
O uso de redes neurais em avaliação de riscos de inadimplência

*Fernando C. de Almeida
Pascal Dumontier*

Tem sido explorado nos últimos anos, em diversos estudos, o uso de redes neurais na avaliação de riscos de inadimplência (Almeida, 1993; Wilson & Sharda, 1994; Poddig, 1995 etc.). No entanto, a concepção e a análise de redes neurais através de métodos estruturados, bem como as dificuldades encontradas em sua utilização, são pouco discutidas. A construção das redes neurais tem sido feita, normalmente, com base na sensibilidade e na experiência do pesquisador (Abelém, Pacheco & Vellasco, 1995).

Neste estudo, propõe-se uma abordagem estruturada de exploração de redes neurais para a avaliação de riscos de inadimplência, analisando o setor de transporte de carga rodoviário francês.

SISTEMAS DE INFORMAÇÃO NAS EMPRESAS: AVALIAÇÃO DE RISCOS DE INADIMPLÊNCIA E REDES NEURAIAS

O uso de um sistema de redes neurais para estimar riscos de inadimplência, por exemplo, a avaliação do risco na concessão de crédito, envolve muitas implicações estratégicas e organizacionais em empresas.

O uso estratégico das redes neurais

Desde Altman (1968), a avaliação de riscos de inadimplência é usualmente apoiada em instrumentos como o modelo ZETA, desenvolvido por meio de uso de análise discriminante multivariada (Altman, Haldeman & Narayanan, 1977) ou de regressão logística (Ohlson, 1980; Johnsen & Mellicker, 1994).

O uso de novas tecnologias de informação — como as redes neurais na área de crédito — começa a ser explorado na literatura e pode ser fonte de vantagem competitiva para uma empresa.

A Visa International, Inc. desenvolveu um sistema baseado em redes neurais para detecção de fraudes com cartões de crédito. Ainda em fase piloto em 15 instituições bancárias, em um ano o sistema propiciou uma economia de US\$ 2 milhões (Classe, 1995). O Mellon Bank, que conta com US\$ 31 bilhões em ativos, relata uma economia de US\$ 500 mil desde

Os autores agradecem, pelo apoio, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo (FEA/USP) e ao Professor Jean-Claude Courbon.

Recebido em julho/95
2ª versão em janeiro/96

Fernando C. de Almeida, Doutor em Administração pela *École Supérieure des Affaires* de Grenoble, França, é pesquisador do Departamento de Administração, área de Métodos Quantitativos e Informática, da Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo e colaborador de pesquisa da *École Supérieure des Affaires*.
Fax: (011) 814-5047
E-mail: falmeida@usp.br

Pascal Dumontier, Doutor em Administração com especialização em Finanças, é Professor Doutor da *École Supérieure des Affaires* de Grenoble, França.
Fax: (0033) 76825999
E-mail: dumontie@esa.grenet.fr

a utilização de um sistema similar de redes neurais para detectar fraudes com cartões (Purcell, 1994).

Os sistemas da Visa ou do Mellon Bank apresentam interessantes aspectos estratégicos: o melhor desempenho das redes neurais fornece aos bancos informações privilegiadas com relação a seus concorrentes. O sistema permite reduzir custos gerados por créditos não-reembolsados além de constituir fonte de diferenciação: o bloqueio do cartão roubado é feito mais rapidamente, dessa forma oferecendo maior segurança aos clientes.

Redes neurais no tratamento da informação

Dada a complexidade crescente do ambiente no qual as empresas estão inseridas, é necessário buscar de maneira prospectiva informações além de suas fronteiras, visando à obtenção de vantagens competitivas.

Os seguintes pontos enfatizam a importância da informação (Lesca & Almeida, 1994):

- permite reduzir a incerteza nos processos de tomada de decisão, aumentando sua qualidade e eficácia;
- aumenta o valor agregado de produtos e serviços.

Entendemos uma rede neural como um instrumento que permite às empresas explorarem seu ambiente de maneira privilegiada e assegurarem sua perenidade, transformando dados em informações úteis à tomada de decisão, aumentando o valor agregado dos seus produtos e serviços.

REDES NEURAIS

As redes neurais artificiais reproduzem o funcionamento do cérebro de maneira simplificada. Noções sobre o funcionamento da memória, como princípios associativos ou capacidade de aprendizado, por exemplo, inspiram os modelos de redes neurais artificiais (Kohonen, 1988). O uso de técnicas de representação do conhecimento sobre avaliação de riscos de inadimplência é de especial interesse. Tais técnicas podem tratar não apenas dados quantitativos, o caso dos métodos estatísticos, mas também dados qualitativos.

Redes *feed-forward*

Diversos modelos de redes neurais já são encon-

trados na literatura (Stanley, 1990). Os modelos são divididos em dois grupos principais: redes *feed-forward* e redes *feed-backward*. Uma rede neural compreende um conjunto de nós interligados. Esses dois modelos diferem quanto à maneira pela qual tais nós — os neurônios — se interligam para transmitir a informação. Em redes *feed-backward* há apenas uma camada de neurônios e todos interligados entre si.

Na realização da pesquisa que originou este artigo foram utilizadas redes *feed-forward*. Neste tipo de rede várias camadas são organizadas horizontalmente (figura 1). Cada neurônio conecta-se e envia informação para os demais da camada seguinte. Neurônios pertencentes à mesma camada não são interligados. Essas redes são freqüentemente constituídas de três camadas: a de entrada, com os neurônios de entrada; a intermediária, com os intermediários; e a de saída, com os de saída. Os neurônios de entrada introduzem informação na rede. Os de saída transmitem as respostas da rede. Neurônios e camadas intermediárias são colocados entre as camadas de entrada e saída.

O modelo de retropropagação é do tipo *feed-forward*, sendo o mais conhecido e referenciado na literatura (Sharda, 1994).

