

ESTUDO EXPLORATÓRIO UTILIZANDO AS TÉCNICAS DE ANÁLISE POR ENVOLTÓRIA DE DADOS E REDES NEURAIAS ARTIFICIAIS NA PREVISÃO DE INSOLVÊNCIA DE EMPRESAS

USE OF DATA ENVELOPMENT ANALYSIS AND NEURAL NETWORKS IN THE PREDICTION OF FIRMS' BANKRUPTCY

Luciana Massaro **ONUSIC**

Doutoranda do Departamento de Administração - FEA/USP
Professora da Faculdade Sumaré e Faculdade Trevisan
luciana_onusic@yahoo.com

Silvia Pereira de Castro **CASA NOVA**

Pós-doutoranda - EAESP/FGV
Professora Doutora do Departamento de Contabilidade e Atuária da FEA/USP
silvianova@usp.br

Adriana Cristina da **SILVA**

Mestre em Controladoria e Contabilidade - FEA/USP
Professora do Departamento de Contabilidade da FEARP/USP
adrics@usp.br

Leila Lage **HUMES**

Doutoranda do Departamento de Administração - FEA/USP
lhumes@usp.br

Resumo

Atualmente diversas técnicas quantitativas têm sido usadas na previsão de insolvência de empresas na busca de reduzir o risco na avaliação de crédito. Este trabalho tem como objetivo, comparar os resultados das técnicas Análise por Envoltória de Dados e Redes Neurais utilizadas para prever a insolvência em uma base de dados fornecida pela SERASA. Os resultados do modelo DEA e Redes Neurais foram próximos, enquanto no modelo DEA 62% das empresas solventes foram classificadas corretamente, nas redes neurais o acerto foi de 64%, um pouco melhor que no modelo DEA. No entanto, para as empresas insolventes, no modelo DEA, o acerto foi de 68%, melhor que nas redes neurais que foi 60%.

Palavras-chave: Previsão de Falência – Análise por Envoltória de Dados – Redes Neurais – Análise Fatorial.

Abstract

Many quantitative techniques have been used recently in bankruptcy prediction of firms as a mean to reduce credit evaluation risks. This paper compares data envelopment analysis and neural networks to predict bankruptcy using data from SERASA. Results of DEA model and neural networks were very similar, while DEA model 62% of non bankruptcy firms were correctly classified, with neural networks classification accuracy was of 64%. However for bankruptcy firms DEA model shows a correct classification was of 68%, better than neural network classification that was of 60%.

Key-words: Bankruptcy Prediction – Data Envelopment Analysis – Neural Networks – Factorial Analysis.

Introdução

Os modelos de previsão de insolvência são de grande auxílio na avaliação de risco, sendo utilizados como uma ferramenta importante na análise de desempenho das empresas e apoio à decisão de risco de crédito. Diversas são as técnicas quantitativas para previsão de insolvência, tais como: Análise Discriminante, Regressão Logística, Redes Neurais Artificiais e Análise por Envoltória de Dados, entre outras.

O objetivo geral deste artigo é verificar a contribuição da análise por envoltória de dados e das redes neurais na análise de previsão de insolvência de empresas.

Ao classificar uma empresa como solvente ou insolvente, existe um risco de erro de classificação. Este erro, naturalmente, pode gerar custos, tais como no caso de uma instituição que se baseia nessa classificação para conceder ou não crédito a terceiros. Uma empresa insolvente pode ser classificada com solvente. Este é chamado de erro tipo I. Inversamente, uma empresa solvente pode ser classificada como insolvente. Este é chamado erro tipo II (ALTAMN *et al*, 1977).

Os erros de tipo I e tipo II geram custos para os credores. Os custos decorrentes do erro tipo I são maiores que os custos decorrentes do tipo II (ALTAMN *et al*, 1977; DUMONTIER, 1990). Segundo Dumontier (1990), o primeiro tipo de custo é aquele sofrido por um credor em caso de falência de seu devedor e o segundo tipo de custo é o custo de oportunidade.

1 Alguns estudos sobre previsão de insolvência

Fitzpatrick (1932) foi quem realizou um dos primeiros estudos sobre previsão de insolvência. No entanto, foi a partir da década de 60, com o surgimento de ferramentas estatísticas, que as possibilidades de estudo sobre previsão de insolvência ganharam impulso. Beaver (1966) utilizou técnicas univariadas para previsão de falências, criando modelos baseados em uma única variável. Altman (1968) explorou a análise

discriminante multivariada. Foram estudados modelos de probabilidade condicionada utilizando modelos tais como Logit (OHLSON, 1980).

Modelos explorando redes neurais (BELL *et al* 1990; ALMEIDA, 1993) começaram a ser utilizados.

Simak (1997) estudou a possibilidade de utilizar DEA como ferramenta para prever a insolvência corporativa futura e comparou este modelo com o modelo Z Score de Altman *et al* (1977).

