

# **AVALIAÇÃO DE INSOLVÊNCIA DE BANCOS BRASILEIROS POR MEIO DE REDES NEURAIIS**

**Fernando C. de Almeida** (\*)

**Alberto Borges Matias**

Faculdade de Economia, Administração e Contabilidade - Universidade de São Paulo

Departamento de Administração

Métodos Quantitativos - Sala AS 34

FEA/USP

Cx. Postal 11.498

05422-970 - São Paulo -S.P

Email: [falmeida@usp.br](mailto:falmeida@usp.br)

[matias@usp.br](mailto:matias@usp.br)

## **Resumo**

Diversos estudos tem explorado o uso de redes neurais na avaliação de riscos de insolvência nos últimos anos. Este estudo explora, em particular, o setor bancário brasileiro. A avaliação de risco de insolvência de bancos brasileiros, é uma questão particularmente importante, no contexto econômico atual. Em função do processo de estabilização da moeda brasileira, os bancos brasileiros, tem sido obrigados a passar por processo rigoroso de adaptação. A técnica de redes neurais é aqui explorada em termos de sua capacidade de distinção do risco de insolvência das instituições analisadas. Seus resultados de previsão são comparados com os resultados feitos por uma instituição nacional de análise de crédito. Índices financeiros são explorados na construção da ferramenta de redes neurais.

**Area Temática: Finanças**

---

(\*) Agradecemos ao CNPq pelo suporte financeiro às nossas pesquisas, bem como à FEA/USP e aos Profs Nicolau Reinhard e Ronaldo Zwicker por nos acolher como pesquisadores.

# **AVALIAÇÃO DE INSOLVÊNCIA DE BANCOS BRASILEIROS POR MEIO DE REDES NEURAIS**

Diversos estudos tem explorado o uso de redes neurais na avaliação de riscos de insolvência nos últimos anos (DE ALMEIDA 1993; WILSON & SHARDA 1994; PODDIG 1995; etc.). Este estudo explora, em particular, o setor bancário brasileiro. A avaliação de risco de insolvência de bancos brasileiros, é uma questão particularmente importante, no contexto econômico atual. Em função do processo de estabilização da moeda brasileira, os bancos brasileiros, tem sido obrigados a passar por processo rigoroso de adaptação: a forte e rápida redução dos ganhos inflacionários forçou os bancos a aumentarem seus volumes de crédito e, em consequência, os volumes de créditos em liquidação, em momento econômico marcado por elevação dos níveis de recolhimento compulsório. Em decorrência da necessidade de fortes ajustes afloraram problemas de liquidez, levando o Banco Central a decretar a liquidação de diversas instituições e efetivar intervenção em diversas outras.

## **1. Avaliação de Riscos de Insolvência**

A avaliação de riscos de insolvência tem sido extensamente efetuada a partir da década de 60, essencialmente voltada para o segmento empresarial não-financeiro (COHEN 1966, BEAVER 1966, ALTMAN 1968, ABATE 1969), fundamentados no uso de regressão e análise discriminante. Só mais recentemente partiu-se para a utilização de redes neurais na avaliação de riscos de insolvência, ainda no segmento não-financeiro das economias (DUMONTIER 1990, ALMEIDA 1993, JOHNSEN 1994, WILSON 1994, PODDIG 1995). A insolvência bancária no Brasil constitui-se em segmento novo de pesquisa, notadamente em razão da política governamental de suporte ao sistema financeiro até agora.

