremdkapital kann weiter untergliedert werden in kurz- (KVERB) und langfristige (LVERB) Verbindlichkeiten. Darin sind je nach Fristigkeit u.a. Bankverbindlichkeiten (BAVERB), Verbindlichkeiten aus Lieferung und Leistung (VLL), Gesellschafterdarlehen (GESDAHR) und Verbindlichkeiten gegenüber Unternehmen, mit denen ein Beteiligungsverhältnis besteht (VERBBET), enthalten. Die Summe aus Eigen- und Fremdkapital bildet das Gesamtkapital bzw. die Bilanzsumme ( $GK \equiv BILS$ ) des Unternehmens. Dieses entspricht ebenfalls der Summe aus Anlage- und Umlaufvermögen der Aktivseite der Bilanz.

In der *Gewinn- und Verlustrechnung* (GuV) werden die Erträge und die Aufwendungen einer Periode - hier eines Geschäftsjahres - einander gegenübergestellt.<sup>17</sup> Die gesetzlich vorgeschriebene Gliederung der GuV nach dem Gesamtkostenverfahren<sup>18</sup> ist im linken Teil der Abb. 2 dargestellt. Die im rech-

<sup>16</sup>Das Eigenkapital dient ebenso als Korrekturposten zur Wahrung der Identität von Aktiva und Passiva.

<sup>17</sup>Vgl. § 275 HGB.

<sup>18</sup>Vgl. § 275 Abs. 2 HGB.

ten Teil dargestellten Zwischenergebnisse stellen die in dieser Arbeit verwendeten Komponenten der sog. *Erfolgsspaltung* dar. Darin werden allgemein wichtige betriebliche Erfolgsgrößen kumuliert und zusammenfassend dargestellt.<sup>19</sup> In den Klammern des linken Teiles der Abb. 2 sind die im hier verwendeten Datensatz vorhandenen absoluten Jahresabschlussvariablen angegeben. Die im rechten Teil gelisteten Bestandteile Betriebsergebnis, Gewinn aus ordentlicher Geschäftstätigkeit und Jahresergebnis sind ebenfalls im Original-Datensatz angegeben. Die Gesamtleistung wird hier aus der Summe der Umsatzerlöse und der Lagerbestandsveränderung errechnet.

GuV	Erfolgsspaltung
Umsatzerlöse (U)	
+/- Bestandsveränderungen (LAGV)	
+ andere aktivierte Eigenleistungen	
	= Gesamtleistung (GL)
+ sonst. betriebliche Erträge	
- Materialaufwand	
- Personalaufwand	
- Abschreibungen (AFA)	
- sonst. betriebliche Aufwendungen	
	= Betriebsergebnis (EBIT)
+ Erträge aus Beteiligungen	
+ andere Erträge des Finanzanlagevermögens	
+ sonst. Zinsen und ähnliche Erträge	
- Abschreibungen auf Wertpapiere	
- Zinsen und ähnliche Aufwendungen (ZINS)	
	= Gewinn aus ordentl. Geschäftstätigkeit (EBT)
+ außerordentliche Erträge	
- außerordentliche Aufwendungen	
- Steuern vom Einkommen und vom Ertrag	
- sonst. Steuern	
= Jahresergebnis (JE)	= Jahresergebnis (JE)

**Abbildung 2:** Gliederungsschema der GuV nach dem Gesamtkostenverfahren und Erfolgsspaltung

## 1.4 Ableitung von relativen Bilanzkennzahlen

Mit der Anwendung von Verhältniszahlen zur Beschreibung der Ertragslage und der finanziellen Stabilität können die relevanten Informationen des Jahresabschlusses gebündelt werden.

Der Vergleich von relativen Kennzahlen hat gegenüber dem Vergleich von absoluten Jahresabschlusswerten zum einen den Vorteil, dass mehrere Informationen zu einer Größe aggregiert werden, und zum anderen, dass hinsichtlich ihrer Größe und anderer grundlegender Kriterien unterschiedliche Unternehmen dennoch miteinander verglichen werden können. Dabei kann jedoch das

<sup>19</sup>Bei der hier dargestellten Erfolgsspaltung wird nicht dem handelsrechtlich vorgeschriebenen Gliederungsschema gefolgt, die das Ergebnis in gewöhnliche und außergewöhnliche Bestandteile aufspaltet (vgl. [Coenenberg 1993], S.251), sondern in Ansätzen dem Vorgehen von [Jerschensky 1998], S.101.

Problem auftreten, dass eine Vielzahl unterschiedlicher Sachverhalte im Ergebnis zu der gleichen Kennzahl führt. Daher werden häufig Kennzahlensysteme verwendet, die einzelne Einflussfaktoren und deren Beziehungen untereinander explizit berücksichtigen.<sup>20</sup>

Im Folgenden können nur die relativen Kennzahlen gebildet werden, die sich mit dem vorhandenen Datenmaterial nach der in den vorherigen Abschnitten durchgeführten Merkmalsbereinigung aus den absoluten Kennzahlen bilden lassen. Im Hinblick auf die gewünschte Abbildung der Vermögens- und der Ertragslage sowie der finanziellen Stabilität wird unterschieden in Vermögensstrukturkennzahlen, Rentabilitätskennzahlen und Liquiditätskennzahlen.

Die *Vermögensstrukturkennzahlen* beziehen sich auf die Passivseite der Bilanz (vgl. Abb. 1) und sollen dazu dienen, die Gefahr einer Überschuldung in die Analyse einzubeziehen. Die *Rentabilitätskennzahlen* dienen dazu, die Ertragskraft des Unternehmens zu beurteilen. Die *Liquiditätskennzahlen* können sinnvoll unterteilt werden in Größen, die den Zahlungsmittelbestand im weitesten Sinne beschreiben und solche Größen, die die Liquidierbarkeit der Vermögensgegenstände beschreiben. Erstere werden durch die ersten drei Liquiditätsgrade beschrieben und letztere durch die Anlage- bzw. Umlaufintensität. Weiterhin werden die Anteile der einzelnen zum Umlaufvermögen gehörenden Positionen (Zahlungsmittelbestand, kurzfristige Forderungen, Vorräte) an der Gesamtposition berechnet und als Liquiditätskennzahlen in die Analyse einbezogen. Die gebildeten relativen Jahresabschlusskennzahlen sind in Tab. 2 dargestellt.

