

Härdle, Wolfgang K.; Moro, Rouslan A.; Schäfer, Dorothea

Article

Support Vector Machines: eine neue Methode zum Rating von Unternehmen

DIW Wochenbericht

Provided in Cooperation with:

German Institute for Economic Research (DIW Berlin)

Suggested Citation: Härdle, Wolfgang K.; Moro, Rouslan A.; Schäfer, Dorothea (2004) : Support Vector Machines: eine neue Methode zum Rating von Unternehmen, DIW Wochenbericht, ISSN 1860-8787, Deutsches Institut für Wirtschaftsforschung (DIW), Berlin, Vol. 71, Iss. 49, pp. 759-765

This Version is available at:

<https://hdl.handle.net/10419/151343>

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.

Support Vector Machines – Eine neue Methode zum Rating von Unternehmen

Inhalt

Support Vector Machines – Eine neue Methode zum Rating von Unternehmen
Seite 759

Wolfgang K.
Härde
stat@wiwi.hu-berlin.de

Rouslan Moro
rmoro@diw.de

Dorothea Schäfer
dschaefer@diw.de

Die Rekordzahlen an Unternehmensinsolvenzen, die schlechte Ertragslage der deutschen Kreditinstitute in den vergangenen Jahren und der von Basel II ausgehende Druck zur Verwendung von realitätsnahen Ausfallwahrscheinlichkeiten haben es überdeutlich gemacht: Der Bedarf an leistungsfähigen Insolvenzprognosemodellen ist immens. Mehr denn je suchen Banken, aber auch andere Finanzdienstleister wie Venture-Capital-Firmen nach geeigneten Methoden, um möglichst treffsicher das Risiko abschätzen zu können, mit dem ein Unternehmen während einer gegebenen Vorhersageperiode insolvent wird.

Fehleinschätzungen bei den Ausfallraten von Krediten haben nicht nur einzelwirtschaftliche Auswirkungen. Auch die Stabilität des Finanzsystems und damit die Liquiditätsversorgung der Volkswirtschaft hängen entscheidend davon ab, ob Banken ihre Kreditrisiken richtig einschätzen und eine adäquate Risikovorsorge treffen können. Forschungsarbeiten des DIW Berlin in Zusammenarbeit mit dem Center for Applied Statistics and Economics (CASE, Humboldt-Universität zu Berlin) haben ergeben, dass Support Vector Machines, kurz SVMs, den Anforderungen an qualitativ hochstehende Insolvenzprognosemodelle in besonderer Weise gerecht werden.¹ Support Vector Machines als Instrument zur Vorhersage von Insolvenzen zu nutzen ist neu. Bei Klassifikationsproblemen in der Biometrie (Früherkennung von Krankheiten) und im Bereich der Mustererkennung werden SVMs jedoch bereits seit geraumer Zeit mit guten Ergebnissen eingesetzt.

Im Jahre 2003 wurden in Deutschland über 39 000 Insolvenzverfahren für Unternehmen eröffnet.² 2002 war die Anzahl der Unternehmensinsolvenzen noch um 19 % geringer. Parallel zum Anstieg der Insolvenzen hat sich die Ertragslage im deutschen Bankensektor in den vergangenen Jahren erheblich verschlechtert.³ Mitverantwortlich dafür waren die hohen Kreditausfälle. 2003 betrugen die durchschnittlichen Forderungen (einschließlich Bankforderungen) pro Unternehmensinsolvenz 800 000 Euro. Die Schäden beschränken sich jedoch nicht nur auf die unmittelbaren Kreditausfälle, sie ziehen auch eine Reihe von indirekten Kosten nach sich. Ausfälle erfordern Wertberichtigungen, verzehren das Eigenkapital der Kreditgeber, verschlechtern die Bilanzstruktur und erhöhen die Refinanzierungskosten der Banken. Bei vergleichsweise hohen Ausfall-

¹ Das Forschungsprojekt wird vom Deutschen Akademischen Austauschdienst finanziell gefördert.

² Statistisches Bundesamt: Pressemitteilung zu den Insolvenzen von Unternehmen und Privatpersonen im Jahr 2003. Wiesbaden 2004 (www.destatis.de/presse/deutsch/pm2004/p1280132.htm).

³ Deutsche Bundesbank: Die Ertragslage der deutschen Kreditinstitute im Jahre 2003. Monatsbericht September 2004; dies.: Die Ertragslage der deutschen Kreditinstitute im Jahre 2002, Monatsbericht September 2003; dies.: Die Ertragslage der deutschen Kreditinstitute im Jahre 2001, Monatsbericht September 2002.