## **2. Redes Neurais**

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

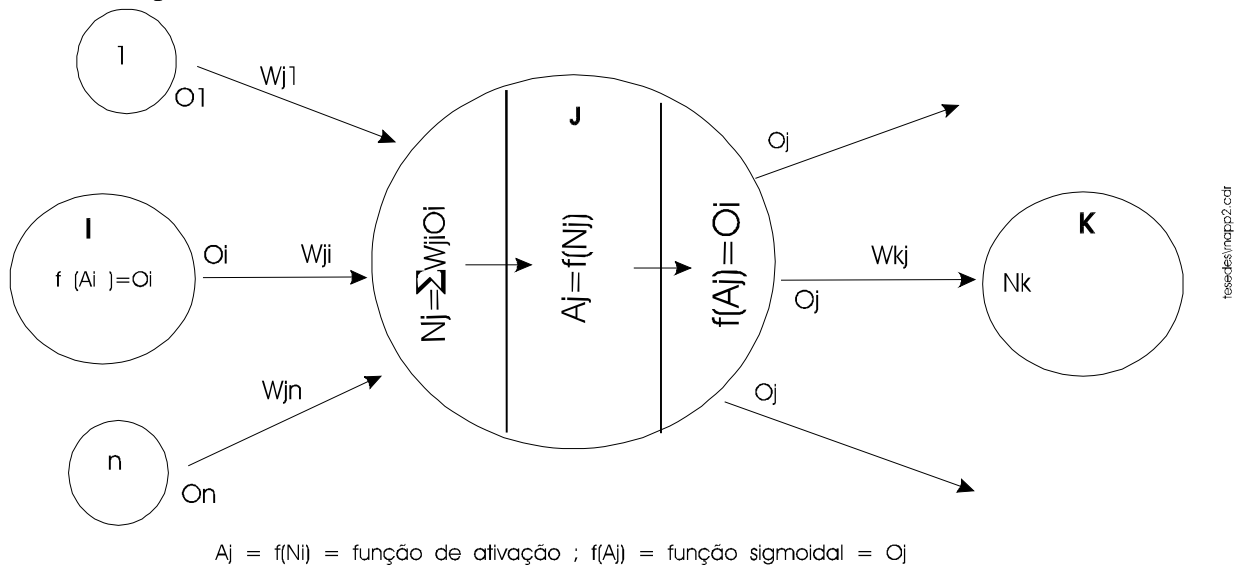
### **Redes Feed-forward**

Diversos modelos de redes neurais são encontrados 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 estes nós, os neurônios, se interligam para transmitir a informação. Em redes feed-backward há apenas uma camada de neurônios e todos os neurônios são interligados entre si.

Nesta pesquisa foram utilizadas redes feed-forward. Neste tipo de rede várias camadas são organizadas horizontalmente (figura 1). Cada neurônio se conecta e envia informação para todos os neurônios da camada seguinte. Neurônios pertencentes à mesma camada não são interligados. Estas redes são freqüentemente constituídas de três camadas: 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. Neurônios e camadas intermediárias são colocados entre as camadas de entrada e saída.

O modelo de retro-propagação é um modelo feed-forward sendo o modelo mais conhecido e referenciado na literatura (SHARDA 1994).

Este estudo usa um modelo de retro-propagação baseado nos Modelos de Processamento Distribuído Paralelo propostos por RUMELHART et al. (1986). A propagação de informação através da rede é efetuada como se segue (Fig. 1): os valores de entrada são transmitidos de uma camada para a outra e transformados através de pesos de conexões entre os neurônios ( $W_{ji}$ : peso da conexão entre o neurônio I e neurônio J). A rede acumula seu conhecimento através dos pesos de conexão.



**Figura 1.- Propagação de sinais na rede neural .**

Podemos tomar como exemplo um neurônio J na camada Jc:

- 1 O neurônio J recebe as saídas  $O_i$  dos neurônios precedentes e o valor  $N_j$  é computado:  
 $N_j = \sum W_{ji} O_i$ .
- 2  $N_j$  é introduzido numa função de ativação  $f(N_j)$  que produz um valor de ativação  $A_j$ . No modelo de RUMELHART o valor de ativação é igual a  $N_j$ .
- 3 A intensidade do sinal enviado de um neurônio para o outro é uma função da intensidade do valor de ativação. Uma função de transferência toma em conta o valor de ativação e produz o sinal de saída  $O_j$ .

$$O_j(t+1) = \frac{1}{1 + e^{-(\sum W_i O_i + \theta_j)}} \quad (\text{eq.1})$$

### O Método de Aprendizado por Retro-Propagação

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 de aprendizado. São corrigidos ao passo que o aprendizado evolui usando-se exemplos (ou fatos) representativos do problema em estudo. Estes fatos são relidos sucessivas vezes até que todos sejam aprendidos pela rede. A retro-propagação 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 uma diferença entre os dois vetores, os pesos de conexão são corrigidos ocorrendo assim o aprendizado.

O modelo de RUMELHART et al. é baseado em uma regra de aprendizado chamada Regra Delta Generalizada:

$$\Delta W_{ji(n+1)} = \mu \delta_j O_i + \alpha \Delta W_{ji(n)} \quad (\text{eq. 2})$$

$\Delta W_{ji(n+1)}$  é o ajuste introduzido em n+1 no peso de conexão entre os neurônios i e j.  $\mu$  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 tanto maiores as mudanças que serão introduzidas nos pesos em cada iteração.  $\alpha$  é uma constante chamada fator suavizante que faz o processo de aprendizado considerar o valor do peso no momento n.  $\delta$  é o sinal de erro na saída do neurônio.

