

**UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE CIÊNCIAS SOCIAIS APLICADAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA - PIMES**

Amanda Aires Vieira

**AVALIAÇÃO DE INSOLVÊNCIA NO SISTEMA BANCÁRIO:  
UMA APLICAÇÃO PARA O CASO BRASILEIRO**

Recife  
2010

Amanda Aires Vieira

**AVALIAÇÃO DE INSOLVÊNCIA NO SISTEMA BANCÁRIO:  
UMA APLICAÇÃO PARA O CASO BRASILEIRO**

Trabalho de Dissertação de mestrado  
submetido para avaliação e aprovado pela  
banca examinadora do Programa de Pós  
Graduação em Economia - PIMES

**Orientador:** Prof. Dr. Ricardo Chaves Lima

Recife  
2010

Vieira, Amanda Aires

Avaliação de insolvência no sistema bancário: uma aplicação para o caso brasileiro / Amanda Aires Vieira.

- Recife : O Autor, 2010.

93 folhas : fig. e tabela.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CCSA. Economia, 2010.

Inclui bibliografia e apêndice.

1. Bancos(Brasil) Automação. 2. Redes neurais(Computação). 3. Instituições financeiras. 4. Fatores de risco(Brasil). I.Título.

336.7

CDU (1997)

UFPE

332.1

CDD (22.ed.)

CSA2010 - 066

---

UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE CIÊNCIAS SOCIAIS APLICADAS  
DEPARTAMENTO DE ECONOMIA  
PIMES/PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

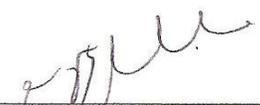
PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE DISSERTAÇÃO DO  
MESTRADO ACADÊMICO EM ECONOMIA DE

**AMANDA AIRES VIEIRA**

A Comissão Examinadora composta pelos professores abaixo, sob a presidência do primeiro, considera a Candidata Amanda Aires Vieira **APROVADA**.

Recife, 02/03/2010.

  
\_\_\_\_\_  
**Prof. Dr. Ricardo Chaves Lima**  
Orientador

  
\_\_\_\_\_  
**Prof. Dr. Jocildo Fernandes Bezerra**  
Examinador Interno

  
\_\_\_\_\_  
**Prof. Dr. Sinézio Fernandes Maia**  
Examinador Externo/UFPE

*Para Dominiki*

## AGRADECIMENTOS

Agradeço a Deus a oportunidade de, mais uma vez, navegar por esse imenso oceano.

Aos meus pais e a minha irmã, pela dedicação, amor, paciência e incentivos providos diariamente. Agradeço em especial, a minha querida Maroca, por tudo. Por ser a melhor parte dos meus dias.

A Stênio, pela parceria de onze anos e por toda compreensão nos períodos de dificuldade.

Agradeço ao professor do Departamento de Ciência Política, Marcelo Medeiros, sempre tão presente na minha carreira profissional. Ao programa de Pós-Graduação em Economia da Universidade Federal de Pernambuco. Em especial, aos professores Yony Sampaio, Francisco Ramos, Márcia Alcoforado e ao meu orientador, Professor Ricardo Chaves.

Agradeço ainda aos amigos do PIMES. Em especial, aos grandes companheiros Poema Isis (Popó), Diego Vasconcelos (Dr. Fodão) e Igor Maciel (Igão) por todas as horas de estudo, pelo companheirismo e ajuda nesses dois anos.

Às autarquias Vitor Cavalcanti (Vitinho), Abdias Neto (Venceslau) e Diego Mota (Motinha). Em especial, gostaria de agradecer a Vitinho pelo apoio metodológico fundamental.

Agradeço ao ex-aluno, orientando e amigo Eduardo Andrade pela ajuda no processo de construção do meu trabalho.

Agradeço a todos os meus alunos de graduação, com especial atenção à turma de ciências contábeis 2008.1, noite, pelo acolhimento e amizade.

Aos amores que moram em outros continentes e/ou hemisférios. À querida amiga Cara Köhler, ao sempre lembrado Darryl Trotter e ao boniiiito Vital Melo. Agradeço ao apoio e alegrias nas horas mais difíceis.

Agradeço aos amigos Iansã Melo e André de Souza, sempre tão presentes nessa jornada de oito anos.

***“Era mais informação do que eu precisava”***  
John Travolta. In.: Pulp Ficton

## Resumo

O ano de 2008 foi marcado pelo ápice da crise financeira mundial, iniciada no mercado imobiliário dos Estados Unidos. Também nesse período, constatou-se o aumento da produção de estudos teóricos e empíricos sobre os determinantes de crises no sistema financeiro e, especificamente, no sistema bancário. Embora diversos trabalhos desenvolvidos analisem os determinantes de falência bancária, buscando identificar quais variáveis econômicas causam desequilíbrios no sistema financeiro, as conclusões encontradas nem sempre convergem para modelos eficientes no processo de *early warning*. O presente trabalho tem por objetivo avaliar como os modelos de redes neurais artificiais podem ser utilizados enquanto ferramentas para previsão de insolvência bancária no Brasil. Para tanto, foram utilizados dados a respeito de liquidação bancária entre os anos de 1996 e 1999 associados a três processos distintos de amostragem dos bancos solventes. Os resultados mostram que o maior volume de variáveis explicativas (neurônios de entrada) no modelo de redes neurais torna o modelo melhor ajustado à série e com menor erro quadrado médio de previsão, ainda que seja possível verificar uma forte presença de multicolinearidade entre essas variáveis. Finalmente, verificou-se que os modelos de redes neurais artificiais apresentam bom desempenho na previsão de falência bancária no Brasil independentemente do processo de amostragem selecionado.

Palavras-Chave: Falência Bancária, Redes Neurais Artificiais.

## **Abstract**

The year of 2008 worked as stage to the summit of the world's recent financial crisis, which begun with US' real estate market. At that time, we watched a growth in production of theoretical and empirical studies about the main causes of crises on financial and banking systems. Although many studies analyze the reasons for bankruptcy into banking system, aiming to identify which economic variables cause misbalance to financial system, their conclusions don't always converge to efficient early warning models. This study intends to evaluate how artificial neural models may be used as tools to foresee bank insolvency in Brazil. We used data about bank liquidation, associating three different sampling processes from bankrupting banks, between years 1996 and 1999. The results show that a greater amount of independent variables (entry neurons) in a neural network model, helps to adjust it and lessens the forecasting average squared deviation, although it is possible to observe multicollinearity among the variables. Finally, it was possible to state that artificial neural network models show a good response in predicting bank insolvency in Brazil, independently from the sampling model used.

Key words: Bank insolvency, Artificial Neural Networks.

## Lista de Tabelas

Tabela 1: Funções do sistema financeiro e os efeitos sobre a economia.....	17
Tabela 2– Estudos empíricos sobre crises bancárias .....	30
Tabela 3 – Resultados dos Modelos de Redes Neurais para amostra com bancos insolventes e as maiores instituições .....	47
Tabela 4 – Resultados de classificação para dados dentro da amostra .....	49
Tabela 5 – Resultados de classificação para dados fora da amostra.....	49
Tabela 6 – Erro quadrado médio dos modelos .....	49
Tabela 7 – Resultados dos Modelos de Redes Neurais para amostra com bancos insolventes associado à amostra aleatória de bancos privados.....	51
Tabela 8 – Resultados de classificação para dados dentro da amostra .....	53
Tabela 9 – Resultados de classificação para dados fora da amostra.....	54
Tabela 10 – Erro quadrado médio dos modelos .....	54
Tabela 11 – Resultados dos Modelos de Redes Neurais para amostra com bancos insolventes associado à amostra aleatória de bancos privados e públicos estaduais .....	56
Tabela 12 – Resultados de classificação para dados dentro da amostra .....	58
Tabela 13 – Resultados de classificação para dados fora da amostra.....	59
Tabela 14 – Erro quadrado médio dos modelos .....	59
Tabela 15 – Resultados dos Modelos de Previsão.....	60
Tabela 16 – Resultados dos Modelos de Previsão.....	62

## Lista de Figuras

Figura 1: Fluxo circular da riqueza expandido.....	16
Figura 2: Evolução do número de bancos existente no Brail.....	19
Figura 3: Exemplo de um modelo de rede neural do tipo Perceptrons <i>Multilayer Perceptrons</i> .....	33
Figura 4 – Estrutura da Rede Neural Utilizada .....	39
Figura 5 – Modelo de Previsão de Falência Bancária, primeiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.....	44
Figura 6 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.....	44
Figura 7 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,99. Neurônios intermediários: 50.....	45
Figura 8 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,999. Neurônios intermediários: 50.....	45
Figura 9 – Modelo de Previsão de Falência Bancária, primeiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.....	52
Figura 10 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.....	52
Figura 11 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,99. Neurônios intermediários: 50.....	53
Figura 12 – Modelo de Previsão de Falência Bancária, primeiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.....	57
Figura 13 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,99. Neurônios intermediários: 50.....	58

## Sumário

1. INTRODUÇÃO .....	10
2. REFERENCIAL TEÓRICO.....	15
2.1. Sistema Financeiro e Risco Bancário.....	15
2.2. Literatura empírica recente sobre risco bancário no Brasil e no Mundo.....	22
3. ASPECTOS METODOLÓGICOS .....	32
3.1. Modelo de Redes Neurais Artificiais de Retropropagação .....	32
3.2. Amostra .....	36
3.3. Especificação da Modelagem Utilizada .....	36
3.4. Origem dos Dados.....	40
4. RESULTADOS E DISCUSSÕES .....	42
4.1. Previsão de Falência I: Modelos de previsão de insolvência para bancos privados comparados com as maiores instituições privadas .....	42
4.2. Previsão de Falência II: Modelo de previsão de insolvência para bancos privados comparados com amostra aleatória de bancos privados .....	50
4.3. Previsão de Falência III: Modelo de previsão de insolvência para bancos privados e públicos estaduais comparados com amostra aleatória de bancos.....	55
4.4. Considerações finais.....	59
5. CONCLUSÕES .....	63
REFERÊNCIAS .....	65
A P Ê N D I C E.....	73

## 1. INTRODUÇÃO

O entendimento sobre a estruturação do sistema de intermediação financeira, assim como seus desdobramentos sobre a economia, pode representar importantes implicações nos formatos de políticas governamentais. Segundo Levine (2005), informações a respeito do impacto do mercado financeiro sobre o crescimento econômico influenciam os tomadores de decisão política sobre a prioridade que esses devem dar às reformas no setor.

Todavia, a percepção de importância do sistema financeiro sobre a economia não é compartilhada por todas as escolas do pensamento econômico. Controversos pontos de vista a respeito de qual o impacto desse setor sobre o crescimento ou até se o mesmo existe têm sido construídos. Três correntes pautam essa discussão: A primeira, defendida por Meier & Seers (1984), caracteriza o sistema financeiro como fator importante, mas não determinante único do crescimento econômico. Essa visão é compartilhada por Lucas (1988), que aponta a existência de uma relevância exagerada dada ao setor financeiro na determinação do crescimento econômico. No outro extremo, a segunda linha de pensamento construída por Miller (1998) afirma que a importância do sistema financeiro é óbvia, não havendo motivos para o dispêndio de tempo na discussão sobre o seu papel na economia. Por fim, o terceiro ponto de vista construído por Bagehot (1873), Schumpeter (1911), Gurley & Shaw (1955), Goldsmith (1969) e McKinnon (1973) leva a uma conclusão mais parcimoniosa e rejeita a idéia de que o nexos sistema financeiro-crescimento pode ser ignorado sem limitações substanciais no entendimento do crescimento econômico.