Tabelle 1

Ratingklassen und Risikoprämien

In %

Ratingklassen (S & P)	Einjährige Ausfallwahrscheinlichkeit	Risikozuschläge
AAA	0,01	0,75
AA	0,02 bis 0,04	1,00
A+	0,05	1,50
A	0,08	1,80
A-	0,11	2,00
BBB	0,15 bis 0,40	2,25
BB	0,65 bis 1,95	3,50
B+	3,20	4,75
B	7,00	6,50
B-	13,00	8,00
CCC	> 13	10,00
CC		11,50
C		12,70
D		14,00

Quellen: Aswath Damodaran: Investment Valuation. 2. Aufl. New York 2002; Karsten Füsler: Basel II – was muss der Mittelstand tun? 2002.

DIW Berlin 2004

wahrscheinlichkeiten ist die Kalkulation entsprechender Risikoprämien erforderlich, damit der Kredit kostendeckend vergeben werden kann (Tabelle 1). Die Unterschätzung der Ausfallwahrscheinlichkeit bedeutet, dass die Bank einen Teil des Insolvenzrisikos trägt, ohne dafür die angemessene Risikoprämie zu erheben. Ein Teil dieser Schäden könnte vermieden werden, wenn Bank- und Finanzinstitute flächendeckend geeignete Frühwarnsysteme in Form eines leistungsfähigen Insolvenzprognosemodells installierten.

Die Nachfrage nach belastbaren und treffsicheren Prognoseverfahren wird allerdings nicht nur durch die Erfordernisse des Risikomanagements, sondern auch durch die Bankenaufsicht gesteuert. Die jüngst vom Baseler Ausschuss für Bankenaufsicht verabschiedeten Regelungen (Basel II) sehen die bonitätsabhängige Eigenkapitalunterlegung von Krediten vor. Das setzt die realitätsnahe Einschätzung der Ausfallwahrscheinlichkeit der Unternehmenskunden voraus und erfordert die Nutzung leistungsfähiger Insolvenzprognosemodelle. Tabelle 2 zeigt die Veränderung der Unterlegung gegenüber Basel I beispielhaft für einen Firmenkredit aus dem Segment der Kredite an klein- und mittelständische Unternehmen (KMU-Segment). Die Eigenkapitalanforderungen sind anhand der veröffentlichten Formeln zur Berechnung der KMU-Risikogewichte ermittelt worden.⁴

Zurzeit ist die Treffsicherheit bei der Vorhersage von Unternehmensinsolvenzen nicht zufriedenstellend. Angesichts gewaltiger Fortschritte in der Computertechnologie, neuer Erkenntnisse in der statistischen Theorie und der Verfügbarkeit weitaus größerer Datensätze als früher scheint die Verbesserung der Prognosequalität jedoch nur eine Frage der Zeit. SVMs, eine neuere Entwicklung der Theorie des statistischen Lernens, sind in dieser Hinsicht besonders vielversprechend.⁵

Insolvenzprognose durch Support Vector Machines

Bei einem Klassifizierungsproblem wie der Zuordnung eines Unternehmens zur Gruppe der insolventen bzw. solventen Unternehmen besteht das Risiko in der Fehlklassifikation. Das Unternehmen kann entweder als solvent eingestuft werden, obwohl es später insolvent wird, oder es kann als insolvent klassifiziert werden, obwohl es in der Vorhersageperiode solvent bleibt. Die „wahre“ Klasse des Unternehmens, *solvent* oder *insolvent*, ist unbekannt. Ein Insolvenzprognosemodell versucht die unbekannte Klasse des Unternehmens anhand seiner Merkmale vorherzusagen.

Als Unternehmensmerkmale werden im Allgemeinen Bilanzkennziffern (z. B. *Umsatzrendite*, *Eigenkapitalquote*, *Verschuldungsgrad*, *Liquiditätsgrad*)

⁴ Basel Committee on Banking Supervision (BCBS, 2004). Basel II: International Convergence of Capital Measurement and Capital Standards: A Revised Framework Basel Committee. Publications No. 107, Juni 2004 (www.bis.org/publ/bcbs107b.pdf).