### 3. Análise de Riscos de Insolvência - Visão Geral do Processo

A maioria dos modelos de avaliação de riscos de insolvência são construídos usando-se amostras pareadas: uma parte da amostra contém informações sobre empresas insolventes; a outra parte contém informações sobre empresas não insolventes. Variáveis são então selecionadas segundo seu interesse potencial na avaliação de riscos de insolvência. Um método estatístico é então usado para desenvolver um modelo discriminante (i.e., uma combinação de variáveis que melhor distingua os dois tipos de empresa). Finalmente o sucesso da discriminação é avaliado através de uma amostra de controle (i.e., uma amostra diferente da usada para obter o modelo).

Em geral a amostra de controle contém empresas solventes e empresas comprovadamente insolventes, isto é empresas que estão em processo de concordata, em liquidação, ou no caso de bancos e instituições financeiras, sob intervenção do Banco Central.

No caso desta pesquisa em razão do número reduzido de bancos insolventes na amostra global, não utilizamos bancos insolventes na amostra de controle. Ao invés disto confrontamos os resultados obtidos com a avaliações feitas pela empresa Austin Asis especializada em diagnóstico financeiro de empresas.

## 4. O Estudo

### Indicadores de Diagnóstico Financeiro de Bancos

Neste estudo, estamos considerando, para a análise de risco de Bancos, 28 indicadores financeiros, expostos na tabela 1 a seguir, descritos nos Manuais de Análise da Austin Asis, empresa brasileira de análise de risco bancário. Além de tais indicadores, foram consideradas as variáveis de origem de capital (privado nacional, estrangeiro, associado a estrangeiro, oficial estatal) e porte (grande, médio, pequeno e micro).

TABELA 1. INDICADORES FINANCEIROS

<b>ESTRUTURA</b>	
1.CAPITALIZAÇÃO	(Patrimônio Líquido/Passivo Real)
2.IMOBILIZAÇÃO PRÓPRIA	((Ativo Permanente - Imobiliz.Arrendamento)/Patrimônio Líquido)
3.IMOBILIZAÇÃO TOTAL	((Ativo Permanente - Imobiliz.Arrendamento)/(Patr.Líquido + Exig.L.P.))
4.CAPITAL DE GIRO	((Patrimônio Líq. - Ativo Permanente)/Patrimônio Líquido)
5.ALAVANCAGEM	(Captação Total/Patrimônio Líquido)
<b>SOLVÊNCIA</b>	
6.ENCAIXE	(Disponibilidades/Depósitos a Vista)
7.COBERTURA VOLUNTÁRIA	(Disponibilidades/Passivo Real)
8.SOLVÊNCIA CORRENTE	(Ativo Circulante Real/Passivo Circulante Real)

9.ASSISTÊNCIA FINANCEIRA	(Obrigações por Empréstimos - Inst. Oficiais/Captação Total)
10.ADEQUAÇÃO DE PRAZOS	(Real. L. P. Real/Exig. L.P. Real)
11.INADIMPLÊNCIA	(Oper.Créd.Liq.Duvidosa/Oper.Crédito)
12.PROVISIONAMENTO	(Prov.Cred.Liq.Duvidosa/Oper.Crédito)
13.COMPROMETIMENTO	(Oper.Créd.Liq.Duvidosa/Patrimônio Líquido)
<b>CUSTO E DESPESA</b>	
14.INTERMEDIÇÃO	(Despesa Interm. Financ. - Prov. CL - Ajuste Prog.Est.Econ./Capt.Total)
15.PESSOAL	(Despesa Pessoal/Captação Total)
16.ADMINISTRATIVO	(Despesa Administrativa/Captação Total)
17.TOTAL	(Despesa Total/Captação Total)

### **RENTABILIDADE**

18.GERAÇÃO DE RENDAS	(Receita Intermediação Financeira/Ativo Real - Ativo Permanente)
19.MARGEM BRUTA	(Resultado Bruto Interm.Financ./Receita Interm.Financ.)
20.MARGEM OPERACIONAL	(Resultado Operacional/Receita Interm.Financeira)
21.MARGEM LÍQUIDA	(Resultado Líquido/Receita Interm.Financeira)
22.RENTABILIDADE DO PL	(Resultado Líquido/Patrimônio Líquido)

### **CRESCIMENTO**

23.APLICAÇÕES TOTAIS	Aplicação Total do último período/Aplicação Total período anterior
24.CAPTAÇÕES TOTAIS	Captação Total do último período/Captação Total do período anterior
25.RECEITA INTER. FINANC.	Rec. Interm.Financ.do últ.período/Rec. Interm.Financ.do período ant.
26.RESULTADO LÍQUIDO	Resultado Líquido do último período/Result. Líquido do período anterior