Kennzahl	Label	Berechnung
Eigenkapitalquote	EKQ	EK/GK
Fremdkapitalquote	FKQ	FK/GK
Verschuldungsgrad	VG	FK/EK
Deckungsgrad des Anlagevermögens durch Eigenkapital	DG1	EK/AV
Deckungsgrad des Anlagevermögens durch langfr. Kapital	DG2	$\frac{EK+LVERB}{AV}$
Vermögensaufbau (Konstitution)	KON	AV/UV
Eigenkapitalrentabilität	EKR	EBT/EK
Gesamtkapitalrentabilität	GKR	EBT/GK
(Brutto-) Umsatzrentabilität	BUR	EBT/U
(Netto-) Umsatzrentabilität	NUR	JE/U
Ergebnisrentabilität	JER	JE/GK
Abschreibungsintensität	AFAI	AFA/GK
Anteil Abschreibungen an Gesamtleistung	AFAGL	AFA/GL
Anteil Gesamtleistung an Gesamtkapital	GLGK	GL/GK
Liquidität 1. Grades	LIQ1	KASSE/KVERB
Liquidität 2. Grades	LIQ2	$\frac{KASSE+FLL}{KVERB}$
Liquidität 3. Grades (Current Ratio)	LIQ3	$\frac{KASSE+FLL+VOR}{KVERB}$
Anlagenintensität	AI	AV/GK
Umlaufintensität	UI	UV/GK
Vorratsanteil	VORA	VOR/UV
Forderungsanteil	FLLA	FLL/UV
Kassenanteil	KASA	KASSE/UV

**Tabelle 2:** Relative Jahresabschlusskennzahlen

Die gebildeten 22 relativen Kennzahlen bilden den für die hier durchzufüh-

<sup>20</sup>Vgl. [Schult 2003], S.15.

de Datenanalyse aufgestellten *relativen Kennzahlenkatalog*.<sup>21</sup> Aufgrund von Multikollinearitätsproblemen wurde vor den in den nächsten Abschnitten durchgeführten Schätzungen eine Faktorenanalyse zur Variablenkonsolidierung durchgeführt. Als Ergebnis dieser wurden die Kennzahlen EKR, BUR, LIQ1 und LIQ2 aufgrund hoher Korrelationen dieser Variablen mit einer oder mehreren anderen Kennzahlen aus dem Kennzahlenkatalog entfernt. Ebenso wurden Clusteranalysen durchgeführt, um eine zu starke Heterogenität der Datenmenge zu vermeiden. Letztlich wurde ein ausreißerbereinigtes Cluster von 14.125 kleinen und mittleren Unternehmen identifiziert, welches für alle folgenden Analysen verwendet wird.

## 2 Binäre logistische Regression zur Insolvenzklassifikation

In diesem Abschnitt wird die binäre logistische Regressionsanalyse zur Klassifikation der binären Zielgröße des Insolvenzkriteriums (KRIT) angewendet. Das logistische Regressionsmodell stellt die Wahrscheinlichkeit der Zugehörigkeit eines Objektes zu einer von zwei Klassen einer Zielvariable in linearer Abhängigkeit von den betrachteten Einflussvariablen dar. Im Kontext der Insolvenzanalyse nimmt die Zielvariable im Falle der Insolvenz eines Unternehmens die Ausprägung 1 und im Falle der Solvenz die Ausprägung 0 an und stellt somit eine binäre Variable dar. Das Modell der logistischen Regression lautet formal

$$\Pr(Y_i = 1) = \frac{e^{\mathbf{x}'_i \boldsymbol{\beta}}}{1 + e^{\mathbf{x}'_i \boldsymbol{\beta}}} = \frac{1}{1 + e^{-\mathbf{x}'_i \boldsymbol{\beta}}} \quad , \quad (2.1)$$

d.h. die logistische Transformation der Linearkombination der unabhängigen Variablen<sup>22</sup>  $\mathbf{x}'\boldsymbol{\beta}$  bildet die Wahrscheinlichkeit eines Unternehmens, der Klasse der insolventen Unternehmen zugeordnet zu werden, ab.

Trotz der logistischen Abbildung der Zielvariable ist bei der logistischen Regression zu beachten, dass zwischen den Einflussvariablen und der Insolvenzfähigkeit lediglich lineare Zusammenhänge modelliert werden, da die unabhängigen Variablen letztlich ausschließlich in Form einer linearen Kombination Einfluss auf die Insolvenzwahrscheinlichkeit nehmen.<sup>23</sup> Die logistische Transformation stellt dabei lediglich eine (nichtlineare) Normierung auf das Intervall  $[0, 1]$  in der weiter oben beschriebenen Art dar. Somit werden insbesondere eventuelle nichtlineare Abhängigkeiten der unabhängigen Variablen untereinander bzw. direkte und indirekte nichtlineare Einflüsse einzelner Einflussgrößen auf die Zielvariable nicht berücksichtigt.

Zur Schätzung und anschließenden Prüfung der Prognosegüte wird die Gesamtdatenmenge aufgrund ihrer großen Objektanzahl zunächst ad hoc im

<sup>21</sup>Zu Gründen und Aussagefähigkeit der hier gebildeten relativen Kennzahlen sei auf die betriebswirtschaftliche Literatur verwiesen, u.a. [Coenenberg 1993] und [Wöhe 1996], S.1055 ff.

<sup>22</sup>In diesem Fall der verwendeten relativen Jahresabschlussgrößen, vgl. Abschnitt 1.4.

<sup>23</sup>Vgl. [Anders 1997], S.166.

Verhältnis 70%/30% in eine Trainings- und eine Testmenge aufgeteilt. Dies wird anhand einer einfachen Zufallsziehung durchgeführt. Die im Folgenden verwendeten Daten entsprechen damit einem Datensatz der relativen Jahresabschlusskennzahlen von 14.125 kleinen und mittleren Unternehmen, von denen 13301 solvent und 824 insolvent sind. Somit stehen für die Schätzung 9887 (9310 solvent und 577 insolvent) Trainings- und 4238 (3991 solvent und 247 insolvent) Testdatensätze zur Verfügung.<sup>24</sup>

Durch die stark ungleiche Verteilung der beiden Klassen der Zielvariable in den zur Schätzung verwendeten Daten (nur 6.238% insolvente Unternehmen) ergibt sich das folgende Problem: Der Schätzalgorithmus des Logitmodells minimiert bzw. verringert sukzessive den Klassifikationsfehler in den Trainingsdaten, um die Modelle zu optimieren.<sup>25</sup> Dies führt jedoch dazu, dass das globale Optimum dann erreicht wird, wenn alle insolventen Unternehmen fälschlicherweise als solvent klassifiziert werden, da in diesem Fall die Fehlerquote insgesamt bei einem sonst nicht zu erreichenden Minimum von 0.06238 liegt. Dieses Problem kann auf zwei Arten umgangen werden. Zum Einen kann aus den solventen Unternehmen eine Zufallsstichprobe im Umfang der Anzahl der insolventen Unternehmen gezogen werden, um eine Gleichverteilung hinsichtlich der Zielvariable zu erreichen. Nachteil dieses Verfahrens ist jedoch die dann stark abnehmende Menge an insgesamt zur Schätzung zur Verfügung stehenden Daten. Im Fall der kleinen und mittleren Unternehmen verblieben lediglich 1414 Unternehmen, von denen weiterhin noch eine Testmenge von ca. 30% abgespalten werden müsste. Als zweite Möglichkeit kann versucht werden, durch das Aufstellen einer sog. *Entscheidungsmatrix* die beiden möglichen Klassifikationsfehler durch eine asymmetrische Fehlerfunktion unterschiedlich stark zu bewerten. Im hier untersuchten Fall müsste der Fehler, ein insolventes Unternehmen irrtümlich als solvent zu klassifizieren, höher bewertet werden als umgekehrt ein solventes Unternehmen als insolvent einzustufen. Diese Vorgehensweise hat auch eine inhaltliche Rechtfertigung: Wenn bspw. ein Kreditinstitut anhand des Klassifikationsmodells eine Entscheidung für eine evtl. Kreditbewilligung treffen will, wäre der erstgenannte Fehler auch praktisch als schwerwiegender einzuschätzen, da in dem Fall ein laut Modell insolvenzgefährdetes Unternehmen einen Kredit eingeräumt bekommt, den es evtl. später nicht tilgen kann. Umgekehrt würde einem "gesunden" Unternehmen fälschlicherweise ein Darlehen verweigert werden, was (aus der Sicht des Kreditinstituts) i.d.R. nicht so gravierende Folgen haben wird. Der Nachteil dieser Vorgehensweise ist die durch theoretisch inhaltliche Vorüberlegungen evtl. nicht vollständig zu beseitigende Subjektivität beim Erstellen der Fehlerfunktion, da es immer auch auf die konkrete Sichtweise des Untersuchenden auf das entsprechende Klassifikationsproblem ankommt. In der

<sup>24</sup>Bei der Schätzung des Modells werden allerdings nur die hinsichtlich aller verwendeten Merkmale vollständigen Datensätze der Trainingsmenge verwendet, was zu einer weiteren Verringerung der Datenzahl auf 6412 Unternehmen (6012 solvent und 400 insolvent) führt.