⁵ Für mehr Informationen über SVMs und die Testergebnisse vgl. K. Wolfgang Härdle, Rouslan Moro und Dorothea Schäfer: Predicting Bankruptcy with Support Vector Machines. DIW Discussion Paper No. 416. Berlin 2004 (www.diw.de/english/dasinstitut/forschgruppen/finanzmarkt/docs/discussion_papers.html). Erscheint in: Pavel Cizek, Wolfgang Härdle und Rafal Weron (Hrsg.): Statistical Tools in Finance. Springer Verlag, Berlin 2005.

Tabelle 2

Ratingklassen und Eigenkapitalanforderungen bei KMU-Krediten¹

In %

Ratingklassen (S & P)	Einjährige Ausfallwahrscheinlichkeit	Eigenkapitalanforderungen (Basel I)	Eigenkapitalanforderungen (Basel II)
AAA	0,01	8,00	0,47
AA	0,02 bis 0,04	8,00	0,71 bis 1,08
A+	0,05	8,00	1,23
A	0,08	8,00	1,63
A-	0,11	8,00	1,97
BBB	0,15 bis 0,40	8,00	2,36 bis 3,96
BB	0,65 bis 1,95	8,00	4,92 bis 7,04
B+	3,20	8,00	7,93
B	7,00	8,00	10,13
B-	13,00	8,00	13,04
CCC	> 13	8,00	> 13,04
CC		8,00	
C		8,00	
D		8,00	

¹ Die Eigenkapitalunterlegung gilt für einen KMU-Kredit von über 1 Mill. Euro an ein Unternehmen, das beim Jahresumsatz die Grenze von 5 Mill. Euro nicht überschreitet.

Quellen: Karsten Füsler: Basel II – was muss der Mittelstand tun? 2002; Berechnungen des DIW Berlin.

DIW Berlin 2004

und Branchendaten verwendet. Darüber hinaus können auch andere Informationen wie *corporate governance principles*, die *Berufsprofile von Vorständen* oder *kürzlich erfolgte Fusionen* verarbeitet werden. „Weiche“ Faktoren wie *Umsetzung strategischer Ziele*, *Managementqualität*, *Nachfolgeregelung* und *Innovationsfähigkeit* können ebenfalls in das Prognosemodell einbezogen werden. Bei den weichen Faktoren besteht jedoch häufig das Problem der mangelnden Datenverfügbarkeit.

Die prinzipielle Idee der SVMs lässt sich einfach beschreiben. Das Risiko, ein Unternehmen falsch zu klassifizieren, besteht aus zwei Komponenten: dem Risiko, mit einem gegebenen Modell das Unternehmen anhand seiner Daten falsch einzustufen, und dem Risiko, auf die Daten ein falsches Modell anzuwenden. Die meisten traditionellen Methoden zur Insolvenzvorhersage blenden den zweiten Teil des Prognoseproblems aus. Sie arbeiten mit a priori festgelegten Prognosefunktionen, das heißt, das Vorhersagemodell ist von vornherein fixiert und wird nicht durch die gegebene Datenlage bestimmt. Häufig beschränkt man sich dabei auf vergleichs-

weise einfache Prognosemodelle und nimmt an, dass der künftige Zustand des Unternehmens – *Insolvenz* oder *Solvenz* – von einer linearen Kombination der Unternehmensmerkmale abhängt. Die Auswertung von Unternehmensdaten hat allerdings gezeigt, dass die Beziehung zwischen einzelnen Unternehmensmerkmalen und Insolvenzwahrscheinlichkeit oft nichtlinear ist. So führen sowohl zu niedrige als auch zu hohe Gewinne zu erhöhter Insolvenzanfälligkeit (Abbildung 1).⁶ Sehr hohe Gewinne können auch ein Zeichen dafür sein, dass das Unternehmen kaum Investitionen durchführt und gerade dabei ist, seine Substanz aufzuzehren. Vergleichsweise einfache Modelle bergen folglich die Gefahr, dass a priori Zusammenhänge zwischen Merkmalen und (späterem) Zustand des Unternehmens spezifiziert werden, die nicht realitätsgerecht sind. Die Spezifikation unzutreffender Abhängigkeiten beeinträchtigt jedoch die Trefferquote des Verfahrens.