Neste estudo foi utilizado um modelo de retropropagação baseado nos Modelos de Processamento Distribuído Paralelo propostos por Rumelhart *et alii* (1986). A propagação de informação pela rede é efetuada como visualizado na figura 1: os valores de entrada são transmitidos de uma camada para a outra e transformados por meio de pesos de conexões entre os neurônios (W_{ji} : peso da conexão entre o neurônio I e o neurônio J). A rede acumula seu conhecimento pelos pesos de conexão.

Podemos tomar como exemplo um neurônio J na camada J :

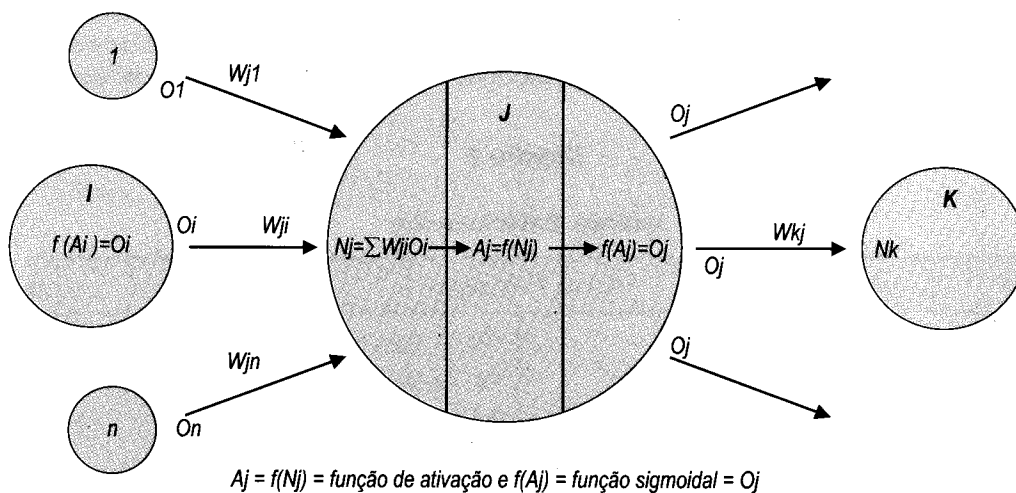


Figura 1: Propagação de Sinais na Rede Neural

- o neurônio J recebe as saídas O_i dos neurônios precedentes e o valor N_j é computado: $N_j = \sum W_{ji} O_i$,
- N_j é introduzido em função de ativação $f(N_j)$ que produz o valor de ativação A_j . No modelo de Rumelhart *et alii* o valor de ativação é igual a N_j ;
- a intensidade do sinal enviado de um neurônio para o outro é uma função da intensidade do valor de ativação. Uma função de transferência leva em consideração o valor de ativação e produz o sinal de saída O_j .

$$O_j(t+1) = \frac{1}{1 + e^{-(\sum W_{ji} O_i + \theta_j)}} \quad [1]$$

O método de aprendizado por retropropagação

As redes são construídas, isto é, pesos de conexão apropriados entre os neurônios são determinados, usando-se um método de aprendizado. Esses pesos são geralmente valores arbitrários no início do processo e vão sendo corrigidos enquanto o aprendizado evolui com a utilização de exemplos (ou fatos) representativos do problema em estudo. A retropropagação é um método de aprendizado supervisionado pois os resultados observados na saída dos neurônios são usados para ajustar os pesos de conexão. O vetor obtido na saída dos neurônios é comparado com o vetor de saída desejado. Se houver diferença entre os dois vetores os pesos de conexão são corrigidos, resultando em aprendizado.

O modelo de Rumelhart *et alii* é baseado na regra de aprendizado denominada Regra Delta Generalizada:

$$\Delta W_{ji}(n+1) = \mu \delta_j O_i + \alpha \Delta W_{ji}(n) \quad [2]$$

$\Delta W_{ji}(n+1)$ é o ajuste introduzido em $n+1$ no peso de conexão entre os neurônios i e j , μ é uma constante chamada taxa de aprendizado que controla a intensidade de correção feita nos pesos de conexão a cada iteração do processo. Quanto maior a taxa de aprendizado maio-

res as mudanças que serão introduzidas nos pesos em cada iteração; α é uma constante chamada fator suavizante que faz o processo de aprendizado considerar o valor do peso no momento n ; δ é o sinal de erro na saída do neurônio.

ANÁLISE DE RISCOS DE INADIMPLÊNCIA: VISÃO GERAL DO PROCESSO

A maioria dos modelos de avaliação de riscos de inadimplência é construída com o uso de amostras pareadas: parte da amostra contém informações sobre empresas inadimplentes; outra, informações sobre empresas não-inadimplentes. Variáveis são selecionadas segundo o interesse potencial na avaliação de riscos de inadimplência. Um método estatístico é então usado para desenvolver um modelo discriminante (combinação de variáveis que melhor identifique os dois tipos de empresa). Finalmente o sucesso da discriminação é avaliado por meio de uma amostra de controle (diferente da utilizada para a obtenção do modelo).

ANÁLISE QUANTITATIVA

Seleção de amostras e coleta de dados

A amostragem de dados utilizada para o desenvolvimento deste estudo consiste de 2.736 empresas francesas pertencentes à indústria de transportes, incluindo 114 inadimplentes no período de 1988 a 1990. A definição de inadimplência adotada é puramente legal: empresas inadimplentes são aquelas cuja falência foi sancionada por procedimentos judiciais.

Pela falta de fundamentos teóricos sobre variáveis relevantes para a avaliação de riscos de inadimplência, as preditivas foram selecionadas devido a seu sucesso em estudos anteriores (Dumontier, 1990). Dois conjuntos de índices financeiros disponíveis durante os períodos de um e

dois anos antes da inadimplência foram usados. O primeiro contém apenas seis variáveis (R1, R2, R3, R4, R6, R12). Seis outros índices (R5, R7, R8, R9, R10, R11) são introduzidos para a obtenção do segundo conjunto (ver quadro 1). Devido à não-disponibilidade de dados, 322 empresas foram excluídas da amostragem inicial. Portanto, a amostragem final consistiu de 76 empresas inadimplentes e 2.338 não-inadimplentes.