No Brasil, um dos primeiros estudos sobre previsão de insolvência foi o de Kanitz (1976).

Elizabetsky (1976 apud Mario, 2002) utilizou a análise discriminante para um grupo de 473 empresas no período de 1972 a 1975, buscando empresas de mesmo ramos de atividade para evitar eventuais diferenças nos resultados. A equação final do modelo possui 28 variáveis e nenhuma empresa foi classificada incorretamente.

O estudo foi realizado por Altman *et al* (1979) foi realizado utilizando a mesma metodologia de Altman (1968). No estudo foram selecionadas 35 empresas solventes e 23 empresas insolventes, sendo que foram escolhidas empresas do mesmo setor de atividade e porte semelhante. O modelo foi capaz de realizar uma previsão de 88%, isto é, 7 das 58 empresas foram mal classificadas.

Almeida (2000) utilizou a análise por envoltória de dados (DEA) na análise de insolvência de empresas brasileiras. No seu estudo, utilizou 60 empresas cadastradas na CVM (Comissão de Valores Mobiliários), sendo que o resultado foi um modelo DEA que acertou 90% das empresas.

2 Técnicas utilizadas na previsão de insolvência das empresas

2.1 Análise por Envoltória de Dados (DEA)

A Análise por Envoltória de Dados (DEA) é uma técnica não paramétrica baseada em programação linear, cujos primeiros estudos foram desenvolvidos por Charnes *et al* (1978), baseado no trabalho de Farrell (1957). Tem como objetivo principal a

comparação de eficiência relativa entre unidades organizacionais denominadas de DMU – Decision Making Units (ROSA, 2001).

Segundo Casa Nova (2002, p. 82), as DMUs (DMU – Decision Making Units) podem ser grupos empresarias, empresas individuais, unidades administrativas, entre outros.

Para Niederauer (2002), essa eficiência é padronizada para se situar entre 0 e 1. No entanto, na complexidade dos processos organizacionais ocorrem a existência de vários insumos e vários produtos podendo exigir a seguinte medida de eficiência:

$$\text{Eficiência} = \frac{\text{Soma ponderada dos produtos}}{\text{Soma ponderada dos insumos}}$$

Para o autor acima, a DEA soluciona este tipo de problema de maneira original.

A formulação original do modelo CCR dos autores Charnes, Cooper e Rhodes, publicado em 1978, e que tem como base múltiplos produtos (*outputs*) e insumos (*inputs*) que atendam à construção de um único produto “virtual” e um único insumo “virtual” é: (CHARNES *et al*, 1997,p.3).

$$\text{Maximizar } h_k = \sum_{r=1}^s u_r y_{rk} \quad (\text{eq. 1})$$

Sujeito a

$$\sum_{r=1}^m u_r y_{rj} - \sum_{i=1}^n v_i x_{ij} \leq 0 \quad (\text{eq. 2})$$

$$\sum_{i=1}^n v_i y_{ik} = 1 \quad (\text{eq. 3})$$

$$u_r, v_i \geq 0$$

y = produtos; x = insumos; u, v = pesos

$$r = 1, \dots, m; \quad i = 1, \dots, n; \quad j = 1, \dots, N$$

Considera-se N empresas produzindo m quantidades de produtos y a partir de n quantidades de insumos x. Uma empresa k qualquer produz yrk quantidades de produtos com a utilização de xik quantidades de insumos. O objetivo da DEA é encontrar o máximo indicador de eficiência hk onde ur é o peso específico a ser encontrado para um produto r e vi o peso específico de cada insumo i (CERETTA; NIEDERAUER, 2000, p. 3 apud

CASA NOVA, 2002, p. 71).

Este modelo apresentado é a formulação matemática original do modelo CCR que tem orientação para o consumo e busca produzir o nível de produção dado, mas minimizando o consumo de insumos.

O modelo BCC com orientação ao consumo (*input*) utilizado, neste trabalho, pode ser visto a seguir:

$$\text{Maximizar } \sum_{r=1}^m u_r y_{rk} - u_k \quad (\text{eq. 4})$$

Sujeito a

$$\sum_{i=1}^n v_i x_{ik} = 1 \quad (\text{eq. 5})$$

$$\sum_{r=1}^m u_r y_{rj} - \sum_{i=1}^n v_i x_{ij} - u_k < 0 \quad (\text{eq. 6})$$

$$u_r, v_i \geq 0$$

y = produtos; x = insumos; u, v = pesos

$$r = 1, \dots, m; \quad i = 1, \dots, n; \quad j = 1, \dots, N$$

A introdução da variável u_k representa os retornos variáveis de escala e pode assumir valores negativos.

Segundo Charnes *et al* (1997), a Análise por Envoltória de Dados pode ser entendida como um conjunto de modelos e metodologias incorporados a um conjunto de modelos. Entre os modelos mais utilizados, estão o CCR e o BCC. No entanto, existem outros modelos como o Aditivo e Multiplicativo. Neste trabalho, é utilizado o modelo BCC.