SVMs verzichten auf die A-priori-Spezifikation des Prognosemodells und beziehen beide Komponenten des Risikos der Fehlklassifikation in den Optimierungsprozess mit ein. Sie wählen anhand der Daten die geeignete Prognosefunktion aus und minimieren dann innerhalb des gewählten Modells das Risiko, aus den Unternehmensdaten eine Fehlklassifikation abzuleiten.⁷

Vorteile gegenüber gängigen Insolvenzprognosemodellen

Trotz ihrer guten Resultate in anderen Klassifikationsproblemen spielen SVMs bei der Insolvenzprognose bislang keine Rolle.⁸ Hier dominieren in der Praxis die Diskriminanzanalyse, die Logit- und Probitanalyse sowie optionsbasierte Modelle (Kasten). Die Vorteile der SVMs gegenüber diesen etablierten Methoden liegen im Wesentlichen in ihrer ausgesprochen flexiblen Struktur, ihrer soliden theoretischen Basis und der Nichtnotwendigkeit von Annahmen über die Verteilung der solventen und insolventen Unternehmen. Die Eigenschaften von SVMs lassen sich aus der statistischen Lerntheorie herleiten. Anders als neuronale Netze produzieren sie grundsätzlich eindeutige Ergebnisse

Abbildung 1

Fünffährige kumulierte Ausfallwahrscheinlichkeit für US-Publikumsgesellschaften 1980 bis 1990 als Funktion von Gewinnkennzahlen



Quelle: Eric Falkenstein: Riskcalc for Private Companies: Moody's Default Model. Moody's Investors Service. 2000.

DIW Berlin 2004

⁶ Eric Falkenstein: Riskcalc for Private Companies: Moody's Default Model. Moody's Investors Service. 2000 (www.defaultrisk.com/pp_score_06.htm).

⁷ Marlene Müller und Bernd Rönz: Credit Scoring Using Semiparametric Methods. In: Jörg Franke, Wolfgang K. Härdle und Gerhard Stahl (Hrsg.): Measuring Risk in Complex Stochastic Systems. Berlin 2000.

⁸ Seit einigen Jahren werden SVMs von der U.S.-Post erfolgreich zur Klassifizierung von Ziffern in handgeschriebenen Adressen eingesetzt. Sie haben sich in der medizinischen Diagnostik bewährt und sind extrem leistungsfähig bei der Erkennung von Mustern. Konkrete Implementierungen haben gezeigt, dass SVMs jeweils treffsicherer arbeiten als z. B. neuronale Netze.

Kasten

Gängige Insolvenzprognoseverfahren

Parametrische Methoden

... machen explizite Annahmen über das Aussehen der Klassifikationsfunktion. Sie sind dann gut geeignet zur Prognostizierung der Insolvenz, wenn *a priori* bekannt ist, welche Abhängigkeiten zwischen den Prädiktoren (z. B. Bilanzkennziffern) bestehen. Sie können jedoch keine Effekte abbilden, die nicht *a priori*, d. h. bei der Wahl der Klassifizierungsfunktion, antizipiert wurden.

Nichtparametrische Methoden

... machen keine expliziten Annahmen über das Aussehen der Klassifizierungsfunktion. Diese Eigenschaft ermöglicht es zwar, das Modell besser an die Daten anzupassen, birgt jedoch auch die Gefahr des Verlustes an Interpretierbarkeit. Nichtparametrische Klassifizierungsfunktionen sind häufig zu komplex, d. h. von zu vielen Parametern abhängig. Das für nichtparametrische Modelle typische Optimierungsproblem besteht folglich darin, deren Komplexität unter der Nebenbedingung einer möglichst guten Anpassung an die vorhandenen Unternehmensdaten so gering wie möglich zu halten.

Semiparametrische Methoden

... stellen eine Mischung aus den beiden erstgenannten Methoden dar. Das Aussehen der Klassifizierungsfunktion ist vorgegeben, jedoch werden einige der Zusammenhänge zwischen den Variablen auf nichtparametrische Weise bestimmt. Ein Beispiel für diesen Ansatz ist das „Moody's RiskCalc Rating“-Modell für Publikumsgesellschaften. Jeder Prädiktor wird zunächst nichtparametrisch transformiert, ehe er in das klassische Probit-Modell eingespeist wird.

Logit- und Probit-Modelle

... gehören zur Klasse der parametrischen Methoden und unterscheiden sich lediglich hinsichtlich der zugrunde liegenden Verteilungsannahmen. Im Prinzip handelt es sich um eine lineare Regression, die schätzt, wie die Wahrscheinlichkeit $P(y = 1)$, $y = \{0 = \text{solvent}, 1 = \text{insolvent}\}$, durch die unabhängigen Variablen (z. B. Bilanzkennziffern) $x_j, j = 1, \dots, d$ determiniert wird.