Quadro 1

Índices Selecionados

Índices Financeiros	
R1 = Receitas Líquidas/Total Ativo	R7 = Receita Operacional/Total Ativo
R2 = Total de Dívidas/Total Ativo	R8 = Vendas/Ativo Fixo
R3 = Disponibilidades/Receitas Líquidas	R9 = Disponibilidades/Total Ativo
R4 = Ativo Circulante/Passivo Circulante	R10 = Estoques/Vendas
R5 = Receita Operacional/Encargos Financeiros	R11 = Estoques/Contas a Receber
R6 = Receita Total/Total Ativo	R12 = log (Total Ativo)

Escolha de um método estatístico

A identificação de características que permitam distinguir empresas inadimplentes das não-inadimplentes tem pelo menos dois aspectos críticos:

- devido à falta de teoria sobre falência, em qualquer escolha de variáveis preditivas que se faça pode ocorrer a desconsideração de algumas importantes;
- relações complexas entre as variáveis preditivas podem alterar a capacidade de previsão dos modelos.

Como as redes neurais têm capacidade de tratar dados incompletos e distorcidos, produzindo resultados satisfatórios a partir de generalizações, espera-se que estas possam obter bom desempenho na avaliação de riscos de inadimplência. A fim de avaliar o desempenho das redes neurais, porém, seu poder discriminante é aqui comparado com uma regressão logística (LOGIT). Optou-se pela regressão logística ao invés de outras análises mais comuns, como a análise discriminante multivariada, por ser uma regressão no mínimo tão eficiente quanto uma classificação linear, mesmo quando todas as hipóteses da análise discriminante são satisfeitas (Press & Wilson, 1978).

Desde Ohlson (1980) a análise LOGIT é usada, frequentemente, para a avaliação de riscos de inadimplência, baseada em características financeiras (índices) das empresas. O modelo LOGIT cria para cada empresa um escore Z :

$$Z = \alpha + \beta X_i \quad [3]$$

onde X_i é o valor da i -ésima variável (características financeiras):

$$P = \frac{1}{1 + e^{-(\alpha + \beta X_i)}} \quad [4]$$

Como P sempre se situa entre 0 e 1, o escore Z é frequentemente interpretado como a probabilidade de inadimplência.

Incorporando probabilidades *a priori* e custo de classificação incorreta

A probabilidade *a priori* de inadimplência e o custo de classificação incorreta devem ser estabelecidos para garantir a precisão do modelo. Há dois tipos de erro de classificação: o primeiro, chamado Erro Tipo I, consiste em classificar uma empresa inadimplente como não-inadimplente. O Erro Tipo II, em classificar uma empresa não-inadimplente no grupo das inadimplentes.

Um ponto de corte (*cut off-score*) é escolhido de modo a minimizar o erro de classificação nos dois grupos. Tanto para as redes neurais quanto para a regressão logística,

esse valor pode variar de 0 a 1 uma vez que a probabilidade de inadimplência é igual a 1 para empresas inadimplentes e 0 para empresas não-inadimplentes.

Validação dos resultados

Como um modelo em geral adequa-se perfeitamente à amostra a partir da qual foi derivado, duas subamostras foram selecionadas aleatoriamente a partir das 2.414 empresas do estudo. A primeira, usada para a obtenção dos modelos; a segunda, para testar sua capacidade de classificação.

Abordagem de concepção de redes neurais

Devido aos inúmeros parâmetros que podem ser alterados na configuração de uma rede neural (número de camadas, número de neurônios intermediários, método de aprendizado etc.) e ao tempo necessário para explorar a influência desses parâmetros, uma abordagem estruturada de concepção de redes neurais torna-se necessária. Normalmente os diversos pesquisadores têm se limitado à exploração de apenas algumas configurações de rede, sem um critério explícito para sua escolha (entre eles, Tam & Kiang, 1992; Abelém, Pacheco & Vellasco, 1995).

Existem técnicas que procuram auxiliar na identificação de uma arquitetura ideal para a rede, eliminando neurônios redundantes ou compartilhamento de pesos (Hertz, Krogh & Palmer, 1991). No entanto, nem sempre tais técnicas são aplicáveis a qualquer tipo de problema. Assim, uma abordagem estruturada é proposta neste trabalho. Nele, propõe-se a concepção e a execução de um plano experimental para explorar a influência de vários parâmetros sobre o desempenho das redes. A avaliação do plano é feita por meio de uma análise gráfica. As redes de melhor desempenho são introduzidas em um portfólio a fim de determinar os riscos de inadimplência. Um portfólio de redes é um grupo de redes selecionadas de um grande número de experimentos elaborados a partir do plano experimental. O portfólio reúne determinado número de redes ótimas incorporando conhecimentos sobre avaliação de riscos de inadimplência e pode servir como base de conhecimento a ser introduzido em um sistema de apoio à decisão. A utilização de um portfólio de redes permite atenuar o erro produzido pelo uso de apenas uma rede.

O desempenho é avaliado considerando-se a porcentagem de empresas classificadas corretamente em cada um dos dois grupos de empresas (inadimplentes e não-inadimplentes).

A abordagem proposta segue os seguintes passos:

- definição de um plano experimental;
- construção das redes neurais a partir do plano experimental;

- análise gráfica dos resultados de classificação das redes neurais;
- identificação de um portfólio de redes.

Definição de um plano experimental

Os elementos a seguir foram explorados pelo plano experimental (quadro 2).

O uso de dados históricos

Três maneiras de introduzir dados históricos foram utilizadas:

- H1 — introduzidos os valores de um (R_{n-1}) e dois anos (R_{n-2}), antes da inadimplência.
- H2 — introduzidos valores um ano antes da inadimplência (R_{n-1}) e a diferença entre dois valores da mesma variável um e dois anos antes da inadimplência ($\Delta R = R_{n-1} - R_{n-2}$).
- H3 — introduzidos valores de cada variável um ano antes da inadimplência (R_{n-1}) e a razão entre valores da mesma variável um e dois anos antes da inadimplência ($\Delta R = R_{n-1} / R_{n-2}$). A não-consideração de dados históricos é representada por I, onde dados um ano antes da falência são introduzidos.