Para muitos autores, os intermediários financeiros podem melhorar a adoção de novas tecnologias, incrementando a taxa de inovação tecnológica e a criação de novos bens assim como processos produtivos [King & Levine (1993), Galetovic (1996), Blackburn & Hung (1998), Morales (2003), Acemoglu, Aghion & Zilibotti (2003)]. Esses pontos de vista convergem com o núcleo da teoria Schumpeteriana sobre finanças no processo de desenvolvimento econômico: regulação e custos de transação reduzidos produzem melhores oportunidades de emprego.

Na elaboração de sua abordagem sobre o desenvolvimento econômico, Schumpeter (1911) postula que, para que um país possa alcançar desenvolvimento, é necessário que esse aprimore três alicerces fundamentais: a tecnologia, o empreendedorismo e o sistema de

crédito bancário. De acordo com o autor, não cabe ao empreendedor financiar projetos de investimento com seus próprios recursos. Schumpeter afirma que esses devem originar-se do capitalista, que recebe os juros do empréstimo.

Para financiar esses projetos, o empreendedor busca tomar crédito no mercado financeiro. De acordo com Krugman (2008), o mercado financeiro é caracterizado por canalizar poupança privada e empréstimo do exterior na direção de gastos de investimento de empresas, tomada de empréstimo pelo governo e empréstimo ao exterior. Atualmente, esse sistema é composto por vários intermediários, além de demandantes e ofertantes de ativos financeiros. Segundo Silva & Porto Júnior (2004), fazem parte do sistema financeiro o Banco Central, além dos bancos comerciais e de investimento, corretoras de valores, fundos de investimento, fundos de pensão, bolsa de valores e companhias de seguro. Dentre esses intermediários, os bancos são apontados, normalmente, como representantes do sistema financeiro. Tal fato pode ser justificado uma vez que os bancos são responsáveis por mais de 60% da fonte de fundos externos de empresas não-financeiras (Silva & Porto Júnior, 2004) e ainda porque o seu passivo é composto por moeda (Krugman, 2008).

Além de aumentar a velocidade de comercialização dos ativos, o sistema financeiro pode ainda potencializar os efeitos da política monetária (Cavalcanti & Villamil, 2005). Segundo Stiglitz & Greenwald (2004), o canal de crédito é um dos meios pelo qual variáveis nominais ou financeiras afetam a atividade e o equilíbrio econômico no curto prazo.

Contudo, nem sempre o canal de crédito é bem desenvolvido. Isso se deve, entre outros fatores, à assimetria de informação presente nas relações financeiras entre concedentes e tomadores de crédito (Cavalcanti & Vilamil, 2005). Como a informação é privada, surge um conflito entre os agentes econômicos no mercado de crédito. Essa situação de interesses divergentes pode ser tratada, na teoria econômica, pelos modelos de Principal-Agente. O intermediário financeiro deseja investir parte de seus ativos em um projeto, mas não poderá realizar isso sozinho: delegará ao empreendedor a execução dessa tarefa. Segundo Birchler & Bütler (2007):

*“Delegation is not only a form of division of labor, and thus a source of higher productivity, as Adam Smith pointed out, but also a source of a special kind of problem” (p.341)*

Laffont & Martimort (2002) afirmam que os problemas de risco moral e seleção adversa surgem pela incapacidade dos intermediários financeiros, seja operacional ou pelos custos elevados, de monitorarem as ações dos agentes antes e após ofertarem o contrato de concessão de crédito.

Um problema oriundo do risco moral e da seleção adversa que influencia o canal de crédito diz respeito à possibilidade de corrida aos bancos. Nesse caso, mesmo que o banco possua uma situação fora de riscos de falência, através de uma boa carteira de empréstimos, ele pode ser prejudicado por rumores de que alguns desses empréstimos não serão saldados. Esses rumores podem ainda sofrer um processo de *spill over* e se espalhar para todo o sistema bancário, causando, assim, fortes prejuízos a todo o sistema financeiro (Hall et al, 2008).

De acordo com Barnhil & Souto (2008), os anos 1980 e 1990 presenciaram um considerável número de crises bancárias, que, em alguns casos, alcançaram efeitos transnacionais. Além das consequências diretas sobre o sistema financeiro, Demirgüç-Kunt e Detragiache (1998) enfatizam que uma crise bancária pode ainda se difundir por outros setores da economia, uma vez que o volume de crédito disponível é retraído. Como afirmam os autores, esse tipo de crise pode gerar uma redução no investimento e no consumo e, possivelmente, levar empresas que apresentam solvência financeira à falência. Esse efeito pode ainda ser mais agressivo para a economia, pois pode afetar o sistema de pagamentos, uma vez que falhas no sistema bancário reduzem a confiança dos agentes econômicos nas instituições financeiras, reduzindo, assim, a poupança doméstica e do fluxo de capital em larga escala.

A crise econômico-financeira mundial, que teve seu auge em 2008, vem sendo estudada por teóricos das mais diversas vertentes do conhecimento, que buscam explicar seus efeitos e sugerir possíveis soluções para esse problema. Segundo Cherubine & Dowbor (2009), com sua origem na emissão de crédito imobiliário a pessoas sem recursos – denominadas de clientes *sub-prime* – nos Estados Unidos, a tensão financeira se espalhou por todo o sistema bancário norte-americano quando esses tomadores de crédito não foram capazes de saldar os empréstimos, levando os bancos a executar a hipoteca dos imóveis e a ofertá-los novamente no mercado. Com o aumento da oferta de casas à venda, os preços foram retraídos fortemente, intensificando as consequências da tensão financeira.

Em particular, durante esses períodos de instabilidade econômica, com a redução do nível de consumo das famílias, cresce o número de empréstimos não saldados pelas empresas, o que implica em um aumento do risco e da volatilidade no mercado. Nessa etapa, segundo Barnhil & Souto (2008), os efeitos da crise bancária começam a se tornar mais generalizados por todo sistema de intermediação financeira, com os bancos sendo afetados por outros fatores vinculados ao risco de mercado, aumentando, desta forma, o número de bancos comprometidos pela crise, levando a um problema sistêmico no mercado financeiro.

Observando a importância do conhecimento sobre exposição do sistema bancário, o desenvolvimento de indicadores financeiros e o uso de técnicas de estimação de risco de crise nesse sistema podem melhor equipar a autoridade monetária na previsão de uma crise bancária sistemática (Hall et al, 2008).

Tendo em vista a necessidade de aprimoramento das ferramentas utilizadas pela autoridade monetária nacional, colocam-se em destaque questões importantes de pesquisa, na medida em que tais ferramentas possibilitam melhor poder de avaliação e, assim, podem dar maior estabilidade ao sistema econômico, permitindo atuação antecipada dos agentes reguladores, proporcionando, por fim, baixa volatilidade dos indicadores econômicos.

Uma discussão relevante no que tange à crise do sistema bancário diz respeito aos métodos de estimação para avaliação da mesma. Vários estudos empíricos têm discutido o tema, principalmente no contexto dos sistemas financeiros de países desenvolvidos. Esse debate, todavia, não tem sido recorrente para economias em desenvolvimento como o Brasil, principalmente com a utilização de modelos computacionais.

Considerando a relevância do sistema de intermediação financeira e sua influência sobre a economia, é de fundamental importância para os agentes econômicos ter conhecimentos sobre ferramentas que possam manter a sua estabilidade (Hall et al, 2008). Dessa forma, a habilidade de prever variações no sistema bancário fornece às autoridades instrumentos que podem minimizar efeitos oriundos de crises potenciais. Assim, o presente trabalho objetiva realizar avaliações que permitam verificar a existência de processos de insolvência no sistema bancário brasileiro entre os anos de 1996 e 1999.

O trabalho está dividido em cinco partes, incluindo a presente introdução. A seção seguinte explora a literatura recente sobre o sistema de intermediação financeira e risco bancário, além de analisar a literatura empírica sobre risco bancário no Brasil e no mundo. A seguir, serão apresentados os modelos utilizados para realizar as avaliações. A parte quatro ilustra os resultados dos modelos de redes neurais artificiais. Finalmente, algumas considerações são realizadas na última seção, à guisa de conclusão.

## **2. REFERENCIAL TEÓRICO**

### ***2.1. Sistema Financeiro e Risco Bancário***

Segundo Krugman (2008), o sistema financeiro é caracterizado por ser um ambiente onde as famílias investem suas poupanças correntes e suas poupanças acumuladas, ou riquezas, comprando ativos financeiros. Esses, por sua vez, se caracterizariam como um título que proporciona ao comprador o direito a uma renda futura paga pelo vendedor do papel. Segundo o autor, existem diversos tipos de ativos financeiros, sendo os mais comuns os empréstimos, as ações, os bônus e os depósitos bancários.

A figura 1 mostra as ligações existentes entre o sistema financeiro e os demais mercados e agentes da economia. Por meio do diagrama, é possível observar que, através dos mercados financeiros, a poupança privada e os fundos do resto do mundo (empréstimos e vendas de ações por estrangeiros) são canalizados para os gastos de investimentos das firmas (títulos de dívida e ações emitidas pelas firmas), tomada de empréstimos pelo governo, tomada e concessão de crédito de estrangeiros e transações de estrangeiros com ações. Os efeitos do sistema financeiro sobre a economia é sistematizado na tabela 1.

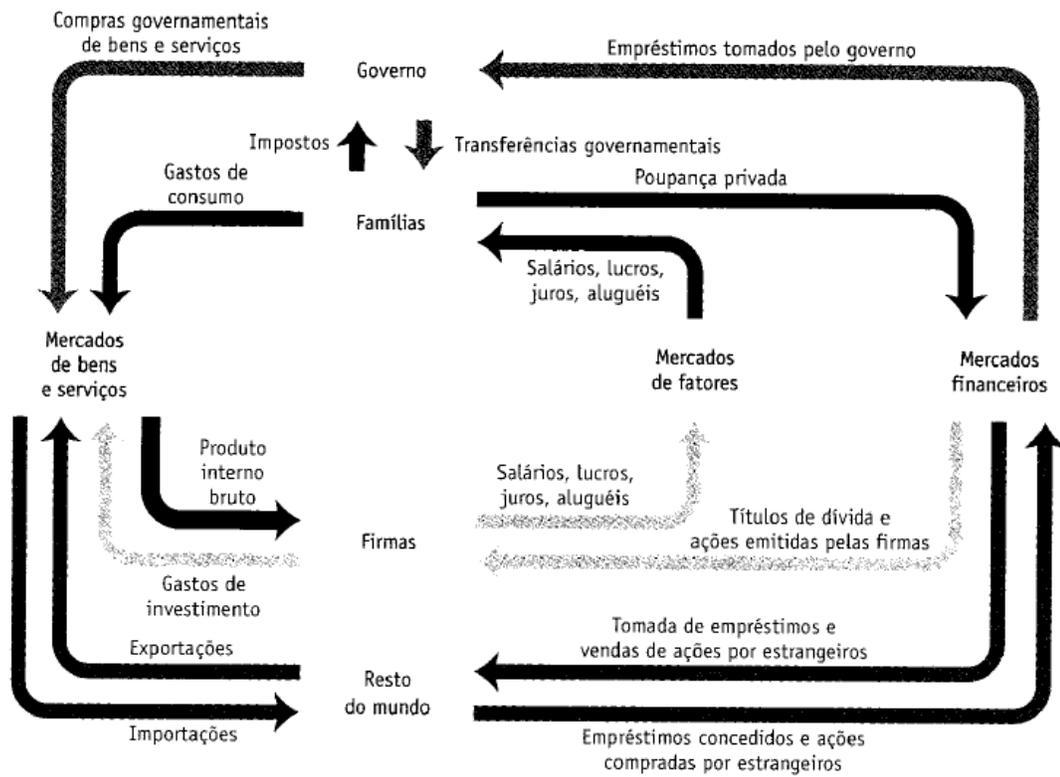


Figura 1: Fluxo circular da riqueza expandido.  
 Fonte: Krugman, 2008.

Tabela 1: Funções do sistema financeiro e os efeitos sobre a economia.