Diskriminanzanalyse

... unterstellt im Allgemeinen, dass solvente und insolvente Unternehmen normal verteilt sind und identische Varianz-Kovarianz-Matrizen besitzen. Unter diesen Annahmen ist die Trennungsfunktion (Diskriminanzfunktion) linear. Als *insolvent* klassifizierte Unternehmen gehören mit höherer Wahrscheinlichkeit zur Gruppe der insolventen als zur Gruppe der solventen Unternehmen. Setzt man die Prädiktoren des zu klassifizierenden Unternehmens in die Diskriminanzfunktion ein, erhält man eine Kennzahl (Score), die über die Einstufung des Unternehmens Auskunft gibt.

Optionsbasierte Merton-Modelle

... betrachten den Wert der Firma als eine Kaufoption auf die gesamten Aktiva. Der Wert des Fremdkapitals entspricht dabei dem Ausübungspreis der Option. Das Ereignis, dass der Wert der Unternehmensaktiva unter den Ausübungspreis (den Fremdkapitalwert) sinkt und die Option nicht ausgeübt wird, entspricht in diesem Modell der Insolvenz. Die Wahrscheinlichkeit des Ereignisses Insolvenz (der Nichtausübung der Option) lässt sich mithilfe der Black-Scholes-Optionspreisformel berechnen. Das optionsbasierte Modell liegt der Berechnung der Eigenkapitalunterlegung nach Basel II zugrunde.

Neuronale Netze

... sind ein künstliches, mehrere Schichten aufweisendes Netzwerk von vielen linearen Klassifikationsfunktionen (Neuronen). Die Klassifikationsresultate vorgelagerter Neuronen dienen als Input für nachgelagerte Neuronen. Die resultierende Klassifikationsfunktion ist abschnittsweise linear und kann komplexe Datenstrukturen beschreiben. Ein typisches Problem der neuronalen Netze ist die Abhängigkeit von heuristischen Verfahren beim Aufbau des künstlichen Netzes.

für die optimale Prognosefunktion. Als sogenanntes nichtparametrisches Prognoseverfahren benötigen sie zudem keine strengen Ad-hoc-Annahmen darüber, aus welcher Funktionenklasse die Prognosefunktion stammt.

Abhängigkeiten zwischen den Prädiktoren können die Prognosegüte entscheidend beeinflussen. Ein Gewinnrückgang bei einem kaum verschuldeten Unternehmen wird andere Auswirkungen auf die Insolvenzwahrscheinlichkeit haben als derselbe Gewinnrückgang bei einer hoch verschuldeten Firma. Interdependenzen dieser Art werden von den herkömmlichen Prognosemodellen häufig nicht berücksichtigt. Die im Vergleich zur Diskriminanzanalyse und auch im Vergleich zu Logit- und Probitmodellen höhere Flexibilität von SVMs hat den Vorteil, dass auch solche komplexen Zusammenhänge zwischen den Prädiktoren Eingang in die Prognose finden.

Hinzu kommt, dass SVMs – im Gegensatz zu anderen Prognosemodellen – nicht auf die (meist unrealistische) Annahme angewiesen sind, dass das Gesetz der großen Zahl erfüllt ist und die Anzahl der für die Untersuchung verfügbaren Insolvenzbeobachtungen gegen unendlich geht.

SVMs sind leicht zu implementieren und anzupassen. Anstatt ein ganzes Prognosemodell im Vorhinein spezifizieren zu müssen, wie das z. B. bei den neuronalen Netzen der Fall ist, muss der Risikomanager bei SVMs nur zwei Parameter a priori festlegen. Er muss entscheiden, welchen Komplexitätsgrad die Klassifikationsfunktion haben soll und in welchem Maße Fehlklassifikationen toleriert werden sollen. Wird ein zu hoher Komplexitätsgrad gewählt, passt sich das Modell möglicherweise zu stark an die bekannten Daten der Lernstichprobe an. Es mag dann zwar die Unternehmen der Stichprobe zu 100 % korrekt klassifizieren, versagt aber bei der korrekten Einordnung neuer, unbekannter Daten. In diesem Fall fehlt dem Modell die notwendige Generalisierungsfähigkeit. Das beste Prognosemodell ist folglich durch Parameter charakterisiert, die bei guter Datenanpassung eine möglichst hohe Generalisierungsfähigkeit erzeugen. Für die Adjustierung der Parameter gibt es entsprechende Optimierungsmethoden. Beispielsweise kann als Kriterium für das beste Modell die Trefferquote für Unternehmen, die nicht in der Lernstichprobe enthalten sind, herangezogen werden.