2.2 Redes Neurais Artificiais

As Redes Neurais Artificiais têm sido utilizadas em vários ramos da ciência e vêm ganhando destaque no setor dos negócios, onde têm sido utilizadas na análise de crédito, análise de riscos de inadimplência, em riscos de seguros, na avaliação de riscos de papéis financeiros, na seleção de pessoal, na simulação de vendas, na sugestão de produtos adaptados ao perfil de cada cliente, previsão de falência, entre outros.

Uma Rede Neural é um modelo matemático que tem inspiração no funcionamento do cérebro humano, pois possui a característica de aprendizado. É uma técnica

útil quando há a necessidade de se reconhecer padrões a partir do acúmulo de experiência ou de exemplos, e cuja representação é complexa.

Uma rede neural é formada por um conjunto de neurônios, também chamados de elementos de processamento (BHARAT; NAG, 1997). As unidades de processamento são distribuídas em um conjunto de camadas. Uma rede neural possui uma estrutura que pode ser descrita a partir de quatro conceitos (HAIR JR. *et al.*, 1998): o tipo de modelo de rede neural; as unidades de processamento que tratam a informação que entra na rede; um sistema de nós que interligam as unidades de processamento; uma função de aprendizado, a partir da qual o sistema calibra o modelo.

Segundo Hair Jr. *et al.* (1998), existem três modelos básicos de redes neurais: perceptron multicamadas, função de base radial e redes de Kohonen. As redes de base radial são mais recentes e são utilizadas, segundo os autores, para os mesmos tipos de aplicação que as multicamadas. Já as redes de Kohonen são mais apropriadas para agrupamentos (*clustering*). A seguir, expõem-se mais detalhadamente a rede multicamadas e a Função de Base Radial (FBR), por serem mais utilizadas neste trabalho.

2.2.1 Redes multicamadas ou redes perceptron multicamadas

Neste tipo de rede, várias camadas são organizadas horizontalmente (Figura 3). Cada neurônio se conecta a todos os neurônios da camada seguinte. Apesar de poderem ser formadas de várias camadas, as redes de três camadas são as mais frequentemente utilizadas: a camada de entrada com os neurônios de entrada, a camada intermediária com os neurônios intermediários e a camada de saída com os neurônios de saída. Os neurônios de entrada introduzem informação na rede. Os neurônios de saída transmitem as respostas da rede. Hornik *et al.* (1989) e Funahashi (1989) provaram que uma rede com apenas uma camada intermediária, portanto, uma rede com três camadas, é suficiente para representar qualquer função ou problema de classificação. É, portanto, suficiente para problemas

de classificação como os de previsão de falência, onde se busca classificar uma empresa como solvente ou insolvente.

O modelo multicamadas mais frequentemente utilizado é o modelo de retro-propagação sendo o modelo mais conhecido e referenciado na literatura (SHARDA 1994; HAIR, JR. *et al.*, 1998).

Hair, Jr. *et al.* (1998) apresenta três elementos básicos das redes multicamadas:

Nós: É o elemento básico das redes neurais, um elemento de processamento que atua em paralelo com os outros nós da rede.

Rede: Uma rede neural é um arranjo seqüencial de três tipos básicos de nós ou camadas: nós (ou neurônios) de entrada, nós intermediários e nós de saída.

Os nós de entrada recebem os dados iniciais e transmitem para a rede.

Aprendizado: Segundo Hair Jr. *et al.* (1998), o que realmente diferencia uma rede neural de outras técnicas multivariadas é sua capacidade de aprendizado. Os valores são propagados pela rede através de pesos de conexão entre os nós. Os pesos de conexão são ajustados através de um método de aprendizado. O modelo mais frequentemente utilizado é o método de retro-propagação que se baseia nos Modelos de Processamento Distribuído Paralelo propostos por Rumelhart *et al.* (1986).

Almeida e Dumontier (1996) explicam como se processa a propagação dos dados na rede (Figura 4): os valores de entrada são transmitidos entre as camadas e transformados através de pesos de conexões entre os neurônios (W_{ji} : peso da conexão entre o neurônio I e neurônio J). O conhecimento armazenado nas redes está nos seus pesos de conexão.

No método de retropropagação, os erros obtidos na saída dos neurônios são calculados e retropropagados para o sistema, corrigindo-se assim os pesos de conexão. Os pesos de conexão são, então, progressivamente corrigidos até que se atinja um nível de erro desejável, encerrando-se assim o processo de aprendizado. “O objetivo é processar um grande número de casos através da

rede neural na fase de aprendizado para desta forma a rede poder realizar as melhores previsões possíveis ao longo de todas as observações de entrada” (HAIR JR. et al 1998, p. 687).