<sup>25</sup>Bei den Lernalgorithmen der Netzwerkmodelle in Abschnitt 3 wird der Fehler in den Validierungsdaten minimiert, was das angesprochene Problem jedoch grundsätzlich nicht beeinflusst, da das Verhältnis von insolventen zu solventen Unternehmen in allen Teildatensätzen annähernd gleich ist.

Praxis müsste somit an dieser Stelle durch eine genauere Analyse der Klassifikationsfehler und ihrer Auswirkungen eine inhaltlich begründete asymmetrische Kostenfunktion erstellt werden, anhand derer die Modelle dann optimiert werden. An dieser Stelle wird vor allem aufgrund des Zieles der möglichst objektiven Vergleichbarkeit verschiedener Modelle die folgende Überlegung angestellt, die zu einer vorzugsweise aufgestellten Kostenmatrix führen kann: Da das ungleiche Verhältnis der Ausprägungen der Zielvariable in den Trainingsdaten für das beschriebene Problem verantwortlich ist, wird die Zahl der solventen zur Zahl der insolventen Unternehmen ins Verhältnis gesetzt und das Ergebnis als Faktor der stärkeren Bewertung des [”Entscheidung Solvent”|Insolvent]-Fehlers verwendet, um so einen Ausgleich der Entscheidungssituationen herbeizuführen. Es ergibt sich für die hier verwendete Datenmenge der kleinen und mittleren Unternehmen in der logistischen Regression die in Tab. 3 dargestellte Kostenmatrix für die vier möglichen Entscheidungssituationen.

Minimiere Kosten für ...		Entscheidung	
		KRIT= 1	KRIT= 0
Ziel	KRIT= 1	0	$\frac{6012}{400} \approx 15$
	KRIT= 0	1	0

**Tabelle 3:** Kostenmatrix für das Insolvenzprognosemodell der Stichprobe von 6412 vollständigen Trainingsdatensätzen der 14.125 Unternehmen.

Die Qualität des geschätzten logistischen Modells wird anhand der Fehlklassifikationsquoten für die möglichen Entscheidungskonstellationen und der damit zusammenhängenden ROC-Kurve evaluiert.<sup>26</sup>

Für die Kostenmatrix aus Tab. 3 ergibt sich das in Tab. 4 dargestellte Klassifikationsergebnis.

	Ziel	Output	Anzahl	Anteil Ziel	Anteil Insgesamt
Train	0	0	7078	0.7603	0.7159
	1	0	268	0.4645	0.0271
	0	1	2232	0.2397	0.2258
	1	1	309	0.5355	0.0313
Test	0	0	3005	0.7529	0.7091
	1	0	115	0.4656	0.0271
	0	1	986	0.2471	0.2327
	1	1	132	0.5344	0.0311

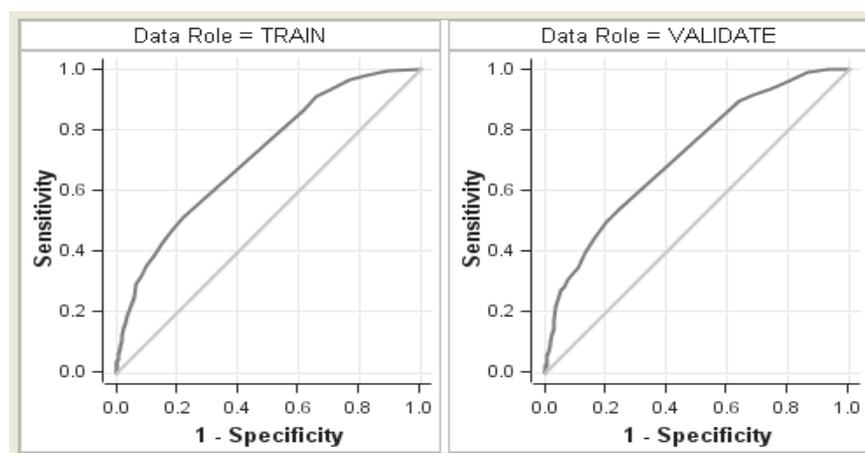
**Tabelle 4:** Klassifikationsergebnisse der binären logistischen Regression für die relativen Jahresabschlussdaten nach Anwendung der Kostenmatrix aus Tab. 3.

Durch die stärkere Bestrafung des [”0”|1]-Fehlers wurde dieser in 268 Fällen begangen, was innerhalb der insolventen Unternehmen einer Fehlerquote von 46.45% und bzgl. aller Unternehmen einer Fehlerquote von 2.71% entspricht.

<sup>26</sup>Zu den Modellbeurteilungsmöglichkeiten von Klassifikationsmodellen vgl. u.a. [Hastie, Tibshirani et al. 2001], S.193 ff.

Der Trainingsfehler beträgt  $FQ_{Train} = 25.29\%$  und der Testfehler  $FQ_{Test} = 25.98\%$ . Dabei kann die - fast einer zufälligen Klassifizierung entsprechende - Fehlerquote innerhalb der insolventen Unternehmen als eindeutig zu hoch angesehen werden. In diesem Zusammenhang ist zu beachten, dass hier je nach einer evtl. unter inhaltlich praktischen Überlegungen veränderten Kostenmatrix vom Anwender ein beliebiger Trade-Off zwischen den Fehlerquoten in den beiden Klassifikationsgruppen erreicht werden kann.

In diesem Zusammenhang kann die sog. *Receiver Operating Characteristic (ROC)*-Kurve zur Modellbeurteilung in Betracht gezogen werden.<sup>27</sup> Für das eben geschätzte logistische Modell ist diese getrennt für Trainings- und Testdaten in Abb. 3 dargestellt.



**Abbildung 3:** ROC-Kurve für das binäre Logit-Modell, Quelle: Model Comparison Results des *SAS Enterprise Miner 5.2*

Auf der horizontalen Achse sind abhängig von der Wahl eines bestimmten Fehlerbewertungsmodells die Anteile der fälschlicherweise als insolvent klassifizierten solventen Unternehmen (*Falsch Positiv (FP)*), welche gleich  $1 -$  der *Spezifität* (Anteil korrekt solvent klassifizierter Unternehmen) des Modells sind, abgetragen. Auf der vertikalen Achse sind diesen gegenüber die *Sensitivitäten* (*Richtig Positiv (TP)*, vgl. Tab. 4), welche den Anteilen der korrekt klassifizierten insolventen Unternehmen entsprechen, dargestellt. Die diagonale Achse entspricht als trivialem Vergleichsfall einem rein zufallsorientierten Gruppieren der Unternehmen in eine der beiden Klassen. Dem Anwender bleibt nun durch die Wahl eines Kostenmodells die Verwendung desjenigen Klassifikationsmodells vorbehalten, welches die beiden Fehlerquoten nach seiner Einschätzung am geeignetsten gegeneinander abwägt.