### **OUTROS**

27. CORRETAGEM	(Aplicações em mercado aberto+TVM+negociação) / Ativo Total
28. ATIVO TOTAL	Valor do ativo total

### **CONCEITOS**

ATIVO REAL	Ativo Total - Relações Interfinanceiras - Relações Interdependências
PASSIVO REAL	Passivo Total - Relações Interfinanceiras - Relações Interdependências
APLICAÇÃO TOTAL	Ativo Real - Ativo Permanente - Diversos
CAPTAÇÃO TOTAL	Passivo Real - Patrimônio Líquido - Diversos

---

### **Seleção da amostra e coleta de dados**

A identificação de características que permitam distinguir bancos insolventes de solventes tem pelo menos dois fatores críticos: i) em qualquer escolha de variáveis preditivas que se faça pode ocorrer a desconsideração de algumas variáveis importantes; ii) relações complexas entre as variáveis preditivas podem alterar a capacidade de previsão dos modelos. Como as redes neurais tem capacidade de tratar dados incompletos e com distorções e produzir resultados satisfatórios a partir de generalizações, estas tem sido utilizadas com sucesso na avaliação de riscos de insolvência (TAM & KIANG 1992, DE ALMEIDA 1993, PODDING 1995; etc).

Para a criação de modelos de análise de risco de insolvência, dois grupos são necessários. Um primeiro grupo contendo instituições insolventes e um segundo grupo contendo instituições solventes. As instituições consideradas insolventes neste estudo são aquelas que sofreram processos de liquidação ou intervenção do Banco Central do Brasil. Para o grupo de solventes, foi escolhido um grupo de bancos considerados tradicionais (18 bancos).

Foram obtidas, através das bases de dados da Austin Asis, informações econômico-financeiras e cadastrais de 225 Bancos atuantes no Brasil. A amostra usada para a criação das redes neurais (amostra de base) contém 45 bancos, sendo 18 bancos solventes e 27 insolventes. O restante da amostra (amostra de controle) é utilizado para avaliar o modelo. A amostra de base foi constituída a partir de dados dos três últimos balanços disponíveis. A amostra de controle foi constituída a partir do último balanço disponível (julho de 1995).

#### **Tratamento da amostra de base para constituição das redes**

A criação das redes neurais, foi efetuada levando-se em consideração dois aspectos:

Primeiro: Capacidade das redes em interpretar dados históricos. Neste sentido a partir da amostra de base foram criadas redes utilizando-se dados apenas do último balanço disponível, bem como redes utilizando dados dos três últimos balanços disponíveis.

Segundo: Possibilidade de alterar a capacidade discriminante das redes segundo o conjunto de variáveis utilizadas. Foram assim criadas redes utilizando-se 27 variáveis (26 índices financeiros e uma variável qualitativa - porte), bem como redes utilizando 29 variáveis (sendo acrescidas duas novas variáveis - valor de corretagem e ativo - e uma variável qualitativa-origem de capital).

Em resumo foram feitas três seleções a partir da amostra de base e com estas, 9 redes neurais foram treinadas - três com cada seleção da amostra (tabela 2).

	Número de variáveis quantitativas	Variáveis qualitativas	Dados históricos
Seleção 1 (S1)	26	1 - Porte/Origem <sup>(*)</sup>	dados de 3 balanços
Seleção 2 (S2)	28	1 (Origem capital) <sup>(**)</sup>	dados de 3 balanços
Seleção 3 (S3)	28	1 (Origem capital) <sup>(**)</sup>	dados do último balanço

**Tabela 2 - Geração de 3 seleções da amostra de base**

(\*) Porte/Origem: Instituição Pequena, Média, Grande ou Estatal

(\*\*) Origem de Capital: privado nacional, estrangeiro, associado a estrangeiro, oficial estatal

#### **Definição de parâmetros na criação das redes neurais**

Existe uma série parâmetros na constituição de uma rede neural, que poderão influenciar sua capacidade preditiva. No entanto a falta de metodologia na concepção de redes neurais (MAGNIER 1991, MANI 1991, DE ALMEIDA 1993), impossibilita sua escolha de maneira racional (número de neurônios na camada intermediária, número de iterações, taxa de aprendizado, etc.).

Segundo MAGNIER (1991), a escolha adequada dos valores dos parâmetros tende a ficar baseada na experiência e sensibilidade do operador que conduz a construção da rede.