<b>Função do mercado financeiro</b>	<b>Efeitos sobre a economia</b>
Mobilização de recursos	Nessa função, os bancos agregam as poupanças individuais e permitem aos investidores o financiamento completo de seus projetos. Desta forma, investimentos que necessitem de grandes volumes de recursos podem ser realizados através da união de diversas poupanças individuais.
Alocação de recursos no espaço e no tempo	Essa função se refere ao fornecimento de recursos a projetos de investimento de longa duração. Ainda que os indivíduos poupadores possuam horizonte de curto prazo, o que lhes confere um perfil de concessão de empréstimos de alta liquidez, vários projetos de horizonte mais amplo podem ser financiados.
Administração do risco	Devido à diversificação de carteira de concessão de crédito aos diferentes tipos de riscos envolvidos em cada atividade produtiva, os intermediários financeiros figuram como agentes mais preparados em minimizar os riscos que envolvem as transações financeiras na economia.
Seleção e monitoramento de empresas	O sistema financeiro possui a função de selecionar e monitorar as empresas que possuem as melhores propostas de investimento produtivo.
Produção e divulgação de informação	A contribuição do sistema financeiro na economia aumenta à medida que aumenta o crescimento econômico

Fonte: Elaboração Própria. Dados de Origem: Silva & Porto Júnior (2004)

A importância do mercado financeiro na economia é dada, entre outras razões, pelo desempenho de tarefas de redução de custos de transação, dos riscos das operações e aumento da liquidez (Krugman, 2008). Segundo Silva & Porto Júnior (2004), a eficiência provida pelo sistema financeiro reside exatamente na redução dos custos de transação e de informação quando um contrato financeiro é realizado. Os custos de transação podem ser reduzidos substancialmente com a introdução dos intermediários financeiros (bancos), pois esses desenvolveram uma especialização na atividade, obtendo, assim, vantagens das economias de escala, isto é, a redução do custo à medida que o número de transações é aumentado.

Entre os intermediários financeiros, os bancos se destacam por captar recursos dos agentes, a um determinado custo, para vendê-los aos demandantes de recursos por um preço maior (taxa de juros), objetivando lucro. A captação de recursos pode ser originada de recursos próprios (capital dos acionistas) ou de recursos de terceiros, tornando-se, assim, uma obrigação (passivo) para com os acionistas e para com os depositantes, respectivamente. Por outro lado, os bancos aplicam os fundos captados principalmente em títulos provenientes de empréstimos para o setor público e privado. Uma característica importante nessa relação entre origem (passivo) e aplicação (ativo) de recursos é que os passivos bancários são principalmente depósitos de curto prazo, enquanto os ativos são usualmente empréstimos de curto e longo prazos (Moreira, 2009).

Ainda segundo Silva & Porto Júnior (2004), os custos de informação dizem respeito aos custos provenientes da assimetria de informação entre o tomador de empréstimo e o banco, ou seja, a primeira parte do contrato possui melhor conhecimento sobre os riscos do que a segunda. Quando existe esse tipo de assimetria, conflitos de interesses tendem a ocorrer. Há dois tipos de problemas advindos da assimetria de informação: seleção adversa e risco moral. O primeiro ocorre antes que a transação ocorra. A Seleção Adversa se torna um problema no mercado financeiro devido ao fato de que é mais provável que tomadores com riscos elevados demandem crédito, aumentando, assim, a probabilidade que estes sejam selecionados. O segundo ocorre depois que a transação é efetuada. O risco moral se refere ao risco dos tomadores de crédito se engajarem em atividades indesejáveis do ponto de vista do prestador, pois tais atividades reduzem a probabilidade de que o empréstimo seja pago. Da mesma forma que a seleção adversa, o risco moral pode ocasionar o fim da concessão de crédito como uma forma de proteção ao risco do prestador (Silva & Porto Júnior, 2004). Para o caso dos bancos, o valor dos seus ativos pode ser reduzido, uma vez que os tomadores

de empréstimos bancários tornam-se inaptos a quitarem seus débitos, o que faz parte do risco de crédito.

Embora de importância fundamental no desenvolvimento da economia, o sistema financeiro não é totalmente desenvolvido em todos os lugares (Fucidji & Mendonça, 2007). Países mais desenvolvidos, a exemplo da Suíça e dos Estados Unidos, possuem canais de crédito mais poderosos na propagação de políticas econômicas. Segundo Fucidji & Mendonça (2007), no Brasil, esse canal ainda se mostra em estágio bastante incipiente, mesmo para padrões de outros países em desenvolvimento, com estrutura financeira semelhante. A figura 2 apresenta a evolução do número de bancos existentes no Brasil entre os anos de 1995 e 2009.

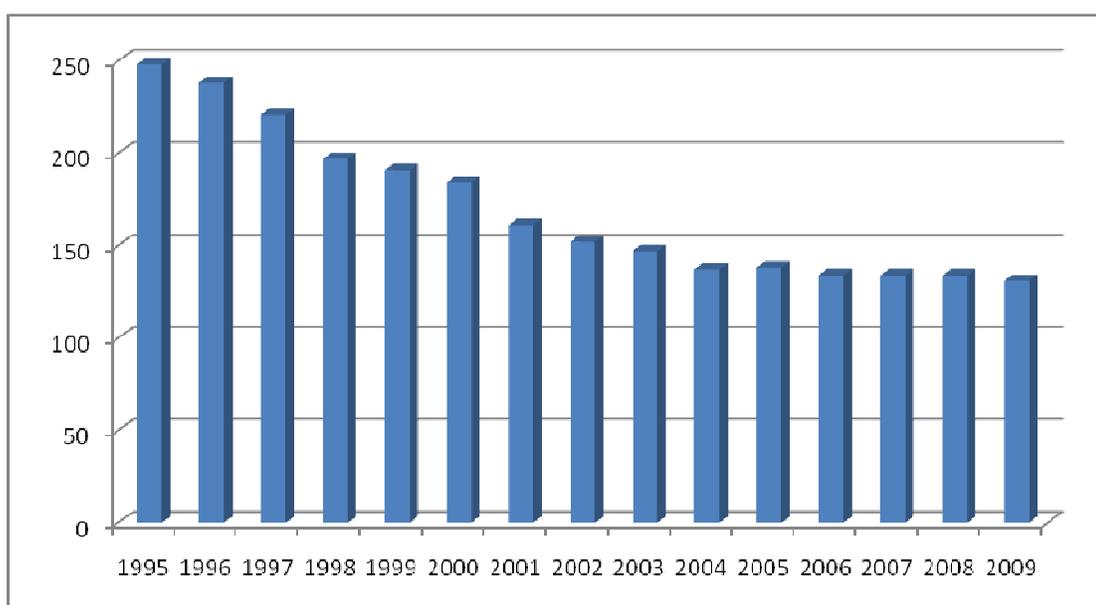


Figura 2: Evolução do número de bancos existente no Brasil.

Fonte: Banco Central do Brasil, 2010.

Um dos fatores ligados ao não desenvolvimento do canal de crédito brasileiro está associado aos altos custos da intermediação financeira. Segundo Cavalcanti & Villamil (2005), esses custos refletem taxas implícitas e explícitas do setor financeiro (taxas sobre transações financeiras, lucros do intermediário, inflação, etc), regulamentação bancária (reservas bancárias) e fatores institucionais (corrupção, subornos). Dentre os fatores não objetivos considerados pelos intermediários financeiros na constituição de seus *spreads*, a falta de informação sobre o tomador de crédito inflaciona os juros cobrados por essas instituições quando financiam projetos.

Segundo Moreira (2002), o risco de crédito pode ser reduzido de várias formas, utilizando-se medidas como: i) seleção criteriosa de clientes; ii) diversificação da carteira de empréstimos para uma clientela portadora de diferentes fatores de risco e iii) utilização de contrapartida (“colateral”), como é o caso dos títulos, por exemplo, em que o devedor disponibiliza para o credor a fim de reduzir o risco de crédito.

Um problema que pode impactar negativamente no sistema financeiro, e assim, nos demais mercados da economia diz respeito a corrida aos bancos. De acordo com Krugman (2008), uma corrida bancária é um fenômeno em que muitos depositantes tentam retirar suas aplicações devido ao temor de falência bancária. Nessas circunstâncias, as famílias perdem por reduzir o grau de confiança no mercado financeiro, diminuindo, assim, a poupança e o fluxos de capitais direcionados tanto as empresas quanto ao governo e investidores do resto do mundo. Os demais mercados envolvidos no fluxo circular da riqueza da economia são influenciados pelas novas expectativas dos agentes.

O canal de crédito pode ainda sofrer maiores estrangulamentos quando passivos de um processo de crise bancária. Por definição, uma crise bancária é caracterizada quando um banco sofre intervenção governamental ou entra em processo de liquidação. Esse processo pode ainda se espalhar para o resto da economia, atingindo outros bancos (McNelis, 2005). Segundo Moreira (2002), a teoria prevê que choques que afetam adversamente o desempenho econômico dos bancos, cujo impacto não pode ser reduzido por meio da diversificação do risco, seriam positivamente correlacionados com uma crise bancária sistêmica.

Seguindo essa lógica, podem-se identificar dois componentes de crise bancária. O primeiro deles diz respeito à magnitude das transferências líquidas de recursos que o sistema é obrigado a realizar. O segundo componente é o limite superior das transferências de recursos, valor acima do qual o sistema pode entrar em processo de crise. O primeiro elemento não constitui um problema, pois, sob condições normais as transferências líquidas não devem se apresentar como grandes dificuldades. O segundo elemento, por sua vez, define a vulnerabilidade do sistema bancário (Hall et al., 2008)

De acordo com Barnhil & Souto (2008), uma crise bancária pode ter grandes poderes de propagação. A literatura tem identificado alguns canais: de acordo com Rochet & Tirole (1986) e Elsinger, Lehar & Summer (2003), a interdependência entre os bancos através de

contratos interbancários pode levar um banco insolvente a não honrar esses contratos, provocando, dessa forma, problemas financeiros para os demais. Um segundo canal de propagação de uma crise bancária foi identificado por Acharya (2001). O autor afirma que os ativos bancários possuem algum grau de correlação, uma vez que bancos podem prover crédito a uma mesma indústria ou a projetos em uma mesma área geográfica. Assim, quaisquer efeitos negativos sobre a indústria ou sobre a área geográfica podem gerar problemas de exposição bancária.

De acordo com Stiglitz (1972), se as perdas de empréstimos excedem as reservas voluntárias e compulsórias, tanto quanto as reservas acionárias, o banco torna-se insolvente. Como os ativos bancários possuem tipicamente baixa liquidez, uma corrida contra os depósitos acelera o processo de insolvência. Ainda segundo o autor, quando uma parcela do sistema bancário experimenta perdas de empréstimos superiores ao seu capital, ocorre uma crise sistêmica. Por fim, ainda segundo Stiglitz (1972), as crises bancárias tendem a gerar maiores externalidades negativas para o resto da economia do que qualquer outro setor financeiro ou produtivo.

Outro meio de propagação de uma crise bancária foi encontrado por Diamond & Dybvig (1983) e Gorton (1985), que afirmam que a notícia sobre a falência de um banco pode provocar um processo de corrida aos bancos, prejudicando o capital dos demais. Segundo Hall (2008), o sistema de pagamentos pode gerar externalidades importantes para a economia como um todo. Essa externalidade resulta do fato de que quando um banco se torna incapaz de honrar os seus compromissos, tal fato pode afetar outro banco até então saudável. Esse processo de interrupções em cascata, de acordo com Hall (2008), reduz a utilidade de todos os depósitos como meios de pagamentos.

Ainda segundo Diamond & Dybvig (1983) e Gorton (1985), uma corrida aos bancos pode ser auto-realizável, isto é, ela pode ocorrer unicamente porque os depositantes acreditam que outros depositantes estão sacando seus próprios fundos, mesmo na ausência de uma deterioração inicial nos balanços bancários. Essa possibilidade, de acordo com os autores, torna as instituições financeiras especialmente vulneráveis.