Número de neurônios nas camadas intermediárias

O número de neurônios intermediários e camadas intermediárias não tem um limite teórico. Tal limite é apenas imposto por custos, tempo e limitações computacionais na criação de uma rede. Para este trabalho, os neurônios intermediários foram explorados utilizando-se 5, 10, 40 ou 80 neurônios em cada camada intermediária.

Quadro 2

O Plano Experimental

Número de Índices	Número de Neurônios na Camada Intermediária	Primeiro Conjunto de Índices (6 índices)				Segundo Conjunto de Índices (12 índices)			
		I	H1	H2	H3	I	H1	H2	H3
Uma Camada	5								
	10								
	40								
	80								
Duas Camadas	5 5								
	10 10								
	40 40								

Número de neurônios intermediários

Como o tempo necessário para treinar uma rede aumenta com o número de camadas, somente duas camadas intermediárias foram utilizadas. Foi limitado também o número de neurônios a 40 no caso de redes com duas camadas intermediárias. Três configurações foram testadas:

- 5 neurônios na primeira camada intermediária e 5 na segunda;
- 10 em uma das camadas e 10 na outra;
- 40 neurônios em cada camada intermediária.

Índices preditivos

Uma vez que os índices mais relevantes para a previsão de inadimplência não são totalmente conhecidos, duas baterias de índices foram usadas.

Construção de redes neurais a partir do plano experimental

Número de experimentos

Quanto maior for o número de experiências por célula (aproximadamente oito minutos nas nossas experiências), mais representativo será o plano experimental. Todavia, em razão do tempo necessário para treinar uma rede, o número de experiências deve ser cuidadosamente avaliado. O número de experiências realizadas para este trabalho foi limitado a 10 por configuração de rede no plano experimental (560 redes criadas no total).

A proporção entre empresas inadimplentes e não-inadimplentes foi de 1:3, proporção escolhida para aumentar a representatividade de empresas não-inadimplentes nas amostras. Pode-se notar que a proporção não é condizente com a distribuição real de empresas inadimplentes e não-inadimplentes na população. No entanto, a inclusão de maior número de empresas não-inadimplentes aumentaria o tempo de aprendizado e, dessa forma, os custos computacionais.

O algoritmo de aprendizado das redes neurais poderia ter sido transformado para levar em conta a probabilidade da inadimplência, como sugerido por Tam & Kiang (1992). No entanto, o pacote utilizado não permitiu esse tipo de correção.

Número de iterações

Iteração é a leitura completa do conjunto de dados durante o processo de aprendizado. O processo de aprendizado de algumas redes neurais foi convergente (a rede aprendeu todos os exemplos dentro da precisão fixada de θ , T). Algumas redes, porém, não convergiram depois de certo número de iterações. Baseado no erro médio observado (aquele observado na saída de cada neurônio, dividido pelo número de neurônios e multiplicado pelo total de exemplos — ou fatos — contidos na subamostra de teste), o processo de aprendizado foi interrompido após 1.300 iterações.

Automatização da experimentação

Devido ao grande número de experimentos propostos no plano experimental, estes foram realizados por meio de um sistema desenvolvido em linguagem de gerenciamento de banco de dados para microcomputador. Esse sistema permite integrar os diferentes estágios e ferramentas (banco de dados, *software* de rede neural) necessários à construção das redes. O sistema possibilita realizar rapidamente grande número de testes, sem passar pelo modo interativo da ferramenta de desenvolvimento de redes neurais. Para esta pesquisa, o sistema consumiu tempo considerável de desenvolvimento (4.500 linhas de programa em *Clipper*).

Análise gráfica dos resultados obtidos com as redes neurais

Uma análise gráfica foi elaborada para avaliar o desempenho das redes treinadas (gráficos de 1 a 4). Como já mencionado, ao considerar-se um ponto de corte para classificar uma empresa em um dos dois grupos (inadimplente e não-inadimplente) há dois tipos de erros de classificação possíveis: o do tipo I e o do tipo II. Por meio de análise gráfica vários pontos de corte podem ser considerados e o desempenho da rede observado para vários níveis de erro. Foram usados para pontos de corte: 0,95; 0,9; 0,7; 0,5; 0,3; 0,1; 0,05 e 0,01.

Como foram selecionadas aleatoriamente 10 subamostras para criar 10 vezes a mesma configuração de redes (56 configurações no plano experimental), a média (μ) e o desvio padrão (σ) da porcentagem de empresas corretamente classificadas para cada grupo de 10 redes foram calculados para cada uma das 56 configurações.

As redes foram reunidas em quatro grupos segundo sua semelhança de desempenho: as de melhor desempenho no grupo 1 com 6 redes; no grupo 2, 10 redes; no grupo 3, 12 redes; as consideradas com pior desempenho no grupo 4, com 24 redes.

C-I-H-N representa a configuração da rede e os dados usados para criá-la. Por exemplo, 1-2-I-5 significa 1 camada intermediária (1), segundo conjunto de índices (2), sem dados históricos (I), 5 neurônios na camada intermediária (5).