Neste estudo assumimos os seguintes valores de parâmetros:

**taxa de aprendizado (a):** igual a 1

**momentum (h)** igual a 0,9,

Lembramos que estes parâmetros que intervêm no algoritmo de aprendizado ( $\Delta W_{ji}(n+1) = \mu \delta_j O_i + \alpha \Delta W_{ji}(n)$ , eq. 2, apresentada anteriormente).


**Taxa de precisão do aprendizado:** igual a 10%.

Estes valores são sugeridos como *default* pela ferramenta de concepção de redes neurais utilizada (BRAINMAKER).

**Número de iterações** ( o número de vezes em que a amostra de base será lida durante o processo de aprendizado): O número de iterações não foi limitado nas experiências realizadas. O processo de aprendizado foi encerrado automaticamente quando o a taxa de precisão requerida foi alcançada.

**Número de neurônios na camada intermediária:** Não existe um critério racional que permita defini-lo (MAGNIER 1991; DUTTA, SHEKHAR & WONG 1992; WILSON & SHARDA 1994; etc.). Neste estudo foram criadas redes com 3 tipos de configuração: redes 3 neurônios, 5 neurônios ou 10 neurônios na camada intermediária (figura 2). A exploração de um grande número de alternativas, é uma questão econômica, pois quanto maior o número de possibilidades a testar maior o custo e tempo necessário a fazê-lo.

Uma vez criadas as redes com 3, 5 e 10 neurônios, pudemos observar através da amostra de controle que não houve grandes divergências entre os resultados de risco de insolvência fornecidos pelas três redes (concordância de 90% dos casos). Por esta razão limitamo-nos a estas três configurações.



**Figura 2 - Três configurações de redes utilizadas - O número de neurônios de entrada varia de acordo com o número de variáveis de entrada contidas na seleção da amostra de base empregada. O número de neurônios de saída é sempre igual a 2, representando as situações de solvência e insolvência.**

**Critério de observação dos resultados das redes**

A partir da amostra de controle, as redes neurais fornecem como resultado valores entre 0 e 1, onde 0 representa as empresas solventes e 1 as empresas insolventes. Os valores resultantes da previsão da rede podem então ser considerados como risco de insolvência. Quanto mais próximo de 1, maior o risco de insolvência, e quanto mais próximo o resultado de 0, menor o risco de insolvência.

A fim de efetuar a classificação das instituições a partir do risco de insolvência, um valor de cut-off de 0,5 foi empregado. Sendo o risco de insolvência superior a 0,5, a instituição é considerada insolvente. Abaixo ou igual a 0,5 a instituição é considerada solvente.

Consideramos aqui 0,5 como valor de cut-off, por este dividir igualmente o risco de erro de classificação em cada um dos grupos. Quanto maior o valor de cut-off, maior o risco de classificar como solvente uma instituição insolvente, e vice-versa, quanto menor o valor de cut-off, maior o risco de classificar como insolvente uma instituição solvente.

### **Verificação da capacidade de classificação das redes**

Em razão da existência de poucos bancos insolventes, todos foram utilizados na confecção das redes, não havia bancos insolventes na amostra de controle. A fim de avaliar o desempenho das redes neurais, seu poder discriminante teria que ser comparado com a avaliação feita por um especialista na área bancária, ao qual se questionaria sobre a situação de solvência, avaliada a partir da análise dos balanços das instituições. O especialista aqui considerado foi a empresa Austin Asis, e as avaliações de referência foram obtidas das análises de risco produzidas por ela.

A partir da amostra de controle (180 instituições), verificamos a capacidade das redes em fazer classificações corretas, sendo consideradas como corretas as classificações que foram coerentes com as classificações feitas pelo especialista. As classificações foram feitas em termos de porcentagem de empresas classificadas corretamente em cada um dos grupos, da seguinte maneira:

	% Instituições Solventes corretamente classificadas(S)	% Instituições Insolventes corretamente classificadas(I)	Classificação Global
Seleção S1	S/Ts	I/Ti	(S+I)/(Ts+Ti)
Seleção S2	S/Ts	I/Ti	(S+I)/(Ts+Ti)
Seleção S3	S/Ts	I/Ti	(S+I)/(Ts+Ti)

**Tabela 3 - Avaliação do desempenho das redes neurais**

**S - Solventes corretamente classificadas**

**I - Insolventes corretamente classificadas**

**Ts - Grupo de instituições solventes**

**Ti - Grupo de instituições insolventes**

### **O Processo de criação das redes**

Uma vez que optamos por três configurações de redes neurais (3, 5 ou 10 neurônios na camada intermediária), eventualmente, as avaliações feitas pelas redes não são concordantes. Neste caso consideramos que a classificação não pode ser realizada, fazendo com que um certo número de instituições fique sem classificação. Os bancos assim classificados ficaram em uma região que denominamos de dúvida.