2.2.2 Função de Base Radial (FBR)

Outro modelo de redes neurais bastante referenciado na literatura são as redes de funções de bases radiais (FBR) que apresentam duas camadas de unidades, além da camada de entrada (HAYKIN 1999; BISHOP 1995; MOODY and DARKIN, 1989). As unidades da camada de saída têm funções de transferências lineares, portanto, cada uma dessas unidades tem como saída uma combinação linear das saídas da camada intermediária (HAYKIN, 1999). A função de base radial pode ser vista como a função de ativação da camada intermediária. A função de transferência da camada intermediária mais comum é uma função gaussiana (HAYKIN, 1999, BISHOP 1995). A saída da unidade j da camada é:

$$z_j = \exp[-(\mathbf{x} - \mathbf{w}_j) \cdot (\mathbf{x} - \mathbf{w}_j)] / 2\sigma^2$$

onde \mathbf{x} é o vetor de entrada e \mathbf{w}_j o vetor peso associado com a unidade intermediária (isto é, o centro da sua função gaussiana) e s^2 é o fator de normalização.

O valor de saída da função de transferência (linear) y_i de uma unidade da camada de saída é determinada por:

$$y_i = \sum_j w_{ij} z_j$$

onde w_{ji} é o peso entre a unidade intermediária j e a unidade de saída i .

Ainda, segundo Haykin (1999), as unidades de saída formam uma combinação linear das funções de base radiais e, dessa forma, a rede desempenha uma transformação não linear da entrada.

A aprendizagem rede de FBR ocorre em dois estágios; a aprendizagem na camada intermediária é seguida da aprendizagem na camada de saída (HAYKIN, 1994; BISHOP, 1995).

A aprendizagem na camada intermediária é executada, usando-se métodos não supervisionados tal como o algoritmo agrupamento de K-means, assemelhando-se à rede de Kohonen, enquanto a aprendizagem na camada de saída usa métodos como o algoritmo dos mínimos quadrados (BISHOP, 1995).

O número de unidades intermediárias é determinado pelo algoritmo de agrupamento.

Do ponto de vista de aprendizagem, as redes FBR são muito mais rápidas do que as de retropropagação (STATISTICA NEURAL NETWORK, 1999).


3 Metodologia da pesquisa

3.1 Tipo de pesquisa

A pesquisa é de caráter quantitativo.

Para a elaboração do modelo de pesquisa, foram levadas em consideração as variáveis independentes e as variáveis dependentes presentes no modelo de previsão. A Figura 1 descreve o modelo de pesquisa que foi utilizado.

Figura 1 - Modelo de Pesquisa



As variáveis independentes inicialmente utilizadas neste trabalho estão no Quadro 1. A variável dependente deste trabalho se traduz em situação

da empresa, que pode ser dividida em:
 - determinação de empresas solventes;
 - determinação de empresas insolventes.

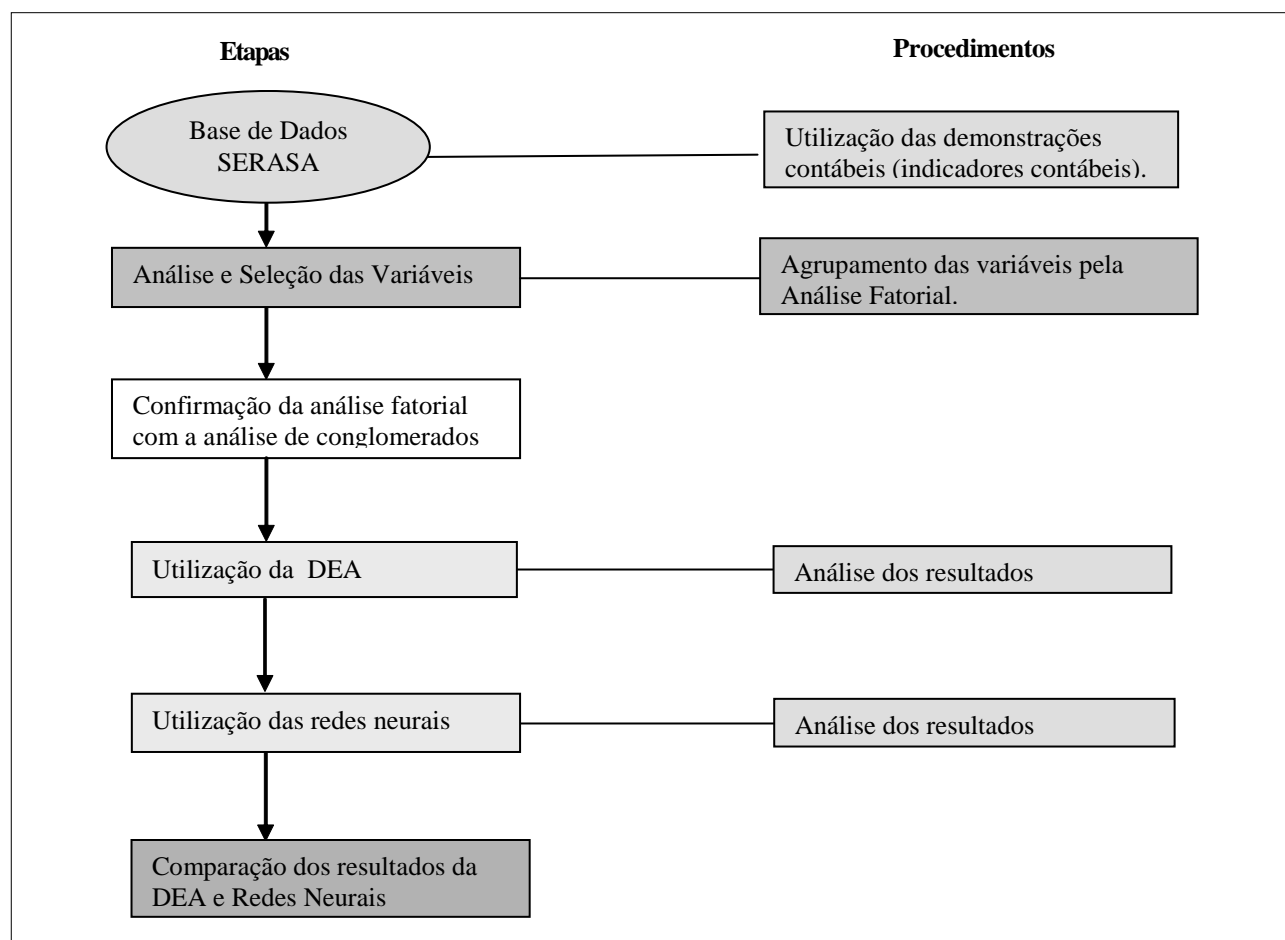
Quadro 1 - Indicadores utilizados inicialmente