Erste empirische Ergebnisse

Um die Insolvenzprognosefähigkeit von SVMs zu testen, wurde aus den Jahresabschlüssen von US-amerikanischen Firmen ein Datensatz mit insolven-

ten Unternehmen konstruiert. Die Jahresabschlüsse sind über die Securities and Exchange Commission (SEC) zugänglich.⁹ 48 Unternehmen mit einer Marktkapitalisierung von mehr als 1 Mrd. US-Dollar haben in den Jahren 2001 und 2002 im Rahmen von Kapitel 11 des US-amerikanischen Insolvenzrechtsgesetzes (Chapter 11, US Bankruptcy Code) Gläubigerschutz beantragt. 42 dieser insolventen Unternehmen wurden ausgewählt und mit 42 erfolgreichen Unternehmen gleicher Größe und aus der gleichen Branche zu einer Lernstichprobe vereint. Die benutzten Bilanzinformationen stammen aus den Jahren 1998 und 1999. Die Prognose wird folglich auf der Grundlage von Daten durchgeführt, die drei Jahre vor dem Ereignis der Insolvenz beobachtet wurden.¹⁰

Die Unternehmen werden durch insgesamt 13 Bilanzpositionen (Tabelle 3 oben) beschrieben. Die durchschnittliche Marktkapitalisierung der Unternehmen betrug 8,12 Mrd. US-Dollar. Für den Lernprozess der SVMs werden aus den Bilanzpositionen abgeleitete Kennziffern (Gewinn-, Liquiditäts-, Verschuldungs- und Aktivitätskennziffern) verwendet (Tabelle 3 unten). Die Parameter für die Generalisierungsfähigkeit und für die Komplexität des Modells wurden mithilfe der Technik der Kreuzvalidierung bestimmt. Bei der Kreuzvalidierung wird jeweils ein Unternehmen aus der Stichprobe genommen. Die verbleibenden Unternehmen bilden die Lernstichprobe, anhand derer die SVM „trainiert“ wird. Nach dem Lernprozess wird die Klasse des Unternehmens bestimmt, das jeweils aus der Gesamtstichprobe herausgenommen wurde. Wenn alle Unternehmen diese Prozedur durchlaufen haben, wird der Prozentsatz der korrekten Klassifizierungen errechnet. Es wurden mehrere Modelle mit voneinander abweichenden Parametern für die Komplexität und die Generalisierungsfähigkeit angepasst. Das hier dargestellte Prognosemodell erzielte eine maximale Trefferquote in Bezug auf die Ereignisse *Solvenz* und *Insolvenz*.

Prognosemodelle auf der Basis der Diskriminanzanalyse haben gezeigt, dass Gewinn- und Verschuldungskennziffern die prägnantesten Prädiktoren für eine spätere Insolvenz darstellen. Um die Fähigkeit von SVMs zum Herausfiltern der notwendigen Informationen zu illustrieren, erfolgt eine Beschränkung auf zwei Kennziffern aus diesen beiden Gruppen: *Gesamtverbindlichkeiten zu Bilanzsumme* und *Nettogewinn zu Bilanzsumme*. Abbildung 2 illustriert das Ergebnis. Die dunklen Dreiecke stel-

⁹ www.sec.gov/edgar.shtml

¹⁰ Die Berechnung und die Erstellung der Grafiken erfolgten mit einem von den Autoren in C++ entwickelten Modul für das Statistikprogramm XploRe. Eine internetbasierte Version dieses SVM-Modells findet sich auf www.i-XploRe.de und www.XploRe-stat.de.