As seguintes etapas foram percorrida a fim de avaliar a capacidade preditiva das redes:

1. Utilizamos inicialmente a seleção S1 da amostra de base e com esta criamos 3 redes (3, 5 e 10 neurônios);
2. Os riscos de insolvência são obtidos para os bancos da amostra de controle através de cada uma das redes.
3. Os bancos da amostra de controle são classificados como solvente ou insolvente segundo o risco de insolvência gerado pelas redes. não são classificados os casos onde não há concordância das três redes quanto ao risco de insolvência.
4. A classificação obtida é comparada com a classificação feita pela Austin Asis e a porcentagem de bancos corretamente classificados é computada.
5. Os passos 1 a 4 são repetidos para as seleções S2 e S3, e é computada a porcentagem de bancos corretamente classificados.



### **Adequação das redes obtidas à amostra de base**

Tendo sido criadas as 9 redes (3 para cada seleção da amostra) constata-se que o processo de aprendizado, convergiu em todos os 9 casos. Isto quer dizer que o modelo se adequa 100% à amostra de base em todos os casos, isto é todas as redes classificam corretamente 100% das observações da amostra de base nos respectivos grupos, solventes e insolventes.

### **Resultados do estudo**

Como dissemos foram concebidas 3 redes para cada seleção da amostra de base tendo sido construídas 9 redes ao total.. As redes construídas apresentam as configurações apresentadas na tabela 4.

<b>Amostras</b>	<b>Número de neurônios intermediários</b>		
	<b>3</b>	<b>5</b>	<b>10</b>
<b>Seleção (S1)</b>	31x3 3x2	31x5 5x2	31x10 10x2
<b>Seleção (S2)</b>	33x3 3x2	33x5 5x2	31x10 10x2
<b>Seleção (S3)</b>	33x3 3x2	33x5 5x2	31x10 10x2

**Tabela 4 - Dimensões das matrizes de coeficientes (pesos de conexão) determinados pelo processo de aprendizado**

Como dissemos no item 2, o processo de aprendizado das redes neurais tem como objetivo determinar o peso das conexões entre cada um dos neurônios. O resultado do aprendizado de cada uma das redes é a determinação de 2 matrizes de coeficientes. A tabela 4 apresenta a dimensão das matrizes de cada uma das redes criadas. Por exemplo a partir da Seleção S1, foram determinadas duas matrizes de coeficientes. Uma com dimensão de 31x3, que representa os coeficientes entre os neurônios de entrada (através do qual são introduzidos os valores dos índices financeiros) e os 3 neurônios intermediários. A outra matriz, com dimensão 3x2, representa o valor dos coeficientes entre os neurônios 3 neurônios intermediários e os neurônios de saída. Lembramos que 2 neurônios representam dois estados possíveis na amostra de base.

Através do conjunto de equações de propagação (item 2), são computados estes coeficientes, bem como os índices financeiros dos bancos na amostra de controle, sendo assim gerado o risco de insolvência. A tabela 5 a seguir, apresenta as matrizes de coeficientes para as redes de 3 e 5 neurônios intermediários geradas a partir da seleção S1 da amostra de base, aqui apresentadas como exemplo.