Índice		Fórmula
Liquidez	Líquides corrente	Ativo Circulante / Passivo Circulante
Liquidez	Liquidez seca	Ativo Circulante + RLP / Passivo Circulante/ ELP
Liquidez	Liquidez geral	
Estrutura	Endividamento	Capital de terceiros/ PL
Estrutura	Imobilização do patrimônio líquido	Imobilizado / PL
Rentabilidade	Rentabilidade do ativo	Vendas Líquidas / Ativo
Rentabilidade	Margem	Lucro líquido / Vendas líquidas*100

3.2 Etapas do Desenvolvimento da Pesquisa

A Figura 2 apresenta uma visão geral dessas etapas desta pesquisa.

Figura 2 – Etapas de Desenvolvimento do Trabalho



3.3 Coleta de Dados: Método e Instrumento

Os dados coletados nesta pesquisa foram dados secundários. A amostra com 300 empresas, sendo 150 em concordata e 150 solventes, foi fornecida pela Serasa que é uma das maiores empresas do mundo em análises e informações para decisões de crédito e

apoio a negócios (<http://www.serasa.com.br>). Não há diferenciação quanto ao fato de serem S.A. de capital aberto/fechado ou Ltda. A moeda é o Real e os valores são históricos, da data da publicação do balanço. O porte das empresas segue a segmentação da Serasa, conforme mostrado no Quadro 2.

Quadro 2 - Porte das empresas e características

Porte da Empresa	Características
Porte 3 - Middle	Faturamento Líquido: 4.000.000,00 Ativo Total: 2.000.000,00
Porte 4 – Middle Plus	Faturamento Líquido: 25.000.000,00 Ativo Total: 25.000.000,00
Porte 5 - Corporate	Faturamento Líquido: 50.000.000,00 Ativo Total: 50.000.000,00

As empresas com numeração de 1 a 150 são as empresas em concordata e as empresas com numeração 151 a 300 são as empresas solventes. Devido à falta de informações em vários itens das demonstrações contábeis, bem como a não paridade do ano em relação à insolvência, algumas empresas tiveram que ser eliminadas. A amostra, portanto, foi redimensionada de 300 empresas para 145 empresas, sendo 82 insolventes pareadas com 63 solventes. O período e a análise é de 3 anos antes da data de concordata.

As técnicas para análise de dados aqui utilizados foram:

- análise fatorial, para redução das variáveis e criação de fatores;
- aplicação da análise por envoltória de dados;
- aplicação de redes neurais.

Foi utilizado o software *SPSS* versão 9.0 como ferramenta de apoio na análise estatística dos dados e na construção da regressão logística e o software *Frontier Analyst Professional*, para a classificação das empresas na análise por envoltória de dados.

4 Resultados obtidos e análise

4.1 Tratamento dos dados

Seleção de variáveis

Análise fatorial é um nome genérico dado a uma classe de métodos estatísticos multivariados, cujo

propósito principal é definir a estrutura subjacente em uma matriz de dados. Em termos gerais, a análise fatorial aborda o problema de analisar a estrutura das inter-relações (correlações) entre um grande número de variáveis, definindo um conjunto de dimensões latentes comuns, chamadas de fatores (Hair *et. al*, 2005).

A análise fatorial permite identificar as dimensões separadas da estrutura e então determinar o grau em que cada variável é explicada por cada dimensão.