<sup>27</sup>Die ROC-Kurve stellt die Fehlerbetrachtung getrennt nach Klassen grafisch dar. In dieser werden die Trefferquoten, in der Form  $1 -$ Spezifität (Abszisse) und Sensitivität (Ordinate) einander gegenübergestellt. Zur ROC-Analyse vgl. [Hastie, Tibshirani et al. 2001], S.277f.

### 3 Entwicklung eines künstlichen neuronalen Netzes zur Insolvenzklassifikation

Im diesem Abschnitt wird ein künstliches neuronales Netz (KNN) auf das Problem der Insolvenzprognose angewendet. KNN haben in den letzten Jahren eine erhebliche Bedeutung in der statistischen Datenanalyse erlangt und wurden auch im Bereich der Insolvenzanalyse vielfach genutzt.<sup>28</sup>

Im Gegensatz zur klassischen parametrischen Statistik, die den datengenerierenden Prozess (DGP) formal identifizieren, modellieren und schätzen will, wird in dem Bereich der Künstlichen Intelligenz (KI), dem die KNN zuzuordnen sind, der DGP lediglich imitiert bzw. erlernt. Ziel ist das Erkennen von Mustern in den Daten. Dabei können die inhaltlichen Zusammenhänge jedoch oft nicht mehr inhaltlich interpretiert werden, da das erlernte System bzw. Netzwerk durch die Verknüpfung mehrerer nichtlinearer Funktionsformen meist sehr komplex ist und somit für den Anwender eine Black Box hinsichtlich der Interpretation der Zusammenhänge darstellt.

Um ein Prognosemodell anhand eines KNN zu entwickeln, muss die Netzwerktopologie spezifiziert und eine Trainingstechnik angewandt werden. Anhand den in Abschnitt 1 bereitgestellten Jahresabschlussdaten von zufällig ausgewählten deutschen Unternehmen erlernt das KNN in der sog. Trainingsphase die Zusammenhänge zwischen einer Zielvariable (Insolvenz Kriterium) und den Inputvariablen anhand der präsentierten Datensätze (Muster) durch das iterative Durchlaufen eines vorher festzulegenden Lernverfahrens eigenständig.

Innerhalb eines KNN werden ein oder mehrere Neuronen durch eine bestimmte Netzwerkarchitektur miteinander verbunden und in einer oder mehreren Schichten angeordnet. Sollen durch neuronale Netze funktionale Zusammenhänge zwischen Einflussvariablen und einer Zielvariable abgebildet werden, besteht die erste Neuronenschicht aus den erklärenden Variablen, die dann innerhalb der nächsten Schichten, den sog. verdeckten Schichten (engl.: hidden layer), des KNN nach bestimmten Verarbeitungsvorschriften durch die in den Schichten enthaltenen Neuronen und deren Aktivierungsfunktionen  $\varphi_i(\cdot)$  funktional weiterverarbeitet werden. Die so zunächst entstandenen Outputs der Neuronen der ersten verdeckten Schicht können dann unter Umständen wiederum als Input einer weiteren Neuronenschicht verwendet werden und leisten so einen Beitrag zur Erklärung der Zielvariable des Modells.

Ein KNN lässt sich als Funktion der beobachteten Daten der erklärenden Variablen  $\mathbf{x}$  und der zu schätzenden Gewichte bzw. Netzparameter  $\boldsymbol{\omega}$  wie folgt

---

<sup>28</sup>Vgl. u.a. [Atiya 2001, Becerra et al. 2005, Burger et al. 1996, Giacomini 2003, Graf, Nakhaeizadeh 1993, Jerschensky 1998].

formal beschreiben:

$$\begin{aligned}
 a = f(\mathbf{x}, \boldsymbol{\omega}^{(1)}, \boldsymbol{\omega}^{(2)}) &= \varphi \left( \sum_{j=1}^J \omega_j^{(2)} \left( \underbrace{\varphi_j \left( \sum_{k=0}^K \omega_k^{(1)} x_k \right)}_{a_j} \right) \right) \\
 &= \varphi \left( \sum_{j=1}^J \omega_j^{(2)} \left( \varphi_j(\mathbf{x}'\boldsymbol{\omega}^{(1)}) \right) \right) = \varphi(\mathbf{a}'\boldsymbol{\omega}^{(2)}) \quad . (3.2)
 \end{aligned}$$

In einem KNN werden die  $K$  Einflussvariablen mit den Gewichten  $\boldsymbol{\omega}^{(1)}$  der ersten Schicht (Inputschicht) gewichtet und aufsummiert. Diese Lineartransformation  $\mathbf{x}'\boldsymbol{\omega}^{(1)}$  wird dann in einem zweiten Schritt von  $j = 1, \dots, J$  verdeckten Neuronen in (meist) nichtlinearer Form durch die jeweiligen Aktivierungsfunktionen  $\varphi_j$  weiterverarbeitet. Die Ausgabe  $a_j$  eines verdeckten Neurons wird dann wiederum mit den Gewichten  $\boldsymbol{\omega}^{(2)}$  der zweiten Schicht (erste verdeckte Schicht) gewichtet und linear transformiert an die Ausgabeschicht weitergeleitet. Dort wird die Eingabe  $\mathbf{a}'\boldsymbol{\omega}^{(2)}$  durch die Aktivierungsfunktion  $\varphi$  des Ausgabeneurons transformiert und als Ergebnis  $a$  des KNN ausgegeben. Bei dem in Gl. (3.2) beschriebenen Netz handelt es sich um ein dreilagiges vorwärtsgerichtetes Netzwerk mit einer verdeckten Schicht und einem Ausgabeneuron. Für den Fall weiterer verdeckter Schichten lässt sich die Gl. (3.2) beliebig weiter verschachteln; mehrere Ausgabeneuronen sind ebenfalls möglich.<sup>29</sup>

Durch künstliche neuronale Netze können beliebige nichtlineare stetige Funktionen approximiert werden, da sie die sog. *universelle Approximationseigenschaft* aufweisen. Diese besagt, dass mehrschichtige KNN in der Lage sind, jede beliebige stetige Funktion anzupassen. Dies geht auf den Beweis von [Kolmogorov 1957] zurück, der zeigte, dass jede mehrdimensionale stetige Funktion auf eine Komposition einer endlichen Menge von primitiven eindimensionalen Funktionen zurückgeführt werden kann. Dies bedeutet für ein KNN mit genügend verdeckten Schichten und darin enthaltenen Neuronen, dass die dem Netz zur Verfügung stehenden Daten und damit der Zusammenhang zwischen den Einfluss- und Zielvariablen beliebig genau angenähert werden kann.

Eine wesentliche Eigenschaft von KNN in ihrer Funktion als statistische Lernverfahren besteht des Weiteren darin, dass bei der Modellierung von unbekanntem Zusammenhängen keine explizite Annahme über die funktionale Form des Zusammenhanges aufgestellt werden muss. Dies unterscheidet sie insb. von den klassischen parametrischen Verfahren. Je nach Art der Netzwerktopologie - d.h. der Struktur des Netzes und der Zahl der Schichten und der verdeckten Neuronen - und der verwendeten Aktivierungsfunktionen lassen sich außerdem die

<sup>29</sup>Es ist ersichtlich, dass im Falle des Fehlens von verdeckten Schichten lediglich eine Lineartransformation der Einflussvariablen erfolgt und damit das KNN den klassischen parametrischen Modellen entspricht. Ist die Aktivierungsfunktion des Ausgabeneurons die Identitätsfunktion, bildet das Netz bspw. die lineare Regression, im Falle der Logit-Transformation die logistische Regression ab.

meisten klassischen Modelle, z.B. das lineare oder logistische Regressionmodell, sowie die parametrisch schwer zu schätzenden nichtlinearen Regressionsmodelle durch KNN modellieren.