Tabelle 3


Bilanzpositionen und Prädiktoren

	Minimum	Maximum	Mittelwert	Standardabweichung
In Mill. US-Dollar				
Bilanzsumme	0,367	91 072	8 122	13 602
Umlaufvermögen	0,051	10 324	1 657	1 887
Kurzfristige Verbindlichkeiten	0	17 209	1 599	2 562
Gesamtverbindlichkeiten	0,115	36 437	4 880	6 537
Liquide Mittel	0	1 714	0,192	0,333
Vorräte	0	7 101	0,533	1 114
Finanzschulden – Restlaufzeit größer als ein Jahr	0	13 128	1 826	2 516
Finanzschulden – Restlaufzeit bis zu einem Jahr	0	5 015	0,198	0,641
Umsatz	0,036	37 120	5 016	7 141
Umsatzaufwendungen	0,028	26 381	3 486	4 771
Gewinn vor Zinsen und Steuern	2 214	29 128	0,822	3 346
Zinsaufwendungen	-0,137	0,966	0,144	0,185
Nettogewinn	-2 022	4 013	0,161	0,628
Kennziffern				
Gewinn vor Zinsen und Steuern/Bilanzsumme	-0,493	1 157	0,072	0,002
Nettogewinn/Bilanzsumme	-0,599	0,186	-0,003	0,110
Gewinn vor Zinsen und Steuern/Umsatz	-2 464	36 186	0,435	3 978
Gewinn vor Zinsen und Steuern/Zinsaufwendungen	-16 897	486 945	15 094	68 968
Finanzschulden/Bilanzsumme	0	1 123	0,338	0,236
Gesamtverbindlichkeiten/Bilanzsumme	0,270	1 463	0,706	0,214
log (Bilanzsumme)	12 813	18 327	15 070	1 257
Liquides Vermögen/kurzfristige Verbindlichkeiten	-4 003	259 814	4 209	28 433
Liquide Mittel/Bilanzsumme	0	0,203	0,034	0,041
Nettoumlaufvermögen/Bilanzsumme	-0,258	0,540	0,093	0,132
Umlaufvermögen/kurzfristige Verbindlichkeiten	0,041	2 001 963	25 729	219 568
Verschuldung mit Restlaufzeit bis zu einem Jahr/Finanzschulden	0	0,874	0,082	0,129
Umsatz/Bilanzsumme	0,002	5 559	1 008	0,914
Vorräte/Umsatzaufwendungen	0	52 687	3 253	27 555

Quelle: Berechnungen des DIW Berlin.

DIW Berlin 2004

Abbildung 2

Insolvenzwahrscheinlichkeit

Quelle: Eigene Darstellung.

DIW Berlin 2004

len erfolgreiche, die hellen Vierecke später insolvente Unternehmen dar. Die Linien repräsentieren Werte der Prognosefunktion (Scores). Je höher der

absolute Zahlenwert, desto geringer ist die Wahrscheinlichkeit, insolvent zu werden. Die hervorgehobene Linie gibt die Trennfunktion zwischen solventen und insolventen Unternehmen wieder. Es zeigt sich, dass auch hochprofitable Unternehmen stark insolvenzgefährdet sein können, wenn der Verschuldungsgrad hoch genug ist. Eine mittlere Profitabilität, kombiniert mit einem moderaten Verschuldungsgrad, bildet das Zentrum des rechts unten liegenden Clusters. Diese Kombination minimiert die Wahrscheinlichkeit einer späteren Insolvenz.

Der entscheidende Unterschied zum Ergebnis der Diskriminanzanalyse ist der Ausweis eines *einzig*en Clusters von solventen Firmen, obwohl die Anzahl der Cluster a priori nicht spezifiziert wurde. Das lässt den Schluss zu, dass Firmen bestimmte Eigenschaften besitzen müssen, damit sie erfolgreich sein können. Es existiert offensichtlich eine optimale Kombination von Kapitalstruktur und Gesamtkapitalrendite (Gewinn zu Bilanzsumme). Abweichungen von dieser optimalen Kombination – sei es in positiver oder in negativer Richtung – erhöhen die Insolvenzwahrscheinlichkeit.

Zieht man alle verfügbaren Kennziffern als Prädiktoren heran und wendet die Technik der Kreuzvalidierung an, erzielt die SVM ein Prognoseergebnis von 62 %. Das entspricht in etwa dem Ergebnis, das die Diskriminanzanalyse liefert (60 %). Anhand des Datensatzes lässt sich somit zwar zeigen, dass SVMs in der Lage sind, komplexe Diskriminanzsituationen zu meistern. Um jedoch auf signifikante Unterschiede zwischen der Treffsicherheit von SVMs und der von gängigen Prognosemodellen testen zu können, sind größere Datensätze notwendig.