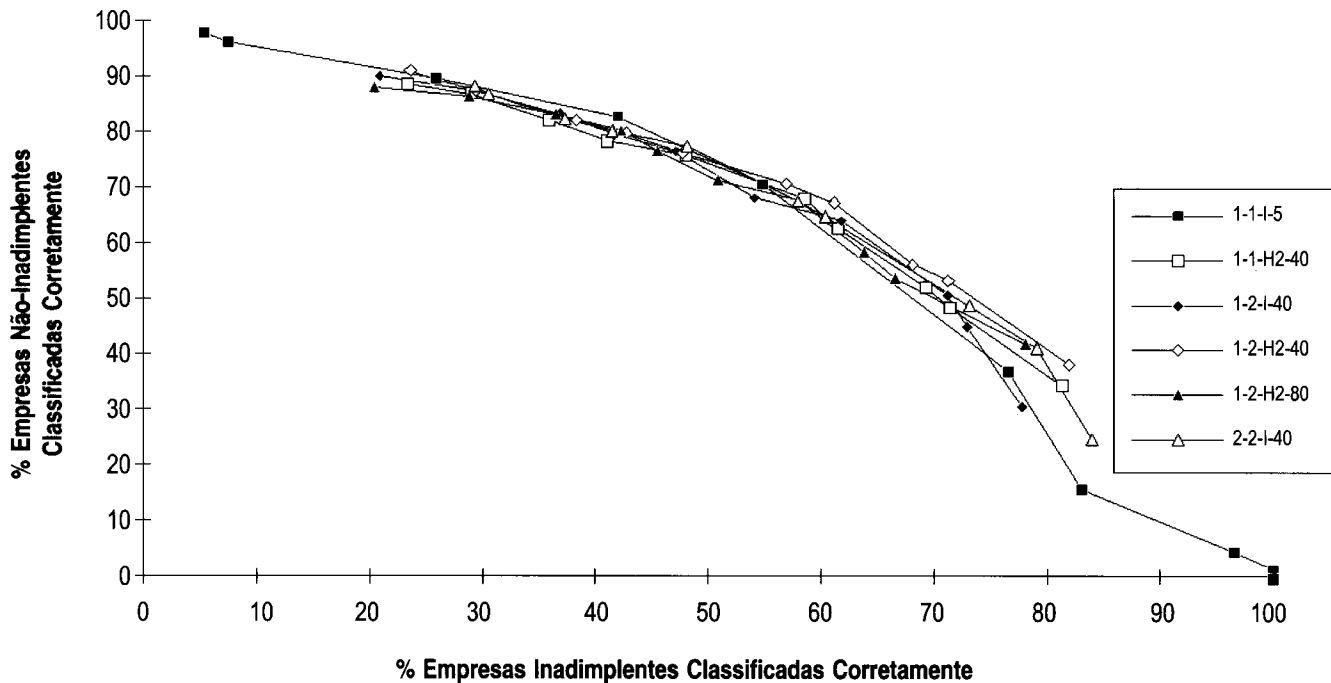


Gráfico 1: As Seis Redes de Melhor Desempenho (Primeiro Grupo)

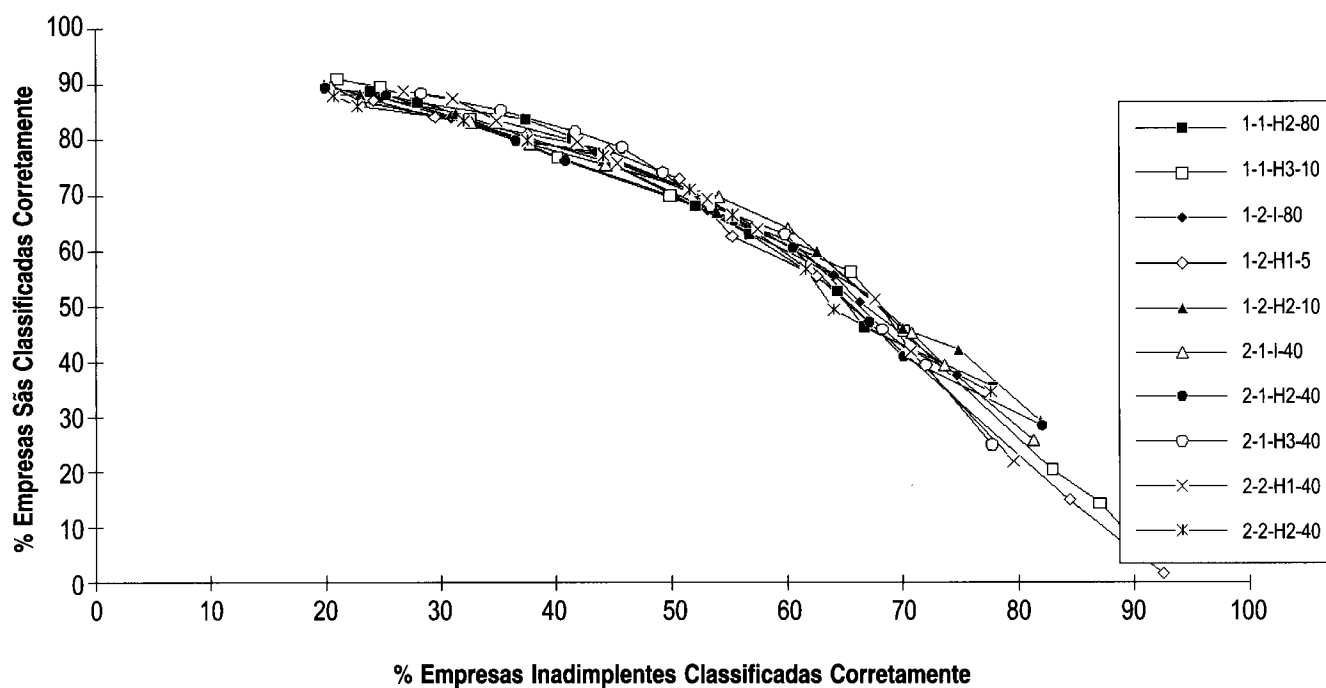


Gráfico 2: Grupo de Dez Redes (Segundo Grupo)




Gráfico 3: Grupo de Doze Redes (Terceiro Grupo)




Gráfico 4: As Vinte e Quatro Redes de Pior Desempenho (8/24) (Quarto Grupo)

Resultado da análise gráfica

Observando-se as diferentes curvas pode-se notar que nem sempre é possível identificar a configuração de melhor desempenho. Os quadros 3 e 4 indicam quatro grupos de redes obtidos pela análise gráfica. O desempenho da configuração varia com o ponto de corte. Dessa forma, um portfólio de seis redes foi identificado por conter aquelas com melhor desempenho dentre as 56 estruturas exploradas.

usando-se 40 neurônios na camada intermediária (1-1-H2-40; 1-2-I-40; 1-2-H2-40), 40 neurônios podem produzir em certos momentos redes de baixo desempenho (1-1-I-40; 1-2-H1-40 etc.). A análise gráfica e os quadros 3 e 4 sugerem as conclusões a seguir.