Die eben beschriebenen Vorteile Neuronaler Netze haben jedoch einen Preis: Eine inhaltliche Interpretation des angepassten Netzes ist fast nicht möglich, da der Weg einer Inputvariable durch das Netz hin zu der Netzausgabe in einer komplexen und vielfach transformierten Weise erfolgt. Insgesamt führen die Vor- und Nachteile von KNN dazu, dass sie zwar als gute Prognosemodelle der Zielvariablen fungieren können, das geschätzte neuronale Modell zur Erklärung der Zusammenhänge zwischen Einfluss- und Zielvariablen jedoch kaum geeignet ist.

Um ein MLP für das konkrete Problem der Insolvenzklassifikation zu entwickeln und zu schätzen, welches die Ergebnisse der klassischen parametrischen Insolvenzmodelle möglichst verbessert, muss zunächst eine geeignete Spezifikation des Netzwerkes, d.h. die Art und Struktur der Schichten und der in diesen enthaltenen Neuronen, erfolgen. Dabei muss grundsätzlich zwischen zwei gegenläufigen Effekten abgewogen werden. Auf der einen Seite kann ein KNN durch eine zu hohe Komplexität nach zu vielen Regeln die Inputvariablen in den gewünschten Output transformieren. Dies führt über den systematischen grundlegenden Zusammenhang hinaus zum Erlernen des nicht systematischen Störeffektes bzw. spezieller Effekte zwischen den Daten, was die Prognosefähigkeit für neue Daten vermindert. Im umgekehrten Fall führt eine zu geringe Netzwerkkomplexität evtl. zu einer zu stark vereinfachten bzw. unzureichenden Abbildung des systematischen Zusammenhanges, was den Erklärungsgehalt des Modells und damit auch die Prognosequalität ebenfalls negativ beeinflusst.<sup>30</sup> Es ist also eine dem Datenumfang und der Problemdefinition angemessene, d.h. sowohl nicht übermäßig komplexe als auch nicht zu einfache Netzwerktopologie zu bestimmen.

Aufgrund der überschaubaren Anzahl der Jahresabschlussvariablen und um dem Ziel der hier durchgeführten Analysen, die Netzwerkmodelle hinsichtlich ihrer Klassifikationsgüte mit den klassischen statistischen Modellen vergleichen zu können, gerecht zu werden, wird ein KNN mit allen zur Verfügung stehenden Variablen erstellt und trainiert.

Im Gegensatz zur Maximum-Likelihood-Schätzung der Regressionsparameter bei der klassischen logistischen Regression<sup>31</sup> erfolgt die Bestimmung der den dortigen Parametern entsprechenden Netzwerkgewichte eines MLP mit dem Backpropagation-Algorithmus durch ein Gradientenabstiegsverfahren.<sup>32</sup> Dabei wird die mittlere quadratische Abweichung zwischen den Netzausgabewerten und den beobachteten Zielwerten des Insolvenz Kriteriums minimiert.

Da das Training einen iterativen Prozess darstellt, in dem sukzessive die Netzwerkparameter hinsichtlich eines Zielkriteriums angepasst werden, muss weiterhin vorher festgelegt werden, wann das Training beendet werden soll. Aufgrund der universellen Approximationseigenschaft eines hinreichend komplexen KNN,

<sup>30</sup>Zu Generalisierungs- bzw. Prognosefähigkeit vgl. u.a. [Hastie, Tibshirani et al. 2001].

<sup>31</sup>Vgl. u.a. [Aldrich, Nelson 1984, Fahrmeir et al. 1996].

<sup>32</sup>Vgl. u.a. [Haykin 1999, Rojas 1993].

jede beliebige nichtlineare Funktion anpassen zu können, ist die Minimierung des Netzwerkfehlers über alle zur Verfügung stehenden Daten nicht als geeignetes Zielkriterium anzusehen. Aus diesem Grund werden hier wiederum die bereits in Abschnitt 2 in zwei Teilmengen aufgeteilten 14.125 Unternehmensdatensätze verwendet. Dabei werden die größere - 70% der Gesamtmenge umfassende - Datenmenge zum Training und die übrige Datenmenge zur Validierung verwendet.

Anhand der dem KNN während des Lernvorganges präsentierten Trainingsmenge  $T = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_T, y_T)\}$  werden die Netzwerkgewichte anhand eines Lernalgorithmus<sup>33</sup> iterativ angepasst. Dabei ist jedoch die Minimierung des Fehlers in den Trainingsdaten nicht das entscheidende Kriterium, da dieser sich bei einer genügend hohen Netzkomplexität so lange immer weiter verringert, bis eine vollständige Erklärung der Trainingsdaten durch das MLP erfolgt ist. Dies würde jedoch wie beschrieben die Prognose- bzw. Generalisierungsfähigkeit des Modells negativ beeinflussen. Die Prognosequalität wird anhand des Fehlers in den Validierungsdaten abgeschätzt, da diese dem KNN während des Trainingsprozesses vorenthalten werden. Dazu wird nach jedem Lernschritt das mit den aktuellen Gewichten spezifizierte Netz auf die Daten der Validierungsmenge  $V = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_V, y_V)\}$  angewendet und es werden für diese die Ausgabewerte der Zielvariable und durch den Vergleich mit den Zielwerten die entsprechenden Fehlerwerte berechnet.

Zu einem bestimmten Zeitpunkt des Trainingsprozesses ist davon auszugehen, dass der Fehler in den Validierungsdaten wieder ansteigt. Dies geschieht dann, wenn das KNN beginnt, die Daten der Trainingsmenge so genau anzunähern, dass über den systematischen Zusammenhang in den Daten hinaus auch un-systematische Störeinflüsse mit angenähert werden. Da der Störeinfluss jedoch nicht beobachtbar bzw. nicht erklärbar ist, kann er in der dem Netz unbekanntem Validierungsmenge auch nicht prognostiziert werden. Zu dieser Prognose kann ausschließlich der systematische Zusammenhang in den Daten verwendet werden. Demzufolge steigt in diesem Fall der sog. *Überanpassung* (engl.: *overfitting*) der durchschnittliche Fehler (Mean Error (*ME*)) einer bestimmten Netzwerkfunktion  $f$

$$ME_f = \frac{1}{V} \sum_{v=1}^V l(y_v - f(\mathbf{x}_v, \boldsymbol{\omega})) \quad , \quad (3.3)$$

gemessen in der Validierungsmenge, wieder an. Nach dem als *Early Stopping* bezeichneten Abbruchkriterium sollte das Training des KNN zu diesem Zeitpunkt beendet werden. Im Folgenden wird als Kriterium für einen Trainingsabbruch das Minimum

$$\min_{\boldsymbol{\omega}} \quad MSE_{Val}(\mathbf{x}_v, \boldsymbol{\omega}) = \frac{1}{V} \sum_{v=1}^V (y_v - f(\mathbf{x}_v, \boldsymbol{\omega}))^2 \quad (3.4)$$

des durchschnittlichen quadratischen Fehlers (Mean Squared Error (*MSE*)) in den Validierungsdaten verwendet. (3.4) stellt eine Schätzung des erwarteten

---

<sup>33</sup>Z.B. eines Gradientenabstiegsverfahrens durch Backpropagation, vgl. u.a. [Bishop 2006, Haykin 1999].