A seleção do método de extração de fatores depende do objetivo da pesquisa. A análise de componentes é usada quando o objetivo é resumir a maior parte da informação original (variância) a um número mínimo de fatores necessários, para explicar a parte máxima da variância representada no conjunto original de variáveis, e quando o conhecimento anterior sugere que as variâncias específicas e do erro representam uma proporção relativamente pequena da variância total.

No caso em questão, foi realizada uma redução das variáveis em fatores, utilizando a análise fatorial para agrupar variáveis.

A matriz foi rotacionada, utilizando o método de análise de componentes principais e método de rotação Varimax como pode ser visto no quadro abaixo. Nota-se na tabela 1 a formação de 3 fatores.

Tabela 1 – matriz rotacionada

	Rotated Component Matrix ^a		
	Componente		
	1	2	3
Zscore(LC)	.958	4.736E-03	.155
Zscore(LS)	.913	-3.12E-03	.122
Zscore(LG)	.860	-6.85E-03	.288
Zscore(ENDIV)	9.062E-03	.984	3.475E-03
Zscore(IMOBPL)	-1.35E-02	.985	3.698E-02
Zscore(MARGEM)	.122	-1.53E-02	.945
Zscore(RENTAT)	.336	.106	.876

Extraction Method: Principal Component Analysis.
 Rotation Method: Varimax with Kaiser Normalization.
^a Rotation converged in 5 iterations.

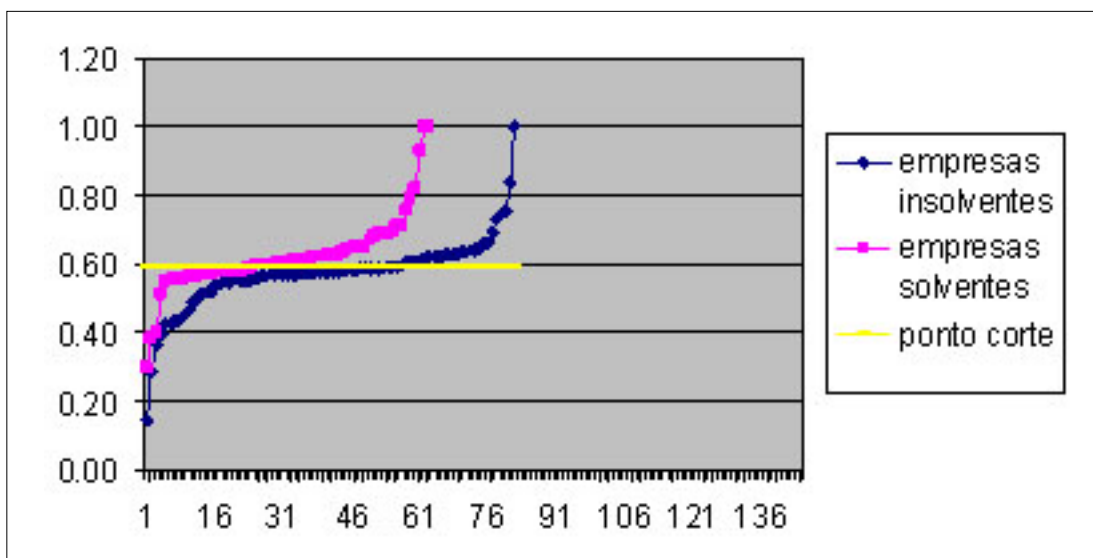
Estes fatores foram utilizados nos modelos de Análise por Envoltória de Dados e Redes Neurais Artificiais.

4.2 Resultados obtidos com a DEA

O modelo utilizado em DEA foi o BCC com

orientação para o consumo. Como é uma técnica que classifica os dados, foi determinado um ponto de corte em que empresas acima deste ponto seriam consideradas solventes e abaixo deste ponto, insolventes. O ponto de corte escolhido foi 50,68% e a classificação das empresas pode ser visualizada na Figura 3:

Figura 3 – Ponto de corte e classificação empresas solventes e insolventes



O resultado obtido por este modelo foi que 39 empresas das 63 solventes foram classificadas de maneira correta como solventes, mostrando 62% de acerto, enquanto que das empresas insolventes,

o acerto foi de 68%, isto é, 56 empresas insolventes das 82 foram classificadas corretamente como insolventes. A Tabela 2 mostra melhor este resultado.

Tabela 2 - resultado da classificação do modelo DEA

Grupo de origem	Classificadas como		Total
	Insolventes	Solventes	
Insolventes	56	26	82
Insolventes (%)	68%%	32%	100%
Solventes	24	39	63
Solventes (%)	38%	62%	100%

4.3 Resultados obtidos com as redes neurais

Foram geradas redes, utilizando-se o modelo de redes de multicamadas com o método de aprendizado de retro-propagação, bem como de redes de função de bases radiais.