Uso de dados históricos

Pode-se observar que redes construídas com dados no formato H3 foram quase sempre as de pior desem-

Influência do tipo de estrutura no desempenho da rede

Pode-se notar, pelos resultados obtidos, que o uso sistemático de um tipo de estrutura de rede nem sempre produz a rede com melhor desempenho. Em outras palavras, mesmo que algumas das redes com melhor desempenho fossem obtidas

Quadro 3

As Dezesesseis Redes de Melhor Desempenho (Primeiro e Segundo Grupos)

Número de Camadas	Número de Neurônios por Camada	Primeiro Conjunto de Índices (6 índices)				Segundo Conjunto de Índices (12 índices)			
		I	H1	H2	H3	I	H1	H2	H3
Uma Camada	5	☺					☹		
	10				☺			☹	
	40			☺		☺		☺	
	80			☹		☹	☹ or ☹?	☺	
Duas Camadas	5 5								
	10 10			☹ or ☹?					
	40 40	☺		☺	☺	☺	☺	☺	

Quadro 4

As Redes de Pior Desempenho (Terceiro e Quarto Grupos)

Número de Camadas	Número de Neurônios por Camada	Primeiro Conjunto de Índices (6 índices)				Segundo Conjunto de Índices (12 índices)			
		I	H1	H2	H3	I	H1	H2	H3
Uma Camada	5		⊗	⊗	⊗	⊗		⊗	⊗
	10	⊗	⊗	⊗		⊗	⊗		⊗
	40	⊗	⊗		⊗		⊗		⊗
	80	⊗	⊗		⊗				⊗
Duas Camadas	5 5	⊗	⊗	⊗	⊗	⊗	⊗	⊗	⊗
	10 10	⊗	⊗		⊗	⊗	⊗	⊗	⊗
	40 40		⊗ or ⊗?						⊗

Número de camadas

Não se conclui sobre o interesse em usar duas camadas na observação de riscos de inadimplência. Em certos momentos uma rede com apenas uma camada desempenha melhor resultado do que duas camadas de rede. Em outros, o resultado é o oposto.

Número de índices

penho. H2 apresentou os melhores resultados (8 redes entre as melhores 16), superior a I (5/16) ou H1(3/16). Estes resultados sugerem inferências interessantes: usando-se a razão entre os valores dos dados históricos, os resultados obtidos são insatisfatórios (H3); as redes são capazes, por elas mesmas, de encontrar as relações mais satisfatórias entre os dados nos diferentes anos (H2).

Os resultados são compatíveis com a consideração de Stanley (1990) referente ao uso de dados históricos. O autor sugere que melhores redes podem ser obtidas quando se usa a diferença entre o valor de dois anos (H2) do que quando se usa os valores por si mesmos (H1).

Finalmente, as melhores redes foram obtidas usando-se H2 em vez de I, o que sugere a conveniência em se usar dados históricos.

Número de neurônios

Redes com 5 ou 10 neurônios geraram redes de baixo desempenho, apesar de algumas configurações desse tipo encontrarem-se entre as melhores. Não foi possível, portanto, chegar a uma conclusão sobre a utilização de poucos neurônios.

Não houve diferença significativa de desempenho das redes com a variação do conjunto de índices utilizado.

Comparação das redes neurais com regressão logística

A fim de se comparar o desempenho da rede com a utilização de métodos estatísticos, a mesma amostra de dados foi usada. O gráfico 5 compara os resultados obtidos com ambas as técnicas. Pode-se notar que os seus desempenhos foram bastante semelhantes. Ambos os gráficos foram construídos usando-se o mesmo intervalo de

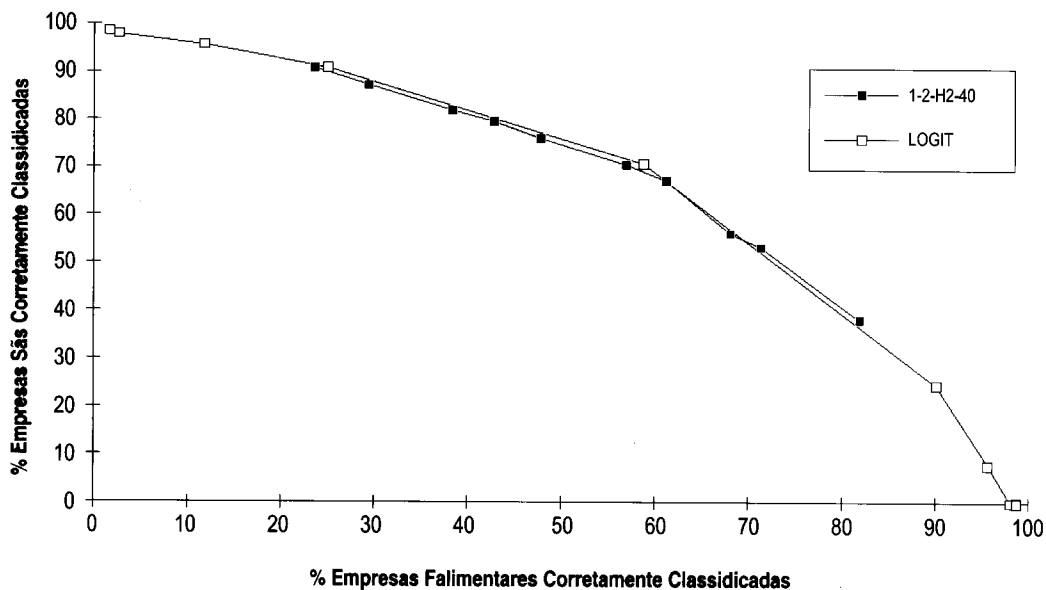


Gráfico 5: Comparação entre Redes Neurais e Regressão Logística

ponto de corte (de 0,95 a 0,001). Todavia, pode-se observar que o LOGIT é mais sensível a mudanças no ponto de corte do que as redes que têm menor amplitude da curva. Deduz-se, assim, que a capacidade de previsão das redes é mais estável do que a do LOGIT, a qual muda mais abruptamente quando o ponto de corte varia. Em uma situação de tomada de decisão, quando os riscos de erro relacionados ao ponto de corte são desconhecidos, previsões feitas com as redes neurais são mais confiáveis do que as feitas pelo modelo LOGIT, uma vez que pequenas mudanças no ponto de corte não incorrem em mudança significativa da previsão resultante.