Prognosefehlers eines Modells, hier eines geschätzten KNN, dar. Zwecks einer erhöhten Schätzsicherheit des Prognosefehlers kann des Weiteren die Kreuzvalidierung angewendet werden, bei der der Durchschnitt der Validierungsfehler unterschiedlicher Validierungsmengen als Schätzung verwendet wird.<sup>34</sup>

Im Folgenden wird ein MLP mit einer - drei verdeckte Neuronen enthaltenen - verdeckten Schicht geschätzt.<sup>35</sup> Aus den in Abschnitt 2 angeführten Gründen, vor allem bzgl. der Minimierung des Klassifikationsfehlers über alle Daten, ist die Anwendbarkeit eines neuronalen Netzwerkmodells auf den gesamten Datensatz der 14.125 Unternehmen aufgrund der 15:1-Ungleichverteilung der Merkmalsausprägungen der Zielvariable von solventen zu insolventen Unternehmen auch hier eingeschränkt. Daher und aus Gründen der besseren Vergleichbarkeit mit den Ergebnissen aus Abschnitt 2 wird an dieser Stelle wiederum die in Tab. 3 auf Seite 12 generierte Kostenmatrix zur Fehlergewichtung während der Schätzung des Modells angewendet.

Bei der Schätzung des KNN ergab sich eine minimale Gesamt-Fehlerquote in den Validierungsdaten von  $FQ_{Val} = 20.48\%$ , welche damit um 5.5% unter der entsprechenden Fehlerquote bei der logistischen Regressionsschätzung liegt.<sup>36</sup>

Datensatz	Ziel	Output	Anzahl	Anteil Ziel	Anteil Insgesamt
alle Daten	Train	0	7537	0.8096	0.7623
		1	295	0.5113	0.0298
	Val	0	1773	0.1904	0.1793
		1	282	0.4887	0.0285
		0	3247	0.8136	0.7662
		1	124	0.5020	0.0293
	0	744	0.1864	0.1755	
	1	123	0.4980	0.0290	

**Tabelle 5:** Klassifikationsergebnisse der MLP's mit einer verdeckten Schicht und drei verdeckten Neuronen für die relativen Jahresabschlussdaten, wobei bei der Schätzung wiederum die Kostenmatrix aus Tab. 3 auf Seite 12 verwendet wurde. Die Aufteilung in Trainings- und Validierungsdaten beträgt ebenfalls 70/30.

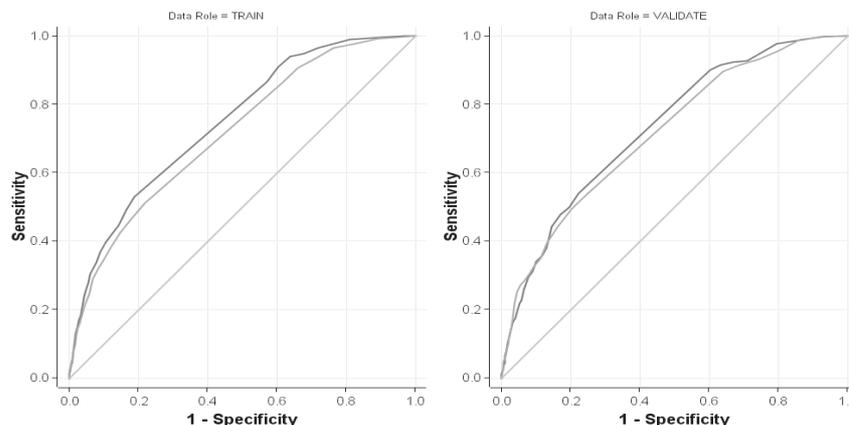
Zur Veranschaulichung der Überlegenheit des auf die gesamten 14.125 Unternehmen trainierten künstlichen neuronalen Netzes sind die ROC-Kurven des dreilagigen MLP und des logistischen Regressionsmodells in Abb. 4 gegenübergestellt. Sowohl in den Trainings- als auch in den Validierungsdaten sind die

<sup>34</sup>Zur Schätzung der Prognosequalität eines Modells und zur Kreuzvalidierung vgl. u.a. [Hastie, Tibshirani et al. 2001], Kap.7.

<sup>35</sup>Es wurden verschiedene Netzwerkarchitekturen mit unterschiedlichen Anzahlen von verdeckten Neuronen verwendet, wobei sich herausstellte, dass eine Zahl von drei verdeckten Neuronen für das vorliegende Klassifikationsproblem ausreichend ist und sich für höhere Anzahlen keine wesentlichen Verbesserungen bzgl. der Klassifikationsergebnisse ergaben. Des Weiteren wird die inhaltliche Interpretation des Netzes mit steigender Anzahl verdeckter Neuronen ungleich schwieriger und auch aus diesem Grund sind drei verdeckte Neuronen als ausreichend anzusehen. Die Anzahl der verdeckten Schichten war durch die verwendete Software *SAS Enterprise Miner 5.2* auf eine beschränkt. Auch kann für das vorliegende Problem vermutet werden, dass sich durch die Verwendung mehrerer verdeckter Schichten keine Verbesserungen der Modelle ergeben würden, u.a. da sich in vielen praktischen Anwendungen künstlicher neuronaler Netze eine verdeckte Schicht als ausreichend erwiesen hat.

<sup>36</sup>Vgl. Tab. 4 auf Seite 12.

Entscheidungshäufigkeiten des MLP fast im gesamten Bereich der fälschlichen Einordnung als insolvent ( $1 - \text{Spezifität}$ ) links bzw. kleiner<sup>37</sup> und im Bereich der korrekten Einordnung als insolvent (Sensitivität) oberhalb und damit höher als beim logistischen Modell.<sup>38</sup>



**Abbildung 4:** Vergleich der ROC-Kurven für das Logit-Modell (helle Kurven) und das MLP mit drei verdeckten Neuronen in einer verdeckten Schicht (dunkle Kurven) in den Trainings- und Validierungsdaten bei Anwendung der Kostenmatrix aus Tab. 3, Quelle: Model Comparison Results des *SAS Enterprise Miner 5.2*.

## 4 Zusammenfassung und Ausblick

In dieser Arbeit wurde eine empirische externe Bilanzanalyse durchgeführt, indem statistische Klassifikationsmodelle entwickelt und zur Insolvenzprognose verwendet wurden. Dazu wurden zunächst aus den Jahresabschlussdaten von 14.125 zufällig ausgewählten deutschen kleinen und mittleren Unternehmen relative Bilanzkennzahlen zur Abbildung der Vermögens-, Finanz- sowie Liquiditätssituation abgeleitet. Anschließend wurde innerhalb der statistischen Analyse insb. die klassische parametrische Methode der binären logistischen Regression mit einem dreilagigen künstlichen neuronalen Netz bzgl. der Klassifikationsergebnisse verglichen. Im Ergebnis erwies sich für die bzgl. der Ausprägungen der Zielvariable stark ungleich verteilte Menge von 14.125 Unternehmen das KNN der parametrischen Logitanalyse als überlegen. So konnte anhand der ROC-Analyse festgestellt werden, dass für fast alle Fehlerbewertungsmodelle anhand verschiedener Kostenmatrizen durch das KNN höhere Trefferquoten für die bei-

<sup>37</sup>Und damit für die korrekte Einordnung als solvent (Spezifität) rechts bzw. größer.