A amostra de 145 observações foi dividida em três sub-grupos:

- amostra de treinamento: 50 observações (25 empresas falidas 25 não falidas);
- amostra de validação: 36 (18 falidas e 18 não falidas);

- amostra de teste: 59 observações (39 falidas e 20 não falidas).

Através de um processo de criação e teste de redes, iniciou-se o aprendizado das redes com a configuração inicial de redes com 4 neurônios na camada intermediária para a rede multicamada e com 11 neurônios para a rede de função de base radial. Foi criado um total de 282 redes.

O desempenho das 10 melhores redes obtidas é apresentado na Tabela 3. As melhores redes obtidas se basearam no modelo de rede multicamada.

Tabela 3 – resultado das redes

Método	Erro	Entradas (Fatores)	Neurônios na camada Intermediária
MLP	0,4949087	1	1
MLP	0,4944079	3	8
MLP	0,4942643	3	6
MLP	0,4939215	3	5
MLP	0,4938184	3	8
MLP	0,4937922	3	7
MLP	0,4937662	3	7
MLP	0,4933705	3	8
MLP	0,4930967	3	7
MLP	0,4928113	3	5

A partir da análise da capacidade de classificação da melhor rede obtida, obtêm-se

os seguintes resultados de classificação, segundo a Tabela 4.


Tabela 4 – Resultado de classificação das redes neurais

	Treinamento		Validação		Teste	
	Não falida	Falida	Não falida	Falida	Não falida	Falida
Total	25	25	18	18	20	39
Class. Correta	14	17	12	7	12	25
% Class. Correta	56,0%	68,0%	66,7%	38,9%	60,0%	64,1%

Pode-se observar que, na amostra de teste, as redes conseguiram classificar corretamente 60% das empresas não falidas como não falidas e 64,1% das

empresas falidas, dentro do grupo das falidas. A Figura 4 representa a configuração da rede de melhor desempenho.

Figura 4 - Configuração da rede



4.4 Análise conjunta dos resultados de DEA e redes neurais

Os resultados do modelo DEA e das Redes Neurais foram próximos, enquanto no modelo DEA, 62% das empresas solventes foram classificadas corretamente, nas redes neurais, o acerto foi de 64%, um pouco melhor que no modelo DEA. No entanto, para as empresas insolventes, no modelo DEA, o acerto foi de 68%, melhor que nas redes neurais que foi 60%.

5 Conclusão

Os resultados obtidos, tanto com o modelo DEA quanto de Redes Neurais, não foram muito distintos, girando em torno de 60% a 68% de acerto.

É importante destacar que qualquer técnica de previsão é passível de erros. A utilização em conjunto destas duas técnicas pode possibilitar uma complementação dos resultados para uma melhor análise.

Voltando à revisão da literatura em que se discutia os custos dos erros de classificação das empresas, os custos decorrentes do erro tipo I são maiores que os custos decorrentes do tipo II (ALTMAN et al 1977; ZAVGREN 1985; DUMONTIER 1990; MALECOT 1992) e ainda, segundo Dumontier

(1990), o primeiro tipo de custo é aquele sofrido por um credor em caso de falência de seu devedor e o segundo tipo de custo é o custo de oportunidade. Neste contexto, o resultado desta pesquisa teve um aspecto positivo em conseguir um erro de classificação menor das empresas insolventes no modelo DEA.

Um das limitações deste trabalho foi a dificuldade de conseguir dados de empresas insolventes, o que resultou em um número pequeno de empresas na amostra. A pesquisa não pode ser extrapolada e os resultados foram alcançados para esta base de dados. O presente estudo limitou-se à comparação dos resultados de classificação para cada uma das técnicas, utilizando apenas os indicadores reduzidos em fatores. Estudos futuros podem ser feitos, utilizando outros indicadores contábeis e não reduzidos em fatores.

Referências

ALMEIDA, F.C. **L'Evaluation des risques de défaillance des entreprises à partir des réseaux de neurones insérés dans les systèmes d'aide à la décision.** Thèse de doctorat en sciences de gestion. Grenoble: Ecole Supérieure des Affaires, Université Pierre Mendès France, 1993.