Fazit

Die tägliche Praxis des Risikomanagements, die jüngst verabschiedeten Eigenkapitalvereinbarungen (Basel II) und die häufig zu beobachtende Neigung von Finanzinstitutionen, auf vergangene Fehleinschätzungen zum Schaden der gesamten Volkswirtschaft mit einer Einschränkung der Kreditvergabe zu reagieren, machen den Bedarf an leistungsfähigen Insolvenzprognosemodellen evident.

SVMs haben bereits in zahlreichen Anwendungsgebieten gezeigt, dass sie äußerst leistungsfähige Klassifizierungsinstrumente sind. Trotz der nachgewiesenen Überlegenheit bei anderen Klassifizierungsproblemen haben SVMs bislang jedoch fast keinen Eingang in das Unternehmensrating gefunden und wurden in der Praxis nicht implementiert. Die vorgestellten Forschungsarbeiten sind ein erster Schritt, um SVMs für das Unternehmensrating nutzbar zu machen.

Die Anwendungsmöglichkeiten von SVMs in der empirischen ökonomischen Forschung sind jedoch nicht auf das Ratingproblem beschränkt. Im Prinzip können sie auf jedes Klassifikationsproblem angewandt werden. So ist auch denkbar, SVMs für die Entwicklung eines leistungsfähigen Frühwarnsystems im Kreditsektor nutzbar zu machen.¹¹

¹¹ Vgl. Tony Van Gestel, Bart Baesens, Joao Garcia und Peter Van Dijke: A Support Vector Machine Approach to Credit Scoring, www.defaultrisk.com/pp_score_25.htm

Hinweis auf eine Veranstaltung

SESSA Konferenz

„Ensuring Sustainable EU Electricity Enlargement“

9. und 10. Dezember 2004

Technische Universität Berlin

Straße des 17. Juni 135, Raum H 3005, 10623 Berlin

Das DIW Berlin veranstaltet gemeinsam mit der Technischen Universität Berlin die SESSA Konferenz „Ensuring Sustainable EU Electricity Enlargement“.

SESSA ist ein europaweites Forschungsprogramm zu den Reformen der Elektrizitätsmärkte, das im Zuge des 6. EU-Rahmenprogramms gefördert wird. Es umfasst neben 20 wissenschaftlichen Forschungsteams auch über 40 Interessenvertreter aus Energieministerien, Energieunternehmen und Regulatoren.

Ziel dieser Konferenz ist es, die Perspektiven und Herausforderungen der Elektrizitätsmarktreformen in den zehn neuen EU-Mitgliedstaaten zu durchleuchten sowie die Situation der drei Kandidatenländer Rumänien, Bulgarien und Kroatien zu begutachten. Im Zuge der Konferenz werden daher sowohl theoretische und rechtliche Aspekte der bevorstehenden Liberalisierung aufgezeigt als auch praktische Beispiele und Anregungen aus den jeweiligen Ländern präsentiert.

Kontakt

Christian von Hirschhausen, DIW Berlin
Tel. 030 - 897 89-343, E-Mail: sessa@diw.de

Weitere Informationen finden sich unter:

www.diw.de/english/produkte/veranstaltungen/sessa

Impressum

Herausgeber

Prof. Dr. Klaus F. Zimmermann (Präsident)
Prof. Dr. Georg Meran (Vizepräsident)
Dr. Tilman Brück
Dörte Höppner
PD Dr. Gustav A. Horn
Dr. Kurt Hornschild
Prof. Dr. Claudia Kemfert
Dr. Bernhard Seidel
Prof. Dr. Viktor Steiner
Prof. Dr. Gert G. Wagner
Prof. Axel Werwatz, Ph. D.
Prof. Dr. Christian Wey
Dr. Hans-Joachim Ziesing

Redaktion

Dr. habil. Björn Frank
Dr. Elke Holst
Jochen Schmidt
Dr. Mechthild Schrooten

Pressestelle

Renate Bogdanovic
Tel. +49-30-897 89-249
presse@diw.de

Verlag

Verlag Duncker & Humblot GmbH
Carl-Heinrich-Becker-Weg 9
121 65 Berlin
Tel. +49-30-790 00 60

Bezugspreis

(unverbindliche Preisempfehlungen)
Jahrgang Euro 120,-
Einzelheft Euro 11,-
Zuzüglich Versandkosten
Abbestellungen von Abonnements
spätestens 6 Wochen vor Jahresende

ISSN 0012-1304

Bestellung unter www.diw.de

Konzept und Gestaltung

kognito, Berlin

Druck

Druckerei Conrad GmbH
Oranienburger Str. 172
13437 Berlin