<sup>38</sup>Vgl. die Werte für die Klassifikationsanteile innerhalb der Zielwerte im oberen Teil der Tab. 5.

den Entscheidungskonstellationen erzielt wurden.<sup>39</sup> Nachteil einer Netzwerkanalyse ist jedoch die fehlende Interpretationsmöglichkeit des geschätzten Netzwerkmodells, um die zwischen den als Netzinput wirkenden relativen Bilanzkennzahlen und der erfolgten Insolvenzklassifikation herrschenden Zusammenhänge inhaltlich beurteilen zu können. Hierzu sind weitere Forschungsaktivitäten zu unternehmen. Weiterhin ist zu untersuchen, inwiefern andere Methoden der statistischen Lerntheorie wie bspw. die in letzter Zeit stark an Bedeutung gewonnenen Support-Vektor-Maschinen eine Insolvenzanalyse unterstützen bzw. evtl. verbessern können.

## Literatur

- [Aldrich, Nelson 1984] Aldrich, J., Nelson, F.: Linear Probability, Logit and Probit Models, Quantitative Applications in the Social Sciences 45, SAGE University Press, L.A. 1984.
- [Anders 1997] Anders, U.: Statistische Neuronale Netze, Vahlen, München 1997.
- [Anderson 1982] Anderson, J.: Logistic Discrimination, in: Krishnaiah, P., Kanal, L.: Handbook of Statistics, Vol. 2, North-Holland Publishing Co., Amsterdam 1982.
- [Atiya 2001] Atiya, A.: Bankruptcy Prediction for Credit Risk Using Neural Networks: A Survey and New Results, in IEEE Transactions on Neural Networks 12.4, 2001.
- [Bartlett 1999] Bartlett, P.: Neural Network Learning, Cambridge Univ. Press 1999.
- [Becerra et al. 2005] Becerra, V., Kawakami, R., Galvao, H., Abou-Seada, M.: Neural and Wavelet Network Models for Financial Distress Classification, Data Mining and Knowledge Discovery 11.1, 2005.
- [Bishop 1995] Bishop, C.: Neural Networks for Pattern Recognition, Oxford Univ. Press 1995.
- [Bishop 2006] Bishop, C.: Pattern Recognition and Machine Learning, Springer, N.Y. 2006.
- [Brockmann 2005] Brockmann, H.: KMU. Definition kleiner und mittlerer Unternehmen der Europäischen Kommission, in: Wirtschaftswissenschaftliches Studium (WiSt), S.39 ff., Beck, München 2005.
- [Burger et al. 1996] Burger, A., Schellberg, B.: Neuronale Netze in der Jahresabschlussanalyse, in: Beiträge zur theoretischen BWL, 1996.

---

<sup>39</sup>Vgl. Abb. 4.

- [Coenenberg 1993] Coenenberg, A.: Jahresabschluss und Jahresabschlussanalyse - Betriebswirtschaftliche, handelsrechtliche und steuerrechtliche Grundlagen, Schäffer-Poeschel, Stuttgart 1993.
- [Fahrmeir et al. 1996] Fahrmeir, L., Hamerle, A., Tutz, G.: Multivariate statistische Verfahren, 2. Auflage, de Gruyter, Berlin 1996.
- [Giacomini 2003] Giacomini, E.: Neural Networks in Quantitative Finance, Master Thesis, Fachgebiet Statistik und Ökonometrie, Humboldt Universität zu Berlin, 2003.
- [Graf, Nakhaeizadeh 1993] Graf, J., Nakhaeizadeh, G.: Credit Scoring Based on Neural and Machine Learning, in: Plantamura, V., Soucek, B., Visaggio, V.G.: Frontier Decision Support Concepts, John Wiley, N.Y. 1993.
- [Handl 2002] Handl, A.: Multivariate Analysemethoden, Springer, Berlin 2002.
- [Hastie, Tibshirani et al. 2001] Hastie, T., Tibshirani, R., Friedman, J.: The Elements of Statistical Learning. Data Mining, Inference and Prediction, Springer, N.Y. 2001.
- [Haykin 1999] Haykin, S.: Neural Networks. A Comprehensive Foundation, Prentice Hall, New Jersey 1999.
- [Hofmann 1977] Hofmann, R.: Bilanzkennzahlen, Industrielle Bilanzanalyse und Bilanzkritik, 4. Auflage, Gabler-Verlag, Wiesbaden 1977.
- [Jerschensky 1998] Jerschensky, A.: Messung des Bonitätsrisikos von Unternehmen: Krisendiagnose mit künstlichen neuronalen Netzen, IDW, Düsseldorf 1998.
- [Johnson et al. 2002] Johnson, R., Wichern, D.: Applied Multivariate Statistical Analysis, 5. Auflage, Prentice Hall, New Jersey 2003.
- [Kolmogorov 1957] Kolmogorov, A.: On the Representation of Continuous Functions of Several Variables by Superposition of Continuous Functions of One Variable and Addition, Doklady Akademiia Nauk SSSR 114 (5), S. 953-956, 1957.
- [Lange 2003] Lange, C.: Neuronale Netze in der wirtschaftswissenschaftlichen Prognose und Modellgenerierung, Physica, Heidelberg 2003.
- [Leffson 1984] Leffson, U.: Bilanzanalyse, 3. Auflage, Poeschel, Stuttgart 1984.
- [Mardia et al. 1979] Mardia, K., Kent, J., Bibby, J.: Multivariate Analysis, Academic Press, London 1979.
- [McLachlan 1992] McLachlan, G.: Discriminant Analysis and Statistical Pattern Recognition, John Wiley, N.Y. 1992.

- [Oerthel, Tuschl 1995] Oerthel, F., Tuschl, S.: Statistische Datenanalyse mit dem Programmpaket SAS, Oldenbourg, München 1995.
- [Pellens et al. 2004] Pellens, B., Fülbier, R., Gassen, J.: Internationale Rechnungslegung, 5. Auflage, Schäffer Poeschel, Stuttgart 2004.
- [Rehkugler et al. 1994] Rehkugler, H., Zimmermann, H.: Neuronale Netze in der Ökonomie, Vahlen, München 1994.
- [Rencher 1995] Rencher, A.: Methods of Multivariate Analysis, John Wiley, N.Y 1995.
- [Rencher 1998] Rencher, A.: Multivariate Statistical Inference and Applications, John Wiley, N.Y. 1998.
- [Ripley 1996] Ripley, B.: Pattern Recognition and Neural Networks, Cambridge Univ. Press 1996.
- [Rojas 1993] Rojas, R.: Theorie der Neuronalen Netze. Eine systematische Einführung, Springer, Berlin 1993.
- [Schott 1988] Schott, G.: Kennzahlen, Instrument der Unternehmensführung, 5. Auflage, Forkel-Verlag, Wiesbaden 1988.
- [Schult 2003] Schult, E.: Bilanzanalyse - Möglichkeiten und Grenzen externer Unternehmensbeurteilung, 11. Auflage, Erich Schmidt Verlag, Berlin 2003.
- [Urban 1993] Urban, D.: Logit-Analyse, Gustav Fischer, Stuttgart 1993.
- [Wöhe 1996] Wöhe, U.: Allgemeine Betriebswirtschaftslehre, 19. Auflage, Vahlen, München 1996.
- [Yoon et al. 1993] Yoon, Y., Swales, G., Margavio, T.: A Comparison of Discriminant Analysis Versus Artificial Neural Networks, Journal of Operational Research 44, S. 51-60, 1993.