Hall et al (2008) salienta ainda que os ciclos econômicos podem influenciar o processo de crise bancária. Segundo o autor, um ciclo econômico descendente pode causar problemas de solvência nas empresas, levando-as a não saldar empréstimos bancários, reduzindo,

posteriormente, o volume de crédito concedido pelos bancos. De acordo com o autor, esse processo pode agravar a crise financeira, aumentando o número de bancos afetados pela crise.

Três outros canais são ainda identificados como fatores de propulsão de uma crise bancária: A taxa de juros da economia, a taxa de câmbio e o risco podem, segundo Hall et al (2008), impactar a saúde financeira de múltiplos bancos simultaneamente. Outros fatores como a política de empréstimo bancário, a eficiência do sistema legal em caso de calotes e nível de empréstimos não saldados na economia podem influenciar substancialmente o risco bancário. Por fim, problemas políticos podem gerar perdas diretas para os bancos através da redução do valor de mercado dos seguros do governo e de perturbações macroeconômicas que podem aumentar o volume de empréstimos não saldados.

Os trabalhos citados apresentam pontos importantes quando considerada a importância do sistema de intermediação financeira e os impactos decorrentes da insolvência de um banco sobre todo o sistema bancário. A seção seguinte traz uma análise sobre como vêm sendo realizados estudos empíricos que possam estimar e avaliar crises no sistema bancário. Esses estudos serviram de base para a construção dos modelos de Redes Neurais Artificiais de retropropagação.

## ***2.2. Literatura empírica recente sobre risco bancário no Brasil e no Mundo***

Uma extensa lista de análises empíricas tem sido desenvolvida com o objetivo de avaliar possíveis crises bancárias. Esses trabalhos têm discutido ainda diversas ferramentas de análise que possibilitam estimar a presença de crise sistêmica e verificar quais os principais determinantes da mesma, considerando, para isso, tanto variáveis macroeconômicas como financeiras e/ou microeconômicas.

No que diz respeito à importância das variáveis macroeconômicas na determinação das crises bancárias, Hausmann (1996) afirma que, particularmente quando se busca compreender uma crise em que uma fração substancial do sistema bancário está envolvida, o foco nas características das instituições que parecem falir é incompleta ou potencialmente corrompida. Assim, o autor considera que, embora as falhas do sistema possam ter algum impacto sobre o processo de insolvência, esse pode ser resultado de uma crise maior. O autor analisa ainda que

o impacto de choques sobre o sistema bancário dependerá do regime macroeconômico e da taxa de câmbio no período.

Alexandre, Canuto & Silveira (2003) defendem, por seu turno, que características estruturais de um determinado banco influenciam no processo de falência. Segundo os autores, os fatores macroeconômicos que fragilizam o sistema bancário afetam todos os bancos indiscriminadamente. Dessa forma, os autores alegam que é fundamental compreender os microfundamentos dos bancos que sucumbiram perante a crise e dos que resistiram a ela.

Entre as metodologias de estimação para previsão de crise bancária utilizadas, Hall, Muljawan, Suprayogi & Moorena (2008) destacam a presença de quatro tipos fundamentais: a análise estatística, a análise estocástica, o Valor de Risco (VaR) e as redes neurais artificiais. Segundo os autores, as redes neurais apresentaram melhor desempenho por não estarem sujeitas às limitações dos dados, pela flexibilidade oriunda de distribuições não-paramétricas, além de estarem sujeitas a um baixo erro de previsão. Hall, Muljawan, Suprayogi & Moorena (2008) afirmam ainda que a análise estatística não deve ser utilizada por estar baseada em suposições simplistas.

Para realizar análise de risco de falência bancária para o caso da Indonésia, os autores utilizam apenas variáveis macroeconômicas, pois, segundo eles, a volatilidade do mercado influencia a qualidade do crédito oferecido. Essa análise é reforçada por Li & Zhao (2006), Varoleinen (2004), Wilson (1997) e Samuelson & Norhaus (1991) que enfatizam que as condições macroeconômicas refletem o desempenho do país, impactando diretamente sobre o sistema bancário.

Como variáveis explicativas, o trabalho utilizou a taxa de crescimento do PIB, a taxa de inflação, o preço das ações de cada banco – para o caso daqueles que operam em mercado aberto –, a taxa de câmbio e a quantidade de moeda em circulação. A série de dados utilizada percorreu o período de março de 2001 a novembro de 2005. Os autores justificam a presença da variável taxa de inflação no modelo devido à grande importância da mesma quando o modelo logit é utilizado. Além disso, segundo o estudo, essa taxa reflete o desempenho do governo em estabilizar preços, enquanto as variáveis preço das ações e taxa de câmbio refletem as tendências do mercado. Por fim, o trabalho sugere a variável PIB como sendo um indicador do comportamento da indústria local. Os resultados apontam a variável índice preço

das ações como a de maior influência na determinação de falência de instituições bancárias na Indonésia.

Barnhill e Maxwell (2002) utilizam a metodologia de estimação VaR, correlacionando taxa de juros, *spread* bancário e taxa de câmbio com a volatilidade do mercado financeiro para o caso norte-americano. Essa análise foi posteriormente estendida por Barnhill, Papapanagiotou e Schumacher (2003) para estimar os riscos de crise bancária na África do Sul. Barnhill, Papapanagiotou & Souto (2004) estimam ainda, utilizando a mesma metodologia, a perda potencial do sistema bancário japonês.

Em outro estudo, Barnhill & Souto (2007) consideram o risco no sistema bancário brasileiro utilizando também a metodologia VaR. Para essa análise, foram utilizadas informações sobre os 28 maiores bancos do país. Nesse trabalho, os autores afirmam que o risco de crise bancária no país aumenta consideravelmente quando se adiciona a variável governo ao modelo. Os autores justificam a importância da variável, pois, segundo suas constatações, o risco no mercado bancário é dirigido sistematicamente pelas mesmas condições financeiras e econômicas que impactam sobre o setor público.

Além da variável governo, os autores consideram ainda fatores macroeconômicos como o PIB brasileiro, a taxa de juros e a taxa de câmbio para medir o desempenho de cada banco. O trabalho propõe que variáveis como valores dos seguros, empréstimos e outros ativos também deveriam ser utilizados na análise. Como resultado, o estudo observa que os bancos brasileiros são mais suscetíveis a crises sistêmicas quando detêm títulos do governo entre seus ativos. Resultado semelhante é encontrado por Alexandre, Canuto & Silveira (2003). De acordo com os autores, desde o retorno do país à democracia, no início dos anos 1980, os bancos, fundamentalmente estaduais, já vinham emprestando grandes quantias a órgãos governamentais, empréstimos esses muitas vezes não pagos. O trabalho sugere, dessa forma, que a falência dos bancos públicos está associada a problemas de ordem fiscal e não a problemas de ordem financeira (Baer & Nazmi, 2000).

Hausmann (1996) analisa, de forma abrangente, os determinantes de crises bancárias. Segundo o autor, o impacto de um choque sobre o sistema bancário de um país dependerá do regime da política macroeconômica no período, particularmente da taxa de juros, da taxa de câmbio e do Produto Interno. O estudo salienta que quando o sistema bancário parece passar

por fragilidades, algum grau de flexibilidade na taxa de câmbio reduzirá a probabilidade de que um choque adverso se transforme em uma crise de forte perturbação no sistema.

A importância da taxa de juros na determinação de crises bancárias é ratificada por Mishkin (1996). De acordo com o autor, a maioria dos problemas de pânico bancário nos Estados Unidos foi precedida pelo incremento das taxas de juros de curto prazo. Tais aumentos, por sua vez, podem ser devidos a vários fatores, a exemplo da elevação da taxa de inflação, política monetária restritiva, aumento da taxa de juros internacional, falta de controle da taxa de juros em função da liberalização financeira ou necessidade de defender a taxa de câmbio contra ataques especulativos (Galbis, 1993; Velasco, 1987; e Reinhart & Kaminsky, 1999).

A relevância da variável taxa de câmbio na delimitação da crise bancária é enfatizada por Arkelof & Romer (1993), Minskin (1996), Drees & Pazar-Basioglu (1995). Segundo os autores, uma desvalorização não esperada na taxa de câmbio da economia pode afetar negativamente a lucratividade bancária, por meio de um aumento da inadimplência. Empréstimos em moeda estrangeira foram fontes de problemas bancários no Chile em 1981, no México em 1995, nos países Nórdicos no início dos anos 1990 e na Turquia em 1994 (Moreira, 2002).

Outra variável macroeconômica importante na demarcação de uma crise bancária diz respeito à inflação. Segundo Baer & Nazmi (2000), a inflação era favorável aos bancos brasileiros por proporcionar grandes rendimentos via receitas inflacionárias (*float*), além de reduzir o valor real dos passivos bancários e por adicionar liquidez ao sistema. A relevância dessa variável no processo de insolvência bancária é enfatizada também por Hausmann (1998). Segundo o autor, a volatilidade nas taxas de inflação prejudica a avaliação dos riscos de crédito das carteiras dos bancos. Tal fato foi observado por Giambiagi (2005) para o caso do Brasil durante o período de implementação do plano real. Segundo o autor, além de reduzir o *float*, o processo de estabilização de preços gerou outros problemas nos bancos devido ao estágio incipiente em que se encontrava o sistema bancário nacional no período<sup>1</sup>.

---

<sup>1</sup> Segundo Giambiagi, embora o plano real tenha gerado um aumento da demanda por crédito com o aumento do PIB, esse aumento gerou problemas de longo prazo para o sistema bancário. De acordo com o autor, devido ao estágio primário do sistema bancário brasileiro, a maior parte dos intermediários financeiros não conseguiu mensurar, corretamente os riscos de crédito e a presença do risco moral. Além desses fatores, soma-se ainda que, com o aumento da taxa de juros de curto prazo (devido à crise mexicana), apenas os tomadores mais propensos ao risco tomam empréstimos, aumentando a probabilidade de inadimplência.

Canuto & Lima (1996) indicam que outras variáveis macroeconômicas como taxa de juros internacional e o balanço de pagamentos também podem impactar sobre o sistema bancário causando, dessa forma, um processo de crise bancária. O estudo aponta ainda para a importância de variáveis microeconômicas e financeiras como a estrutura de incentivos de redes de segurança além dos processos de concorrência na determinação de insolvência bancária.

Demirguç-Kunt & Detragiache (1997) fornecem uma abordagem para os determinantes de crise bancária tanto para países desenvolvidos como para países em vias de desenvolvimento. Segundo os autores, um indicador de crise bancária diz respeito à diferença entre ativos e passivos, ou seja, o patrimônio líquido da instituição financeira. Eles consideram que, se essa variável alcançar valores negativos, o banco se encontrará em estado de insolvência.

Seguindo a linha de determinantes financeiros e microeconômicos de crises bancárias, Gorton (1988) defende que processos de insolvências bancárias estariam relacionados diretamente ao comportamento do consumidor: ao observar variações do ambiente financeiro, o consumidor, buscando reduzir perdas, antecipa a crise ao fazer uma retirada repentina dos depósitos bancários. Fato semelhante foi observado por Park (1991), ao analisar o processo de pânico bancário nos Estados Unidos. Segundo o autor, a falta de informação sobre a situação financeira dos intermediários leva os depositantes a uma corrida bancária. Para ele, esse fato pode ser resolvido com a provisão, pelo governo ou pelos bancos, de informações referentes à situação de solvência de cada banco específico.

Donaldson (1992) e Cole & Gunther (1995) analisam os determinantes das crises bancárias considerando variáveis financeiras dos bancos individuais. Os resultados encontrados pelos autores apontam para a investigação mais detalhada dos impactos dos seguros de depósitos, da suspensão das retiradas e da qualidade do tomador de empréstimo sobre o processo de insolvência bancária. Cole & Gunther (1995) afirmam ainda que indicadores como o capital, ativos problemáticos e renda líquida também são importantes na determinação da falência bancária.