Rede de 3 neurônios gerada a partir da amostra 1				Rede de 5 neurônios gerada a partir da amostra 1				
Coeficientes de conexão entre neurônios de entrada e neurônios intermediários				Coeficientes de conexão entre neurônios de entrada e neurônios intermediários				
Neurônios Intermediários				Neurônios Intermediários				
	1	2	3	1	2	3	4	5
<b>Neurônios de entrada</b>								
Capitaliz	-3.428	-.067	4.238	1.399	1.205	4.203	.396	-.723
ImPropria	-.058	-4.203	-1.144	2.766	-3.171	.924	-1.574	-.985
ImTotal	-2.580	-2.148	2.531	2.090	-1.181	4.093	-.796	-.470
CapGiro	.720	3.302	-.613	-2.997	1.618	-3.458	1.144	-1.051
Alavanc	3.201	.341	-1.693	-.245	.371	-3.185	-2.467	-1.485
Encaixe	-1.710	.889	2.188	-.341	.548	1.222	.584	-.559
CobVolunt	-.156	-1.327	.238	2.574	.874	1.802	.769	-.014
LiqCorrente	-2.585	-.096	4.719	-2.201	.237	4.173	-.120	-1.089
AsFinan	3.210	-3.430	-4.637	2.600	-2.916	-4.332	-2.418	-3.573
AdPrazos	3.035	3.821	-1.334	1.685	.950	-1.551	-.995	.106
Inadimpl	.818	-1.024	-2.567	.661	-.948	-3.600	-.077	-.379
Provision	-3.703	1.294	3.628	-2.902	1.567	3.355	2.277	.233
Compromet	7.587	-3.644	-7.171	4.238	-3.006	-7.999	-1.009	.329
CIntermed	2.433	-2.293	-2.597	1.778	-1.714	-2.788	-.473	-2.232
CPessoal	.461	1.872	-2.135	.190	.985	-2.155	.107	-1.398
CAdmin	3.932	-3.856	-6.375	5.686	-2.606	-5.825	-1.198	-.544
CTotal	1.082	-2.058	1.479	1.895	-1.441	1.490	-1.448	-.179
GerRendas	-.154	-.837	-.753	.920	-.275	-.338	-.294	.248
MargBruta	-.779	-.812	-.481	.101	.093	1.067	-.789	-.381
MargOper	.528	-1.428	.589	.729	-.680	.339	-.180	-.646
MargLiq	-.631	-.401	.099	-.997	-.458	.551	-.702	-1.142
RentPL	-2.113	.115	.355	-3.254	-.127	.817	.115	.298
CreAplicTot	1.888	-.966	-1.270	1.973	-.853	-1.637	.178	-.526
CreCaptTot	2.848	-1.960	-1.649	2.860	-1.564	-2.308	-1.542	-1.792
CreRecInt	2.911	-2.292	-3.399	3.647	-.495	-3.511	-1.526	-2.402
CreResLiq	-2.509	1.525	1.722	-1.409	.758	2.272	.669	-.319
Pequeno	3.917	-1.118	-4.135	1.285	-1.748	-6.050	-.218	.072
Médio	-2.032	.543	2.943	-1.639	-.184	3.238	.786	.504
Grande	-2.771	.578	3.805	-.766	1.268	5.054	.990	1.614
Estatal	3.189	-4.310	-2.613	2.339	-3.826	-2.320	-2.408	-1.466
q	.888	1.116	-1.031	.127	.444	-1.909	-.235	.098
<b>Coeficientes de conexão entre neurônios intermediários e neurônios de saída</b>				<b>Coeficientes de conexão entre neurônios intermediários e neurônios de saída</b>				
Neurônios de saída				Neurônios de saída				
Insolvente Solvente				Insolvente Solvente				
<b>Neurônios Intermed.</b>				<b>Neurônios Intermed.</b>				
1	5.487	-5.485		1	5.916	-5.804		
2	-7.918	7.916		2	-2.381	2.581		
3	-5.119	5.129		3	-7.953	7.960		
q	-.494	.495		4	-1.578	1.450		
				5	.038	1.426		
				q	-.960	.838		

Tabela 5 - Matrizes de coeficientes ou pesos de conexão

Apresentamos a seguir os resultados de classificação das redes neurais, em termos de porcentagem de classificação correta, relativamente à avaliação do especialista considerado.

	<b>Insolventes corretamente classificadas</b>	<b>Solventes corretamente classificadas</b>	<b>Classificação global</b>
<b>Amostra 1 (S1) - 27 variáveis e 3 balanços</b>	93%	60%	68%
<b>Amostra 2 (S2) - 29 variáveis e 3 balanços</b>	77%	50%	56%
<b>Amostra 3 (S3) - 29 variáveis e último balanço</b>	70%	58%	61%

**Tabela 6 - Porcentagem de empresas corretamente classificadas através das redes neurais**

### **Conclusões**

Este estudo mostrou o interesse em utilizar ferramentas como redes neurais na avaliação de riscos de insolvência. Foi possível através das redes neurais classificar corretamente até 68% das instituições financeiras. Outros estudos devem ser realizados procurando identificar, outras formas de construir as redes como por exemplo outras variáveis que permitam distinguir de maneira mais precisa instituições solventes de insolventes.

É interessante notar que houve um importante decréscimo na capacidade de classificação das redes criadas com a seleção S2. A inclusão de novas variáveis não trouxe informação capaz de melhorar a capacidade das redes em classificar as instituições da amostra de controle.

Outro fato importante é que as redes criadas com informação do último balanço disponível à época da coleta de dados propiciaram uma melhor qualidade de classificação do que as redes criadas com dados de três balanços. Uma das hipóteses deste fato poderia ser que uma vez que a situação apresentada pelas instituições insolventes no último balanço era mais crítica, a rede pôde observar um maior contraste entre instituições solventes e insolventes. Esta hipótese no entanto não pôde ser comprovada.