## SFB 649 Discussion Paper Series 2007

For a complete list of Discussion Papers published by the SFB 649, please visit <http://sfb649.wiwi.hu-berlin.de>.

- 001 "Trade Liberalisation, Process and Product Innovation, and Relative Skill Demand" by Sebastian Braun, January 2007.
- 002 "Robust Risk Management. Accounting for Nonstationarity and Heavy Tails" by Ying Chen and Vladimir Spokoiny, January 2007.
- 003 "Explaining Asset Prices with External Habits and Wage Rigidities in a DSGE Model." by Harald Uhlig, January 2007.
- 004 "Volatility and Causality in Asia Pacific Financial Markets" by Enzo Weber, January 2007.
- 005 "Quantile Sieve Estimates For Time Series" by Jürgen Franke, Jean-Pierre Stockis and Joseph Tadjuidje, February 2007.
- 006 "Real Origins of the Great Depression: Monopolistic Competition, Union Power, and the American Business Cycle in the 1920s" by Monique Ebell and Albrecht Ritschl, February 2007.
- 007 "Rules, Discretion or Reputation? Monetary Policies and the Efficiency of Financial Markets in Germany, 14th to 16th Centuries" by Oliver Volckart, February 2007.
- 008 "Sectoral Transformation, Turbulence, and Labour Market Dynamics in Germany" by Ronald Bachmann and Michael C. Burda, February 2007.
- 009 "Union Wage Compression in a Right-to-Manage Model" by Thorsten Vogel, February 2007.
- 010 "On  $\sigma$ -additive robust representation of convex risk measures for unbounded financial positions in the presence of uncertainty about the market model" by Volker Krätschmer, March 2007.
- 011 "Media Coverage and Macroeconomic Information Processing" by Alexandra Niessen, March 2007.
- 012 "Are Correlations Constant Over Time? Application of the CC-TRIG<sub>t</sub>-test to Return Series from Different Asset Classes." by Matthias Fischer, March 2007.
- 013 "Uncertain Paternity, Mating Market Failure, and the Institution of Marriage" by Dirk Bethmann and Michael Kvasnicka, March 2007.
- 014 "What Happened to the Transatlantic Capital Market Relations?" by Enzo Weber, March 2007.
- 015 "Who Leads Financial Markets?" by Enzo Weber, April 2007.
- 016 "Fiscal Policy Rules in Practice" by Andreas Thams, April 2007.
- 017 "Empirical Pricing Kernels and Investor Preferences" by Kai Detlefsen, Wolfgang Härdle and Rouslan Moro, April 2007.
- 018 "Simultaneous Causality in International Trade" by Enzo Weber, April 2007.
- 019 "Regional and Outward Economic Integration in South-East Asia" by Enzo Weber, April 2007.
- 020 "Computational Statistics and Data Visualization" by Antony Unwin, Chun-houh Chen and Wolfgang Härdle, April 2007.
- 021 "Ideology Without Ideologists" by Lydia Mechtenberg, April 2007.
- 022 "A Generalized ARFIMA Process with Markov-Switching Fractional Differencing Parameter" by Wen-Jen Tsay and Wolfgang Härdle, April 2007.

**SFB 649, Spandauer Straße 1, D-10178 Berlin**  
**<http://sfb649.wiwi.hu-berlin.de>**

This research was supported by the Deutsche  
Forschungsgemeinschaft through the SFB 649 "Economic Risk".



- 023 "Time Series Modelling with Semiparametric Factor Dynamics" by Szymon Borak, Wolfgang Härdle, Enno Mammen and Byeong U. Park, April 2007.
- 024 "From Animal Baits to Investors' Preference: Estimating and Demixing of the Weight Function in Semiparametric Models for Biased Samples" by Ya'acov Ritov and Wolfgang Härdle, May 2007.
- 025 "Statistics of Risk Aversion" by Enzo Giacomini and Wolfgang Härdle, May 2007.
- 026 "Robust Optimal Control for a Consumption-Investment Problem" by Alexander Schied, May 2007.
- 027 "Long Memory Persistence in the Factor of Implied Volatility Dynamics" by Wolfgang Härdle and Julius Mungo, May 2007.
- 028 "Macroeconomic Policy in a Heterogeneous Monetary Union" by Oliver Grimm and Stefan Ried, May 2007.
- 029 "Comparison of Panel Cointegration Tests" by Deniz Dilan Karaman Örsal, May 2007.
- 030 "Robust Maximization of Consumption with Logarithmic Utility" by Daniel Hernández-Hernández and Alexander Schied, May 2007.
- 031 "Using Wiki to Build an E-learning System in Statistics in Arabic Language" by Taleb Ahmad, Wolfgang Härdle and Sigbert Klinke, May 2007.
- 032 "Visualization of Competitive Market Structure by Means of Choice Data" by Werner Kunz, May 2007.
- 033 "Does International Outsourcing Depress Union Wages? by Sebastian Braun and Juliane Scheffel, May 2007.
- 034 "A Note on the Effect of Outsourcing on Union Wages" by Sebastian Braun and Juliane Scheffel, May 2007.
- 035 "Estimating Probabilities of Default With Support Vector Machines" by Wolfgang Härdle, Rouslan Moro and Dorothea Schäfer, June 2007.
- 036 "Yxilon – A Client/Server Based Statistical Environment" by Wolfgang Härdle, Sigbert Klinke and Uwe Ziegenhagen, June 2007.
- 037 "Calibrating CAT Bonds for Mexican Earthquakes" by Wolfgang Härdle and Brenda López Cabrera, June 2007.
- 038 "Economic Integration and the Foreign Exchange" by Enzo Weber, June 2007.
- 039 "Tracking Down the Business Cycle: A Dynamic Factor Model For Germany 1820-1913" by Samad Sarferaz and Martin Uebele, June 2007.
- 040 "Optimal Policy Under Model Uncertainty: A Structural-Bayesian Estimation Approach" by Alexander Kriwoluzky and Christian Stoltenberg, July 2007.
- 041 "QuantNet – A Database-Driven Online Repository of Scientific Information" by Anton Andriyashin and Wolfgang Härdle, July 2007.
- 042 "Exchange Rate Uncertainty and Trade Growth - A Comparison of Linear and Nonlinear (Forecasting) Models" by Helmut Herwartz and Henning Weber, July 2007.
- 043 "How do Rating Agencies Score in Predicting Firm Performance" by Gunter Löffler and Peter N. Posch, August 2007.

**SFB 649, Spandauer Straße 1, D-10178 Berlin**  
<http://sfb649.wiwi.hu-berlin.de>

This research was supported by the Deutsche  
 Forschungsgemeinschaft through the SFB 649 "Economic Risk".



- 044 "Ein Vergleich des binären Logit-Modells mit künstlichen neuronalen Netzen zur Insolvenzprognose anhand relativer Bilanzkennzahlen" by Ronald Franken, August 2007.

**SFB 649, Spandauer Straße 1, D-10178 Berlin**  
**<http://sfb649.wiwi.hu-berlin.de>**

This research was supported by the Deutsche  
Forschungsgemeinschaft through the SFB 649 "Economic Risk".