Hardy & Pazarbasioglu (1998) analisam o processo de crise bancária em países selecionados e dividem as variáveis determinantes da crise em três grupos: reais, bancárias e macroeconômicas. No primeiro grupo, as variáveis explicativas objetivam capturar o grau do

uso eficiente do crédito assim como a capacidade de pagamento dos tomadores de empréstimo. Nesse bloco, foram consideradas as variáveis taxa de crescimento do produto interno real em relação ao ano anterior, as taxas de crescimento do consumo privado e do investimento, além da relação entre o incremento do capital por produto como uma *proxy* do uso eficiente do investimento.

Para o segundo grupo, os autores analisam os indicadores associados às características bancárias. As variáveis selecionadas nesse grupo dizem respeito à variação do passivo bancário em relação ao PIB, que serviria como *proxy* de uma corrida aos bancos e uma perda na confiança no sistema bancário. O segundo indicador desse grupo diz respeito à taxa de crescimento do crédito destinado ao setor privado. Por fim, a terceira variável se refere à taxa de crescimento dos passivos estrangeiros do banco. Essa foi utilizada para explicar como o sistema bancário conta com o capital estrangeiro nas suas operações, servindo como uma *proxy* para a vulnerabilidade do sistema a uma retirada brusca dos fundos internacionais.

O último grupo de indicadores analisado por Hardy & Pazarbasioglu (1998) corresponde às variáveis macroeconômicas que podem ou não estar relacionadas direta ou indiretamente (através do setor real) com a situação de solvência do sistema bancário. Os autores apontam, nesse último grupo, as variáveis taxa de inflação (aproximadas pelo deflator do PIB), taxa de juros real dos depósitos, mudanças na taxa de câmbio e o aumento real das importações.

O estudo de Hardy & Pazarbasioglu (1998) utilizou a metodologia do modelo logit e concluiu que problemas de insolvência bancária estão associados tanto a variáveis reais, macroeconômicas quanto as de ordem financeira. Segundo os autores, problemas bancários são oriundos de reduções no PIB, crescimentos da taxa de inflação, expansão do crédito para o setor privado e entrada de capital, aumento da taxa de juros, diminuição do incremento entre o capital e o produto, além de um rápido decréscimo na taxa de câmbio e um choque adverso de negócios.

Janot (2001) utiliza dois modelos para a identificação dos microfundamentos de falência bancária no Brasil: o modelo logit e o modelo de risco proporcional de Cox. Para esse estudo, o autor considerou uma amostra composta por 21 bancos que sofreram intervenção ou foram liquidados pelo Banco Central entre os anos de 1995 e 1996, além de um grupo de 40 bancos solventes privados de grande porte. Como possíveis previsores de crise bancária no Brasil, o

trabalho testou 68 indicadores econômico-financeiro que compõem o INDCON (Indicadores Econômico-financeiros de Instituições sob Acompanhamento e Controle do Banco Central do Brasil). Os resultados do trabalho apontam como variáveis previsoras de insolvência bancária a participação das captações em moeda estrangeira dentro das exigibilidades, a participação das operações ativas não usuais na carteira ativa e a participação de ativos de liquidez imediata nas operações ativas usuais.

Em trabalho semelhante, Rocha (1999) estima a possibilidade de falência bancária no Brasil também através do modelo de risco proporcional de Cox, utilizando variáveis financeiras. Nesse trabalho, a autora desconsidera os bancos públicos declarados como insolventes e analisa apenas 15 bancos privados declarados como insolventes em conjunto com os 17 maiores bancos privados no país. Os resultados do estudo apontam como variáveis determinantes da falência bancária no Brasil a elevada alavancagem – para o caso de pequenos bancos –, os elevados custos administrativos – incluindo-se encargos com pessoal –, a baixa margem líquida e o elevado crescimento das captações. A baixa captação em moeda estrangeira com relação às demais fontes de captação e a baixa participação dos ativos de liquidez imediata no total das operações ativas usuais, assim como encontrado no trabalho de Janot (2001), também foram apresentadas como determinantes de falência bancária.

Alexandre, Canuto & Silveira (2003) analisam os determinantes das falências bancárias para o caso dos bancos atacadistas brasileiros. Os autores utilizam uma amostra composta por 15 bancos atacadistas que sofreram liquidação ordinária ou extrajudicial por parte do Banco Central entre julho de 1994 e dezembro de 1996 associados a um grupo formado por 33 bancos atacadistas que se mantiveram solventes no período. O trabalho analisa a probabilidade de falência bancária utilizando o modelo logit. Para essa análise, os autores consideram 26 indicadores econômico-financeiros dos bancos. Os resultados do estudo apontam as variáveis capital de giro, custos da intermediação e solvência corrente como determinantes das crises de insolvência dos bancos atacadistas brasileiros.

Na análise de crise no sistema bancário norte-americano, McNelis (2005) utiliza três modelos de avaliação: modelos de redes neurais artificiais, Logit e Weibull e afirma que para resultados dentro da amostra, métodos não lineares apresentavam mais falsos positivos que falsos negativos. Considerando os desempenhos dos três modelos, o autor constatou não existir muitas diferenças entre os resultados, concluindo que o modelo de redes neurais com

três neurônios intermediários apresenta resultado semelhante ao provido pelo método mais acurado, quando em observações dentro da amostra.

Para resultados fora da amostra, o autor observa que as redes neurais artificiais apresentam melhor desempenho, com menor erro quadrado médio da previsão, sendo seguido pelo logit, considerado pelo autor, o tipo mais simples de rede neural. Segundo McNelis (2005), o desempenho da família de redes neurais indica, claramente, que esse método deve ser preferido na estimativa de crises bancárias.

Para realizar o estudo acima, o autor considera tanto variáveis micro como macroeconômicas e traz como resultado a importância das variáveis nível de capital e volume total de empréstimos nacionais. Considerando, assim, que tanto as condições macroeconômicas quanto as características individuais de cada banco são importantes sinais para possíveis problemas bancários.

Em análise semelhante à realizada por McNelis, Baesens (2003) compara o desempenho das redes neurais e do modelo logit na classificação do *credit scoring* e conclui que as redes neurais obtêm um desempenho significativamente melhor que a regressão logística, quando considerado a 5% de significância. O autor afirma ainda que, embora a diferença absoluta possa ser considerada pequena, deve ser notado que pequenas diferenças absolutas na classificação de desempenho podem ser traduzidas em perdas substanciais de ativos pelos bancos.

Uma desvantagem considerada pelo autor sobre o uso dos modelos de redes neurais na previsão de risco bancário diz respeito a sua estrutura em caixa preta, pois, embora a aproximação universal das redes neurais pareça atrativa, segundo o autor, a ausência de poder explicativo tem prejudicado o seu uso no gerenciamento do risco.

A tabela abaixo apresenta um resumo de alguns dos trabalhos encontrados na literatura que analisam risco bancário e as variáveis utilizadas em cada análise.

Tabela 2– Estudos empíricos sobre crises bancárias

<b>Autores</b>	<b>Variáveis Utilizadas</b>	<b>Sistema Bancário Analisado</b>	<b>Metodologia</b>
Hall, Muljawan, Suprayogi, Moorena (2008)	*Taxa de crescimento do PIB; *Taxa de inflação; *Preço das ações de cada banco; *Taxa de câmbio; *Quantidade de moeda em circulação.	Indonésia (dados de Março de 2001 a novembro de 2005)	Redes Neurais Artificiais
Barnhill e Maxwell (2002)	*Taxa de juros; *Spread bancário; *Taxa de câmbio.	Estados Unidos	Valor de Risco (VaR)
Barnhill, Papapanagiotou e Schumacher (2003)	*Taxa de juros; *Spread bancário; *Taxa de câmbio.	África do Sul	VaR
Barnhill, Papapanagiotou e Souto (2004)	*Taxa de juros; *Spread bancário; *Taxa de câmbio.	Japão	VaR
Barnhill & Souto (2008)	*Volume de títulos do governo; *PIB; *taxa de juros; *Taxa de câmbio; *Valores dos seguros; *Valores dos empréstimos; *Demais ativos.	Brasil	VaR
McNelis (2005)	*Presença do Banco Central; *Capital/ativos (%); *Empréstimos agrícolas/total de empréstimos; *Empréstimos ao consumidor/ total de empréstimos; *Empréstimos de cartão de crédito total de empréstimos; *Empréstimos para instalações/ total de empréstimos; *Retorno dos ativos (%); *Margem de juros (%); *Ativos líquidos/total de ativos (%); *Total de Ativos norte-americanos/PIB	Estados Unidos	redes neurais artificiais, logit e weibull
Hausmann (1998)	*PIB *Taxa de Juros *Taxa de Câmbio	-	Análise descritiva
Canuto & Lima (1999)	*PIB *Taxa de Juros *Taxa de Câmbio *Estrutura de incentivos de redes de	-	Análise descritiva

	segurança *Estrutura de processos *Taxa de juros internacional *Balanço de pagamentos		
Demirgüç-Kunt & Detragiache (1998)	*Ativos do banco *Passivos do banco	-	Análise descritiva
Hardy & Pazarbasioglu (1998)	*Variação do PIB *Taxa de crescimento do produto privado *Taxa de Crescimento do Investimento *Capital/Produto *Passivo bancário em relação ao PIB *Crédito destinado ao setor privado *Passivos estrangeiros do banco *Taxa de Inflação *Taxa de juros real *Taxa de Câmbio *Aumentos no volume das importações	Seleção de diversos países	Logit
Janot (2001)	* Indicadores Econômico-financeiros de Instituições sob Acompanhamento e Controle do Banco Central do Brasil	Brasil	Logit e Modelo Proporcional de Cox
Rocha (1999)	*Margem Líquida; *Alavacagem; *Captações	Brasil	Modelo Proporcional de Cox
Alexandre, Canuto & Silveira (2003)	*Imobilização Própria; *Imobilização Total; *Capital de Giro; *Solvência Corrente; *Inadimplência; *Provisionamento; *Custos Administrativos; *Custos da Intermediação; *Margem Líquida; *Rentabilidade do Patrimônio Líquido; *Crescimento das aplicações; *Crescimento do Lucro líquido	Brasil (apenas para bancos atacadistas)	Logit
Gorton (1998)	*Comportamento do consumidor	-	Análise descritiva
Donaldson (1992)	*Seguros de depósitos *Volume de retirada *Qualidade do tomador de empréstimos	-	Análise descritiva
Cole & Gunther (1995)	*Seguros de depósitos *Volume de retirada *Qualidade do tomador de empréstimos *Capital *Ativos Problemáticos *Renda líquida	-	Análise descritiva

Fonte: Elaboração Própria

### **3. ASPECTOS METODOLÓGICOS**

#### ***3.1. Modelo de Redes Neurais Artificiais de Retropropagação***

De acordo com Portugal & Fernandes (2000), os modelos de Redes Neurais Artificiais (RNA), também conhecidos como modelos conexionistas de computação ou sistema de processamento paralelo distribuído, são representações matemáticas inspiradas no funcionamento do cérebro humano. Alexander (2007) afirma que as redes neurais são aproximadores universais, no sentido de que elas podem ajustar qualquer função não-linear com qualquer grau de precisão. Ainda segundo Hall, Muljawan, Suprayogi & Moorena (2008), esses modelos possuem flexibilidade para distribuições paramétricas não-específicas, ou seja, conseguem capturar relações não estruturadas entre as variáveis, além de ter vantagens em superar limitações nos dados.