PROCESSO DE INADIMPLÊNCIA

Análise do processo de falência por meio das redes neurais

Se a preocupação do tomador de decisão é a obtenção de uma ferramenta adequada à previsão de inadimplência, ao pesquisador em finanças interessa principalmente compreender os mecanismos e o processo de inadimplência.

Alguns consideram limitada a capacidade das redes neurais em esclarecer de que maneira as variáveis explicativas dos fenômenos (índices financeiros) são levadas em conta pelas redes para chegar-se a uma resposta, no caso para chegar-se ao risco de inadimplência (Tam & Kiang, 1992). A observação dos pesos de conexão entre os neurônios não permite que se chegue a uma conclusão. No caso de regressão logística, basta observar os valores dos coeficientes da função discriminante para saber-se de que maneira cada índice influencia o resultado da função (quadro 5).

No entanto, em nossa opinião, tal função representa de maneira linear e bastante redutora o fenômeno de inadimplência. As redes neurais têm uma representação consideravelmente mais complexa do que uma função logística, pois cada neurônio pode ser encarado como sendo uma função logística (ver equação 1).

Mesmo não sendo possível interpretar os pesos de conexão entre os neurônios, pode-se fazer uma análise de sensibilidade com a rede, variando os valores de determinado índice financeiro e fixando os outros. A figura 2 representa a análise da influência dos índices para uma determinada empresa. Comparando-se essa figura com o que se obtém com a regressão logística nota-se, por exemplo, que os R2 (Total de Dívidas/Total Ativo) e R8 (Vendas/Ativo Fixo) têm forte influência no resultado apresentado pela rede. O R2 tem correlação positiva (barra preta à direita) e o R8 correlação negativa com a falência (barra preta à esquerda). No que diz respeito à regressão logística, para a mesma subamostra usada para analisar a rede, apenas R3 (Disponibilidades/Receitas Líquidas) e R4 (Ativo Circulante/Passivo Circulante) foram significativos (quadro 5). A rede mostra, porém, que a empresa em questão, apesar de não-inadimplente, é bastante sensível a variações no seu nível de endividamento, o que poderia significar que um aumento do nível de seu endividamento aumentaria significativamente o risco de se tornar inadimplente. Os dados de outras empresas foram introduzidos na rede, sendo feitas análises de sensibilidade. Pôde-se observar que a rede portou-se de maneira distinta, mostrando variação na importância de cada índice, segundo a empresa. Por uma questão de espaço, não são aqui demonstrados esses resultados.

A influência da técnica sobre a observação do fenômeno de falência

Os métodos quantitativos e estatísticos foram, até o presente, os únicos instrumentos por meio dos quais era possível analisar a inadimplência e a influência das variáveis preditivas para a previsão de inadimplência.

Na verdade, os instrumentos utilizados para observar um fenômeno exercem forte influência sobre a compreensão desse fenômeno. Cada época possui um conjunto de metáforas que instigam o pensamento em determinada direção. Dessa maneira, as estruturas convencionais dos computadores induziram as pesquisas cognitivas e a com-

Quadro 5

Coefficientes da Função Logística Criada para a Primeira Subamostra de Dados

Subamostra	Const	C1	C3	C4	C5	C10	C11
1	-1,268	0,1163	-9,4689	-2,3063	0,0329	8,0016	-0,1827
Teste t-Student	-1,9	0,5	-3,1	-3,4	1,1	1,2	-0,3
Probabilidade	0,056	0,63	0,002	0,001	0,282	0,205	0,762

$$Pr(\text{ob(inadimplência} = 1) = \text{LOGIT} (-1,268 + 0,1163R1 - 9,4689R3 - 2,3063R4 + 0,0329R5 + 8,0016R10 - 0,1827R11)$$




Figura 2: STE Nouvelle Boniface Internacional (Empresa Não-Inadimplente)

preensão do cérebro humano em direção à Inteligência Artificial. Os processamentos paralelos e as redes neurais permitem que as pesquisas cognitivas caminhem segundo uma nova metáfora. O mesmo deve ocorrer com relação à avaliação de riscos de inadimplência. As conclusões sobre a compreensão do fenômeno de inadimplência, às quais chegaram os pesquisadores até o momento, foram certamente influenciadas por métodos que simplificam e restringem as relações entre as variáveis explicativas, como é o caso da regressão logística. Um modelo representado por uma função logística é uma grande simplificação do processo de inadimplência. O representado pelas redes neurais é significativamente mais complexo.

CONCLUSÕES

Neste estudo discute-se o uso de redes neurais para a avaliação de riscos de inadimplência.

Indica-se a importância do uso de um sistema e de um *software* que permitam a exploração automática dos diversos parâmetros de concepção das redes neurais. Uma vez que pequeno número de testes não é suficiente para comparar várias redes, a sua construção manual não é um procedimento viável desde que pode introduzir erro no tratamento dos dados, além de consumir tempo excessivo. O desenvolvimento deste *software* exigiu esforço considerável.

A necessidade de construção de um plano experimental para a exploração de grande número de parâmetros indica a dificuldade em construir uma rede neural para suportar um processo de decisão. Este fator não é normalmente explorado na literatura.

A ausência de uma teoria de falência traz dificuldades adicionais na escolha apropriada das variáveis preditivas. Outras variáveis, que não as utilizadas neste estudo, poderiam eventualmente obter melhores resultados de previsão. Seria interessante utilizar as próprias variáveis contábeis em vez de índices.