- ALMEIDA, H. R. **Análise de envoltória de dados na tomada de decisão para concessão de crédito**. Dissertação de mestrado do programa de Engenharia Aeronáutica e Mecânica. São José dos Campos: ITA, 2000.
- ALTMAN, E. L. Financial ratios, discriminant analysis, and the prediction of corporate bankruptcy. **Journal of Finance**, v. 23, n. 4, p. 589-609, 1968.
- ALTMAN, E. L.; HALDEMAN, R.; NARAYANAN, P. Zeta Analysis. *Journal of Banking and Finance*, junho, p.29-54, 1977.
- ALTMAN, E. L.; BAIDYA, T. K. N.; DIAS, L. M. R., Previsão de problemas financeiros em empresas. **Revista de administração de empresas**, v. 19, n. 1, 1979.
- BEAVER, W. Financial ratios as predictors of failure. **Journal of Accounting Research**, 4:supplement, p.71-111, 1966.
- BELL, B.T., RIBAR, G.R., VERCHIO, J.R. **Neural nets vs. Logistic regression: a comparison of each model's ability to predict commercial bank failures**. Actes du congrès international de comptabilité. Tome I, Nice, 1990.
- BISHOP, C.M. **Neural Networks for Pattern Recognition**- Oxford Press University, 1995.
- BOOTH, P. Decomposition measures and the prediction of financial failure. **Journal of business finance and accounting**. Vol. 10, n. 1, p. 67-81, 1981-1983.
- CASA NOVA, S. P. C. **Utilização da Análise por Envoltória de Dados (DEA) na Análise de Demonstrações Contábeis**. Tese de doutorado. São Paulo: Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, 2002.
- CERETTA, P.S.; NIEDERAUER, C.A.P. **Rentabilidade do setor bancário brasileiro**. 24º Encontro Nacional da ANPAD – Associação Nacional de Programas de Pós Graduação em Administração. Florianópolis: setembro, p. 10-13, 2000.
- CHARNES, A.; COOPER, W.W.; RHODES, E. Measuring the efficiency of decision making units. *Eur. J. Opl. Res.* 2, p. 429-444, 1978.
- CHARNES, A.; COOPER, W.W.; LEWIN, A.; SEIFORD, L. **Data Envelopment Analysis: Theory, methodology and application**. Massachusetts: Kluwer, 1997.
- DUMONTIER, P. Vices et vertus des modèles de prévision de défaillance. **Papier de recherche**, n° 90-12, Université de Grenoble II, CERAG, 1990.
- FARREL, M. J. The Measurement of Productive Efficiency. **Journal of the Royal Statistical Society**. Séries A, Parte III, p. 253-290, 1957.
- FITZPATRICK, P. A. **A Comparison of the Ratios of the Successful Industrial Enterprises with those of Failed Companies**. The Accountants Publishing Company, 1932.
- GUPTA, Y.P.; RAO, R.P.; BAGGI, P.K. Linear goal programming as an alternative to multivariate discriminant analysis: a note. **Journal of Business, Finance, and Accounting**, p.593-598, 1990.
- HAIR, J.F. ANDERSON, R.E. TATHAM, R.L. BLACK, W.C. **Multivariate Data Analysis**. Prentice Hall, 1998.
- HAYKIN, S. **Neural networks: a comprehensive foundation**. 2ª ed. NJ: Prentice Hall. Moody, J. e C.J. Darkin, (1989) – “Fast learning in networks of locally-tuned processing units” – *Neural Computing*, vol.1, p.281-294, 1999.
- HORNIK, K. .M. Stichcombe e H. White. “**Multilayer feedforward networks are universal approximators**” – *Neural Networks*, vol. 2, p. 359-366, 1989
- KANITZ, S.C. **Indicadores Contábeis e Financeiros de Previsão de Insolvência: a experiência na pequena e média empresa brasileira**. Tese de livre docência. São Paulo: Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, 1976.
- LANE, W.R., LOONEY, S.W., WANSLEY, W. Na application of the cox proportional hazards model to bank failure. **Journal of Banking and Finance**. vol. 10, p.511-531, 1986.

MARAIS, M. PATELL, J., WOLFSON, M. The experimental design of classification models: an application of recursive partitioning and bootstrapping to commercial bank loan classification. **Journal of Accounting Research**. supplément, 1984.

MARIO, P.C. **Contribuição ao estudo da solvência empresarial: uma análise de modelos de previsão – estudo exploratório aplicado a empresas mineiras**. Dissertação de mestrado. São Paulo: Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, 2002.

MATARAZZO, D.C. **Análise Financeira de Balanços: abordagem básica e gerencial**. 5^a ed. São Paulo: Atlas, 1998.

MATIAS, A.B.; SIQUEIRA, J.O. Risco Bancário: modelo de previsão de insolvência de bancos no Brasil. **Revista de Administração**. São Paulo: v.31, n.2, abril-junho p. 19-28, 1996.

NIEDERAUER, C. A. P. **Ethos: Um Modelo para Medir Produtividade Relativa de Pesquisadores Baseado na Análise por Envoltória de Dados**. Tese de doutorado. Santa Catarina: Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, 2002.

OHLSON, J.A. Financial ratios and the probabilistic prediction of bankruptcy. **Journal of Accounting Research**. vol.18, n.1, primavera, 1980.

ROSA, F. de. **Canais de Atendimento Eletrônico e Satisfação, retenção e Rentabilidade de Clientes em Bancos**. Tese de doutorado. São Paulo: Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, 2001.

SERASA, Disponível em <<http://www.serasa.com.br>>. Acesso em 10 de abril de 2004.

SIMAK, P.C. **DEA based analysis of corporate failure**. Thesis. Master of Applied Science. Toronto (Canadá): Graduate Department of Mechanical and Industrial Engineering, University of Toronto, 1997.