De acordo com Mandic & Chambers (2001), o conexionismo surgiu na década de 40, com o trabalho dos pesquisadores Mcculloch e Pitts, que estudaram a capacidade de um modelo neural simples, composto por apenas um neurônio. Nos anos seguintes vários pesquisadores contribuíram com o progresso da área através da ampliação das regras de aprendizagem e o desenvolvimento de arquiteturas de sistemas não lineares dinâmicos. Porém, de acordo com Gately (1996), só em 1986, quando os computadores já tinham sido desenvolvidos com força suficiente para o início das pesquisas práticas com as redes neurais e com a redescoberta do algoritmo de Retropropagação por Rumelhart et al (1986), foi que as redes neurais tornaram-se aptas a resolverem problemas na área de negócios. De acordo com Mandic e Chambers (2001), os modelos de redes neurais emergiram nos anos 80 como um potencial modelo para a realização de previsões não lineares, de alta complexidade e com dados não estacionários. Devido à evolução de computadores pessoais, que possibilita, ainda hoje, o desenvolvimento e aprimoramento de redes neurais, não se pode determinar ao certo a quantidade de redes neurais existentes.

Segundo Gately (1996), as redes neurais podem ter aplicações nas diversas áreas do conhecimento, como no diagnóstico médico, previsões financeiras, controle de voo, reconhecimento da fala e exploração de poços de petróleo. No campo das previsões financeiras, seu emprego é amplo, onde destacamos a previsão de preços de ações, de indicadores econômicos, da saúde financeira de empresas, do risco de crédito e do risco bancário.

Segundo Mandic & Chambers (2001), um modelo de rede neural é especificado pela sua topologia, pelas características dos neurônios e pela regra de aprendizagem ou treinamento. A topologia ou arquitetura do modelo é determinada pela quantidade de camadas, onde cada uma delas é composta por um ou mais neurônios (unidades de processamento). Apesar de o número de redes existentes não ser conhecido, de acordo com Gately (1996), aproximadamente 90% das redes são de retropropagação composta por uma camada de entrada, uma intermediária e uma de saída. Apesar disso, uma rede neural pode possuir várias camadas intermediárias ou não possuí-las. A figura abaixo mostra um exemplo de rede neural com uma camada de entrada (com dois neurônios, E1 e E2), uma camada intermediária (composta por cinco neurônios I1 a I5) e uma camada de saída (formada pelo neurônio S).

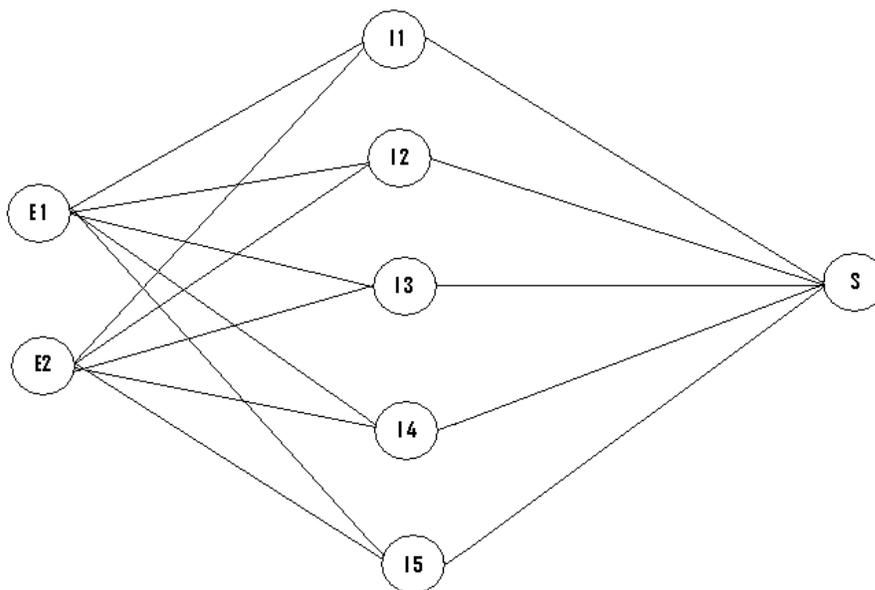


Figura 3: Exemplo de um modelo de rede neural do tipo Perceptrons *Multilayer Perceptrons*  
Fonte: Cavalcanti et al, 2009

Segundo Mandic & Chambers (2001), o neurônio representa o componente básico da rede neural. Os neurônios que compõem a camada de entrada da rede neural são responsáveis por inserirem as informações das variáveis independentes, através de valores, no modelo. Já os demais neurônios, localizados nas demais camadas, são responsáveis por determinarem a relação matemática entre as variáveis independentes e dependente(s). Ainda segundo os autores, um neurônio pode ser definido matematicamente por

$$y = \Phi \left( \sum_{i=1}^N w_i x_i + w_0 \right) \quad (1)$$

Onde os  $x_i$ 's são os valores de entrada em cada neurônio,  $w_i$ 's são os pesos que determinam as ligações entre os neurônios,  $w_0$  é o peso do neurônio,  $y$  é o valor gerado pelo neurônio e a função  $\Phi$ , conhecida como função de ativação, é geralmente determinada por uma função do tipo sigmóide como (2).

$$y(u) = \frac{1}{1 + e^{-u}} \quad (2)$$

De acordo com Smith (1993), a função do tipo sigmóide mais utilizada é função logística.

Do ponto de vista dos padrões das conexões entre os neurônios, as redes neurais podem ser divididas em dois tipos: as redes feedforward, em que cada neurônio de uma camada possui conexões diretas com neurônios da camada seguinte ou camadas mais afastadas, e as redes feedback, onde, além das ligações existente nas redes feedforward, existem ligações que partem de camadas avançadas e retornam a camadas anteriores.

A construção de um modelo de rede neural é dividida em duas etapas. na primeira, que é conhecida como fase de aprendizagem ou de treinamento, as conexões entre os neurônios são ajustadas até que o modelo seja capaz de compreender as relações existentes entre a(s) variável(is) independente(s) e a(s) variável(is) dependente(s) com o grau de precisão desejado. Na segundo fase, conhecida como fase de teste ou validação, através da realização de previsões *ex post*, avalia-se se o modelo ajustado possui poder preditivo de realizar previsões com grau de precisão semelhante ao adotado na fase de treinamento. De acordo com Gately (1996), 90% dos dados disponíveis para a construção do modelo devem ser utilizados no processo de aprendizagem e o restante dos dados deve ser utilizado na fase de validação. Antes de iniciar o processo de aprendizagem, deve-se definir a quantidade de camadas do modelo, a quantidade de neurônios em cada camada, o tipo de função de ativação dos neurônios, os tipos de ligações entre os neurônios e o critério de convergência. O critério de convergência é responsável por definir o ajustamento dos valores gerados pelo modelo com os dados da variável dependente observados. Após definidas essas informações, baseado em uma

regra de aprendizagem, os pesos das conexões entre os neurônios são ajustados por um processo iterativo. Considerando a importância apontada por Gately (1996) com relação aos modelos que possuem três camadas, a literatura indica o Algoritmo de Retropropagação (*backpropagation*), também conhecido com Regra do Delta Generalizado, como a regra mais utilizada para a aprendizagem. Portugal & Fernandes destacam, ainda, que durante o processo de aprendizagem, utilizando o algoritmo de Retropropagação, o erro gerado na camada de saída é propagado para trás na rede para que os pesos sejam ajustados. Cada vez que os erros são retropropagados e os parâmetros ajustados, diz-se que o modelo realiza uma iteração. Para mais detalhes sobre o Algoritmo de Retropropagação e suas propriedades, ver Nielsen, Jensen & Kendall (1993). A figura abaixo mostra uma rede neural do tipo Multilayer perceptrons.

Um possível problema oriundo do processo de treinamento da rede neural artificial diz respeito ao superajustamento ou super-treinamento da mesma. Nesse caso, a rede inicia um processo de memorização das relações estocásticas das variáveis e perde o poder de realizar generalizações (previsões) (Arnaud, 2007). Para lidar com esse tipo de problema, alguns métodos como a regularização dos termos (Poggio e Girosi, 1990), a seleção de modelos (Moody, 1992) ou parada com validação cruzada (Hecht-Nielsen, 1990) têm sido sugeridos pela literatura.

Embora muitos trabalhos considerem as redes neurais como modelos eficientes para estudo de casos de falências bancárias devido ao seu poder de generalização universal, algumas críticas têm sido feitas a respeito da sua estrutura “opaca” ou em “caixa-preta”. Segundo Hall, Muljawan, Suprayogi & Moorena (2008), o maior inconveniente associado ao uso das redes neurais como instrumento de tomada de decisão diz respeito à ausência de capacidade de explicação. Assim, de acordo com os autores, embora as RNAs possam alcançar alto grau de ajustamento na previsão, a razão que leva a esse ajuste não está prontamente disponível, ou seja, o uso de redes neurais como preditores de crise bancária não permite a formalização da relação entre variáveis de entrada e variáveis de saída de maneira compreensiva. Entretanto, a literatura recente tem enfatizado que o uso das redes neurais artificiais diversas vantagens às análises. Ainda segundo Hall, Muljawan, Suprayogi & Moorena (2008), esses modelos possuem flexibilidade para distribuições paramétricas não-específicas, ou seja, conseguem capturar relações não estruturadas entre as variáveis, além de ter vantagens em superar limitações nos dados. Os autores afirmam ainda que as redes neurais podem possuir uma ou mais camadas intermediárias, dependendo da complexidade existente entre as variáveis

dependentes e independentes. Por fim, eles salientam que as RNA estão sujeitas a previsões com erros mínimos e pequenas variâncias

### **3.2. Amostra**

Para o estudo em tela, foram selecionados três tipos de amostras: o primeiro considerou 19 bancos privados insolventes (aqueles que sofreram processo de liquidação pelo Banco Central) entre os anos de 1996 e 1999 associados aos 30 maiores bancos privados do país. Esses foram selecionados como base de comparação, seguindo metodologia proposta por Rocha (1999). A segunda amostra considerou ainda os 19 bancos privados falidos entre 1996 e 1999 e associou, a esses, 30 bancos privados selecionados através do processo de amostragem aleatória, de um universo composto por 132 bancos privados. O processo de seleção aleatória dos bancos solventes foi realizado com base na metodologia de Whalen (1991). Por fim, a última amostra considerou 23 bancos privados e públicos estaduais liquidados no período combinados com 31 bancos públicos estaduais e privados solventes no período. Para o processo de amostragem do terceiro grupo de bancos solventes, utilizou-se o processo de amostragem estratificada, dada a pequena participação dos bancos públicos estaduais na população total.

Vale salientar que a escolha dos dois primeiros tipos de amostras foi estabelecida a fim de observar a existência de variação dos resultados do modelo com a alteração da amostra. Assim, esse dois tipos foram escolhidos com o objetivo de verificar em que medida as variáveis que explicam falência dependem do processo de amostragem. A terceira amostra foi estabelecida com o objetivo de tentar observar se o processo de falência dos bancos públicos pode ser previsto, ainda que, segundo a literatura, esse processo esteja mais ligado a fatores de ordem fiscal do que a indicadores financeiros ou macroeconômicos. Segundo Rocha (1999), todos os bancos existentes no mercado poderiam ser usados no processo de amostragem, mas isso implicaria em uma presença de poucos bancos insolventes na amostra, o que pode comprometer o processo de estimação.

### **3.3. Especificação da Modelagem Utilizada**

Para o presente estudo, o modelo de redes neurais *Multilayer Perceptrons* com algoritmo de retropropagação e uma camada intermediária de neurônios será utilizado para estimar

possíveis processos de falências bancárias no Brasil. A presença de apenas uma camada intermediária é reforçada por diversos trabalhos teóricos a exemplo do estudo de Corrar, Paulo & Dias Filho (2007), pois, de acordo com a literatura, apenas uma camada é suficiente para aproximar qualquer função contínua.