No que diz respeito ao interesse em utilizar o mé-

todo gráfico, a comparação rigorosa dos desempenhos das várias redes não deve ser a maior preocupação do tomador de decisão. A identificação de um conjunto ótimo de redes é provavelmente suficiente para suportar o processo de decisão na avaliação de riscos de inadimplência. Por esta razão, a análise gráfica é neste caso uma técnica satisfatória.

Por este estudo é introduzido um método estruturado de exploração de redes neurais na avaliação de riscos de inadimplência. Outros métodos deveriam também ser explorados de maneira aprofundada. Estudos sobre o uso de redes neurais em administração em geral não discutem a exploração de diferentes parâmetros na sua concepção. Outros parâmetros, diferentes dos apresentados neste estudo, deveriam ser explorados em pesquisas futuras.

Neste estudo foi considerado o setor francês de transporte. O desempenho das redes neurais não foi significativamente superior ao desempenho do método estatístico. É possível que em outros setores, nos quais outras variáveis, diferentes das usadas neste estudo, sejam utilizadas, o desempenho seja superior. Outras áreas potenciais de aplicação das redes neurais são exploradas por Almeida (1994).

Este estudo diz respeito ao problema de desenvolvimento de redes neurais na avaliação de riscos de inadimplência. Outros estudos poderiam explorar de maneira mais aprofundada a compreensão do processo de falência através do seu uso. As redes neurais não mostram o mesmo comportamento da regressão logística, mas elas poderão eventualmente trazer novas perspectivas ao problema de interpretação do processo de inadimplência. ♦

RESUMO

Neste estudo é explorado o uso de redes neurais para a avaliação de riscos de inadimplência. Propõe-se uma abordagem estruturada de exploração de redes neurais avaliando o setor de transporte rodoviário francês. A avaliação do desempenho das redes neurais é realizada pela comparação desta técnica com a de regressão logística. A construção de um plano experimental e de uma análise gráfica permite a exploração de número significativo de configurações de redes. Apesar da obtenção de resultados positivos pela utilização de redes neurais, destaca-se neste estudo as dificuldades no uso desta técnica.

Palavras-chave: redes neurais, riscos de inadimplência, regressão logística, metodologia.

ABSTRACT

In this study is explored the use of neural networks to evaluate corporate bankruptcy risks. It proposes a neural network structured evaluation approach to evaluate the French route transportation system. Bankruptcy risk evaluation is explored in this paper comparing neural networks performance with the logistic regression technique. Neural networks show interesting performance in comparison with logistic regression. However, in this study is also showing some important difficulties in using this technique.

Uniterms: neural networks, bankruptcy prediction, logistic regression, methodology.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABELÉM, A.J.; PACHECO, M. A.; VELLASCO, M.M.B.R. Modelagem de redes neurais artificiais para previsão de séries temporais. SIMPÓSIO BRASILEIRO DE REDES NEURAS, 2. *Anais...* p.107-112, out. 1995.
- ALMEIDA, F.C. de. *L'évaluation des risques de défaillance des entreprises à partir des réseaux de neurones insérés dans les systèmes d'aide à la décision*. Tese (Doutorado) em Administração. Grenoble, 1993. École Supérieure des Affaires, Universidade de Grenoble.
- _____. Desvendando o uso de redes neurais em problemas de administração de empresa. *Revista de Administração de Empresas*, v.35, n.1, p.46-55, 1995.
- ALTMAN, E. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, v.23, n.4, p.589-609, set. 1968.
- ALTMAN, E.; HALDEMAN, R.; NARAYANAN, P. Zeta analysis. *Journal of Banking and Finance*, p.29-54, jun. 1977.
- CLASSE, A. Caught in the neural net. *Accountancy*, p. 58-59, fev. 1995.
- DUMONTIER, P. Vices et vertus des modèles de prévision de défaillance. *Papier de Recherche* n.90-12, Grenoble, Université de Grenoble II, CERAG, 1990.
- HERTZ, J.; KROGH, A.; PALMER, R.G. *Introduction to theory of neural computing*. Redwood City, Addison-Wesley, 1991.
- JOHNSON, T. & MELICHER, R.W. Predicting corporate bankruptcy and financial distress: information value added by multinomial logit models. *Journal of Economics & Business*, v.46, n.4, p.269-286, out. 1994.
- KOHONEN, T. An introduction to neural computing. *Neural Networks*, v.1, p.3-16, 1988.
- LESCA, H. & ALMEIDA, F.C. de. Administração estratégica da informação. *Revista de Administração*, v.29, n.3, p.66-75, jul./set.1994.
- OHLSON, J.A. Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, p.109-131, Spring 1980.
- PODDIG, T. Bankruptcy prediction: a comparison with discriminant analysis. REFENES, A.P. *Neural networks in capital markets*. New York, John Wiley & Sons, 1995. p.311-340.
- PRESS, D.J. & WILSON, S. Choosing between logistic regression and discriminant analysis. *Journal of American Statistical Economics*, p.3-35, 1986.
- PURCELL, L. Roping in risk. *Bank Systems & Technology*, v.31, n.5, p.64-68, 1994.
- RUMELHART, D.E.; MCCLELLAND, J.C.; PDP Research Group. *Parallel distributed processing: exploration in the microtexture of cognition*, v.1. London, The MIT Press, 1986.
- SHARDA, R. Neural networks for the MS/OR analyst: an application bibliography. *Interfaces*, v.24, n.2, p.116-130, 1994.
- STANLEY J. *Introduction to neural networks*, 3rd. ed. California, Sierra Madre, Cal. Scientific Software, 1990.
- TAM, K.T. & KIANG, M.Y. Managerial applications of neural networks: the case of bank failure predictions. *Management Science*, v.38, p.926-947, 1992.
- WILSON, R.L. & SHARDA, R. Bankruptcy prediction using neural networks. *Decision Support Systems*, v.11, n.5, p.545-557, jun. 1994.