### **Limites deste estudo**

Este estudo guarda alguns limites que devem aqui ser destacados.

Um dos limites diz respeito aos valores dos parâmetros explorados. Outras configurações de rede como por exemplo um número maior de neurônios na camada intermediária poderia ter sido explorado. Ainda diferentes níveis de precisão durante o processo de aprendizado poderiam ter sido explorados.

Outro limite deste estudo diz respeito ao critério de avaliação da capacidade de classificação das redes neurais. Sua classificação foi comparada com a avaliação feita pela Austin Asis. Esta instituição poderia eventualmente cometer erros de classificação com relação às empresas da amostra de controle. Isto somente pode ser constatado a médio prazo à medida que a situação de solvência das instituições da amostra de controle evoluírem.

Neste estudo foi utilizado um número reduzido de empresas solventes na amostra de base. Seria interessante procurar aumentar o número de instituições solventes, o que poderia aumentar a capacidade de previsão da rede.

### **Referências**

- ABATE, R.P. - "Numerical Scoring Systems for Commercial Loans" Bankers Monthly, January, 1969.
- ALTMAN, E. - "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy". - **Journal of Finance**, vol. 23, n.4, p.589-609, setembro, 1968.

- ALTMAN, E., R. HALDEMAN e P. NARAYANAN. -"Zeta analysis". -**Journal of banking and finance**, p.29-54, junho, 1977.
- BEAVER, W. "Financial ratios as predictors of failures", in Empirical Research in Accounting, selected studies, 1966, in supplement to the Journal of Accounting Research, January, 1967.
- COHEN, I. J., T.C. GILMORE, e F.A. SINGER, "Bank procedures for analyzing business loan applications" in Analytical Methods in Banking, K.J. Cohen e F.S. Hammer, Homewood, Ill: R.D. Irwin, 1966.
- DE 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.**- Tese de Doutorado em Administração. -Ecole Supérieure des Affaires, Universidade de Grenoble, 1993.
- DUMONTIER, P. (1990). -"Vices et vertus des modèles de prévision de défaillance". - **Papier de recherche** n° 90-12, Université de Grenoble II, CERAG, 1990.
- DUTTA, S., S. SHEKHAR e W.Y. WONG - "Decision Support in Non-Conservative Domains: Generalization with Neural Networks" - WP n 92-31, INSEAD, 1992.
- HERTZ, J., KROGH, A. e R.G. PALMER. -**Introduction to Theory of Neural Computing.** -Redwood City: Addison-Wesley, 1991.
- JOHNSON, T. e MELICHER, R.W. -"Predictiong corporate bankruptcy and financial distress: Information Value Added by Multinomial Logit Models". -**Journal of Economics & Business**, vol.46, n.4, p.269-286, Outubro 1994.
- KOHONEN, T.- "An Introduction to Neural Computing".- **Neural Networks**, vol.1, p.3-16, 1988.
- MANI, G.- "Lowering variance of decisions by using artificial neural etwork portfolio". - **Neural Computing**, vol. 3, p.484-486, 1991.
- MATIAS, A.B. - "Contribuição às Técnicas de Análise Financeira: um modelo de concessão de crédito", trabalho de formatura apresentado à FEA/USP em dezembro de 1978.
- PODDIG, T. "Bankruptcy Prediction: A Comparison with Discriminant Analysis". in **Neural Networks in Capital Markets**. Editado por A.P. REFENES, New York.- John Wiley & Sons, 1995.
- 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**, vol.31, n.5, p.64-68, 1994.
- RUMELHART, D.E., J.C. McCLELLAND, PDP Research Group.- **Parallel Distributed Processing - Exploration in the Microtexture of Cognition.**- Volume 1.- London.- The MIT Press.- 1986.
- SHARDA, R.- "Neural Networks for the MS/OR analyst: An application bibliography". - **Interfaces**, vol.24, n.2, p.116-130, 1994.
- SHARDA, R.- "Neural Networks for the MS/OR analyst: An application bibliography". - **Interfaces**, vol.24, n.2, p.116-130, 1994.
- STANLEY J. - **Introduction to Neural Networks.**-CA:Sierra Madre.-Cal. Scientific Software.-3rd edition.-1990.
- TAM, K.T. & KIANG, M.Y.- "Managerial Applications of Neural Networks: The case of Bank Failure Predictions".- **Management Science**, vol. 38, p.926-947, 1992.
- WILSON, R.L. & SHARDA, R. -"Bankruptcy Prediction Using Neural Networks". -**Decision Support Systems**, vol. 11, n. 5, p. 545-557, junho 1994.