As variáveis independentes consideradas na estimação do modelo seguirão o estabelecido pela literatura. Dessa forma, assim como realizado por Hardy & Pazarbasioglu (1998), o presente trabalho também agrupará as variáveis em três grupos de acordo com a sua natureza: reais, macroeconômicas e financeiras.

Para o caso da variável real, será considerada a variação real do Produto Interno Bruto no período. O uso da variável PIB foi realizado nos trabalhos de Hall, Muljawan, Suprayogi & Moorena (2008), Barnhill & Souto (2008), McNelis (2005), Hausmann (1998), Canuto & Lima (1999) e Hardy & Pazarbasioglu (1998).

Como variáveis macroeconômicas, o modelo utilizará os indicadores de inflação, taxa de juros real, taxa nominal de câmbio média no período e índice médio da bolsa de valores. O indicador de inflação seguirá o proposto por Hardy & Pazarbasioglu (1998) e será calculado através do IPCA. Os trabalhos de Hall, Muljawan, Suprayogi & Moorena (2008), Barnhill e Maxwell (2002), Barnhill, Papapanagiotou e Schumacher (2003), Barnhill, Papapanagiotou e Souto (2004), Barnhill & Souto (2008), McNelis (2005), Hausmann (1998), Canuto & Lima (1999), Hardy & Pazarbasioglu (1998) e Hall et al (2008) ressaltam a importância da inserção dessas duas variáveis na determinação da falência bancária. Hall, Muljawan, Suprayogi & Moorena (2008) sugerem ainda uma forte relação entre as variações na bolsa de valores e os processos de insolvência bancária.

Por fim, para o caso das variáveis bancárias, o trabalho seguirá o abordado por Demirgüç-Kunt & Detragiache (1998), Alexandre, Canuto & Silveira (2003), Janot (2001) e Rocha (1999). Para esse grupo, serão consideradas as variáveis total de ativos do banco, total de passivos, despesas de intermediação, total de captações, custo de intermediação (participação do total das despesas de intermediação em relação captação total), patrimônio líquido, ativos permanentes, capital de giro, total de captações em mercado aberto, participação das operações de mercado aberto no total de passivos. Por fim, uma última variável de

característica binária denominada consolidado bancário foi inserida no modelo a fim de captar os efeitos de insolvência bancária entre bancos comerciais e bancos não-comerciais.

O estudo é desenvolvido a partir da análise de amostras contendo bancos solventes e insolventes para o período entre 1996 e 1999. Seguindo o proposto por Lane, Looney & Wansley (1986), foi considerado o conjunto de dados de um ano atrás de cada banco. Esse grupo de variáveis é composto por indicadores reais, macroeconômicos e financeiros para cada um dos bancos insolventes. Para o caso dos bancos solventes, determina-se que a variável dependente pode ser considerada como uma variável censurada, uma vez que tudo o que se sabe sobre esses bancos é que eles sobreviveram até dezembro de 1999. Para esse último grupo de observações, foram utilizados os mesmos indicadores datados do final de 1998.

Finalmente, é importante observar que o modelo analisado segue o previsto pela literatura no que diz respeito à hipótese de variáveis independentes constantes ao longo do período observado. Assim, conforme Rocha (1999), essa hipótese pressupõe que os valores dos indicadores não mudam até o banco quebrar ou ser censurado. Ainda segundo a autora, embora essa hipótese possa ser questionada, o bom ajustamento e os resultados de previsão justificam sua adoção. A figura a seguir apresenta a estrutura da rede neural de maior complexidade (16 neurônios de entrada, uma camada intermediária contendo um número variado de neurônios, um neurônio de saída) utilizada no presente trabalho.

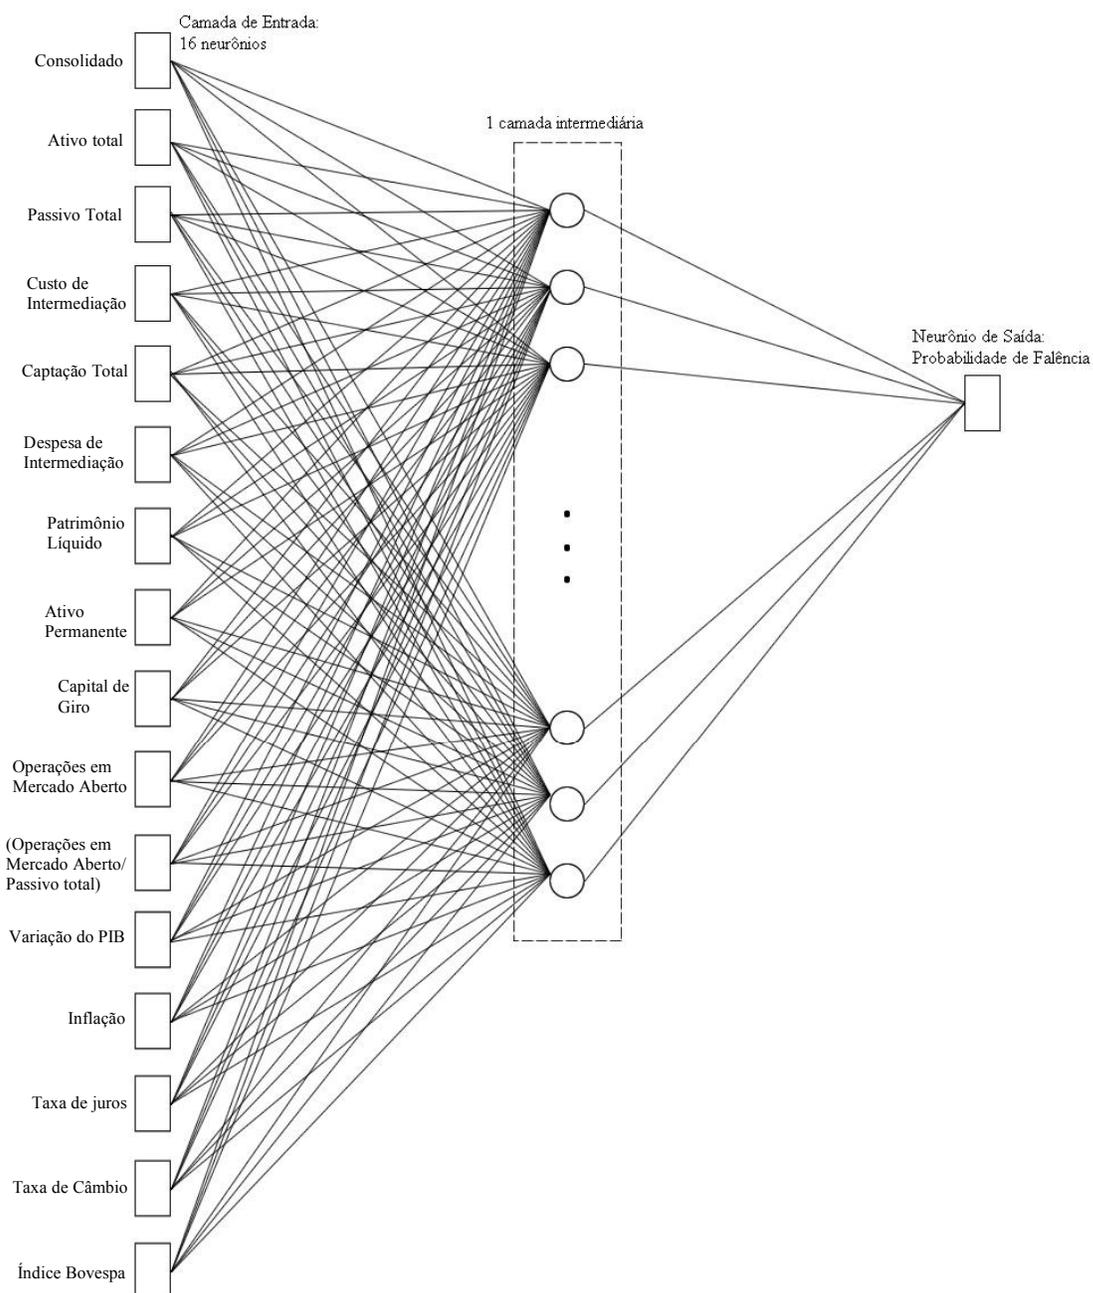


Figura 4 – Estrutura da Rede Neural Utilizada  
Fonte: Elaboração Própria

A modelagem a ser construída tem como objetivo verificar a probabilidade de insolvência bancária no Brasil. Deve-se, dessa forma, fazer uso do conjunto de variáveis explicativas

referentes ao ano da quebra ou ao ano de censura dos bancos. Para o presente trabalho, o ano de 1999 foi considerado de censura, pois, tudo o que se sabe sobre os bancos solventes da amostra é que eles sobreviveram até esse ano. Dessa forma, foram utilizadas as informações do ano de 1998 para esse conjunto de observações. No processo de treinamento da rede neural, foram incluídos apenas os bancos que faliram até 1998. O objetivo desse procedimento é utilizar as observações não incluídas na estimação dos modelos para verificar a robustez dos mesmos na avaliação de previsão fora da amostra.

No que diz respeito às séries das variáveis explicativas, tendo em vista o alto grau de correlação entre as variáveis (ver apêndice 2), existe a possibilidade da existência de multicolinearidade. Segundo Lima (2004), nessa situação, pode existir a inversão de alguns coeficientes dos parâmetros estimados, fornecendo, dessa forma, falsas estimativas de falência bancária. Para solucionar esse problema, foram estimados três modelos de redes neurais artificiais a fim de observar o poder de previsão de acordo com o grupo de variáveis inseridas como neurônios de entrada. Em todos os casos, a qualidade das previsões geradas será avaliada em dois momentos: inicialmente, será analisada a proporção de acerto dentro da amostra utilizada para o treinamento da rede neural e, na segunda etapa, será feita uma análise de robustez dos modelos, avaliando as previsões dos mesmos para dados fora da amostra.

### **3.4. Origem dos Dados**

Para o presente estudo, a informação necessária para a avaliação de insolvência no sistema bancário brasileiro é analisada através das características macroeconômicas do país e das características microeconômicas e financeiras dos bancos. A justificativa para a inserção de variáveis macroeconômicas no modelo de previsão de insolvência bancária é dada por Li & Zhao (2006) que afirmam que condições macroeconômicas afetam o sistema bancário em um país. Esse fato é ratificado por Hall et al (2008) e Samuelson & Nordhaus (1991) que consideram a taxa de inflação do país como uma *proxy* sobre o desempenho do governo na política de estabilização de preços e considera ainda que a taxa de câmbio e os preços das ações meçam as tendências de mercado no país. As variáveis macroeconômicas utilizadas no presente trabalho estão disponíveis no IBGE, Banco Central, Ipeadata. Os dados que dizem respeito às variáveis particulares de cada banco são disponibilizados pelo Banco Central. As variáveis microeconômicas consideradas seguem o indicado pela literatura e são de grande

relevância, pois podem demonstrar informações sobre o estágio de solvência financeira que se encontra cada banco.

#### 4. RESULTADOS E DISCUSSÕES

Com o objetivo de determinar o subconjunto dos indicadores que mostra a relação mais forte com a probabilidade de insolvência dos bancos, vários modelos alternativos compostos por diferentes variáveis explicativas foram estimados com base nas informações de um ano atrás ou do ano de censura dos bancos. Como os indicadores foram agrupados em três categorias (real, macroeconômica, financeira) e, dentro de cada um dos grupos existe alta correlação entre os variáveis, diferentes estimativas foram realizadas utilizando subconjuntos distintos de cada divisão. Os resultados das estimações são apresentados em três subseções: A primeira parte apresentará os resultados dos grupos para a amostra com bancos privados falidos associados aos maiores bancos do país. Em seguida, será mostrado o resultado para os bancos privados insolventes em conjunto com amostra aleatória dos bancos privados. Por fim, serão apontados os resultados para o conjunto de bancos privados e públicos estaduais insolventes associados à amostra aleatória estratificada de bancos privados e públicos estaduais solventes. Em todos os casos, os modelos foram estimados com o uso do *software* RATS (*Regression Analysis of Time Series*), versão 7.0.

##### ***4.1. Previsão de Falência I: Modelos de previsão de insolvência para bancos privados comparados com as maiores instituições privadas***

Para analisar o poder de previsão de falência bancária no Brasil, foram utilizados três modelos de redes neurais. Cada um deles está associado a uma combinação específica de variáveis. Para o primeiro modelo, foram utilizadas, como neurônios de entrada, as variáveis: despesa financeira, patrimônio líquido, índice Bovespa, e a relação entre as operações de mercado aberto no total de passivos. Essas variáveis foram selecionadas por apresentar o menor grau de correlação entre si (ver apêndice 2). No segundo modelo, foram utilizadas as variáveis: consolidado, a relação entre as operações de mercado aberto no total de passivos, capital de giro, despesa financeira, variação real do PIB, inflação, taxas de juros e de câmbio. Os indicadores selecionados no segundo modelo acompanharam o indicado por Hardy & Pazarbasioglu (1998), no que diz respeito à seleção dos grupos. A escolha das variáveis seguiu o indicado por Rocha (1999). Por fim, o terceiro modelo incorporou as variáveis consolidado, ativo total, passivo total, despesa financeira, custo de intermediação, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB,

inflação, taxas de juros e de câmbio, além do índice Bovespa. O terceiro modelo foi selecionado com o objetivo de verificar se a existência de multicolinearidade influenciará negativamente o poder de previsão da rede neural.

Dado o tamanho reduzido da amostra, optou-se por dividir o conjunto da seguinte maneira: quarenta e nove observações foram reservadas para treinamento, e quatro observações para teste, sendo essas observações compostas por dois bancos solventes e dois bancos insolventes. A preferência pela parcela de dados destinada à fase de teste decorreu da observação de que tal procedimento permitia acelerar o aprendizado da rede neural.

Com relação à quantidade de camadas existentes na rede neural, essa está de acordo com o que é recomendado por alguns autores especialistas no assunto. De acordo com Corrar, Paulo & Dias Filho (2007), para aplicações mais usuais na área de negócios, uma rede neural deve possuir apenas uma camada intermediária. Porém, a quantidade de neurônios que compõem essa camada deve ser estipulada através da experimentação de algumas redes para esta série. Na fase de treinamento, as redes neurais dos primeiro e terceiro modelos obtiveram boa performance para 0,95 de grau de convergência.

Nas figuras abaixo, a linha escura mostra os dados observados no processo de insolvência bancária brasileira (falência) e a linha azulada apresenta os resultados da rede neural após o processo de treinamento (ANN). Vale ainda considerar que as primeiras 19 observações dizem respeito aos bancos insolventes enquanto as 30 seguintes são referentes às observações dos bancos solventes. Todas elas, juntas, foram utilizadas no processo de aprendizagem da rede neural. As quatro últimas observações (49-53), tanto da série falência quanto da série ANN, compõem o conjunto de informações utilizado no processo de teste da rede. As figuras 5 e 6 mostram os desempenhos das redes neurais para o primeiro e o terceiro modelos de variáveis de entrada e grau de convergência de 0,95.

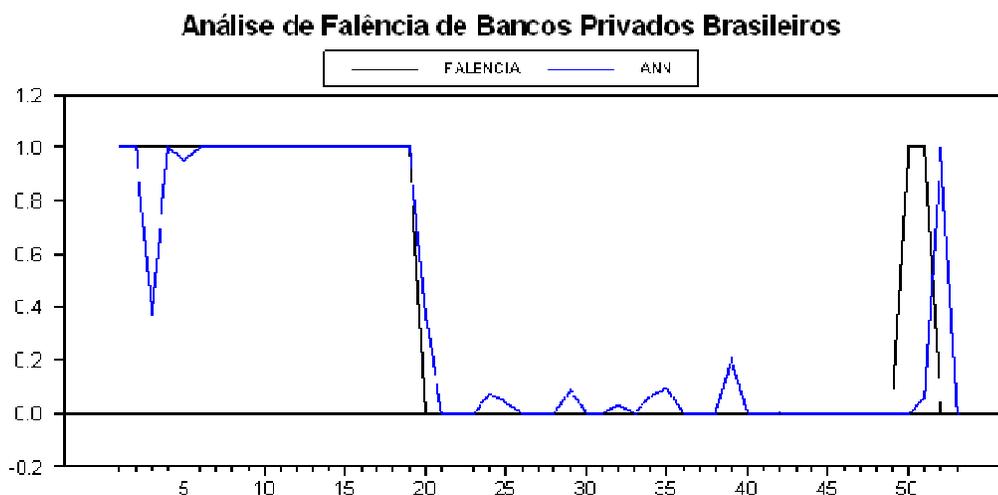


Figura 5 – Modelo de Previsão de Falência Bancária, primeiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.  
Fonte: Elaboração Própria

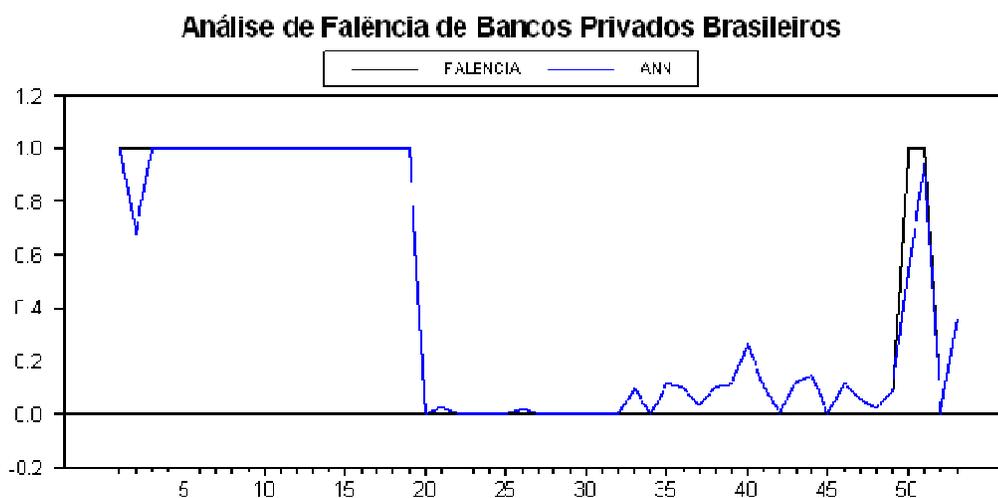


Figura 6 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.  
Fonte: Elaboração Própria

O segundo modelo estimado, por seu turno, embora indicado pela literatura como predictor de crise bancária, não conseguiu obter o grau de convergência requerido de 0,95 no processo de treinamento da rede.

Com o aumento do grau de convergência do modelo, saindo de 0,95 para 0,99 e, posteriormente para 0,999, e do número de neurônios intermediários, de 30 para 50, observou-se que apenas a terceira rede neural convergiu, após 225, 252 e 385 iterações, respectivamente. As figuras abaixo

apresentam os níveis de ajustamento das séries para cada nível de grau de convergência do terceiro modelo. Assim como nas figuras anteriores, a linha escura mostra os dados observados no processo de insolvência bancária brasileira (falência) e a linha azulada apresenta os resultados da rede neural após o processo de treinamento (ANN).

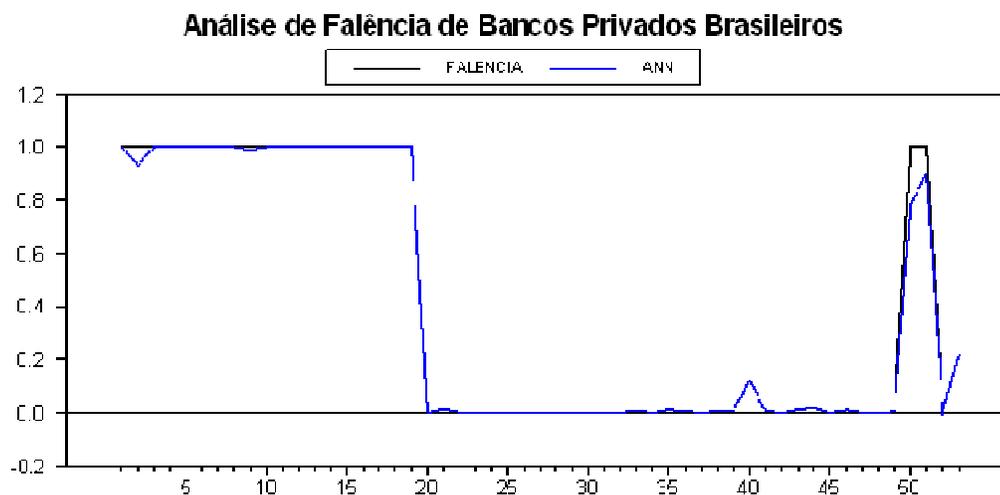


Figura 7 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,99. Neurônios intermediários: 50.  
Fonte: Elaboração Própria

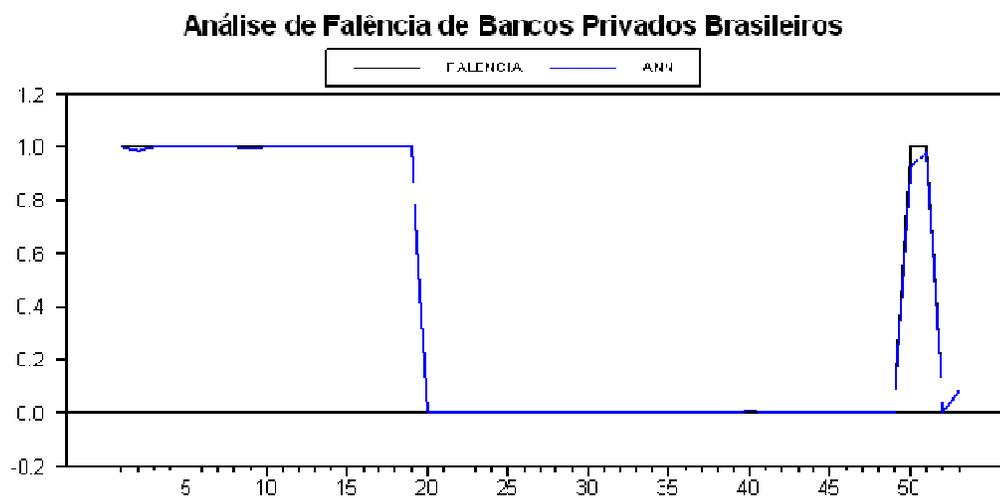


Figura 8 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,999. Neurônios intermediários: 50.  
Fonte: Elaboração Própria

Os quatro gráficos apresentados acima mostram que, apesar da existência de multicolinearidade entre as variáveis independentes que compõem os neurônios de entrada, o terceiro modelo apresenta forte ajustamento à série de falência bancária. Tal fato pode ser observado pela proximidade entre as linhas escura e azulada. A explicação para esse fato é dada pela existência de relações não lineares entre as variáveis. Vale ainda salientar que o grande número de iterações do modelo 1, quando comparado ao terceiro modelo expressam uma relação mais complexa entre as variáveis desse modelo, não existindo, nesse caso, número ótimo de iterações. A tabela abaixo apresenta as especificações de cada modelo de rede neural e o respectivo número de iterações necessárias ao processo de treinamento até que fosse alcançado o grau de convergência exigido.

Tabela 3 – Resultados dos Modelos de Redes Neurais para amostra com bancos insolventes e as maiores instituições

Primeiro Modelo		Segundo Modelo		Terceiro Modelo	
Variáveis utilizadas: despesa financeira, patrimônio líquido, a relação entre as operações de mercado aberto no total de passivos e o índice Bovespa.		Variáveis utilizadas: consolidado, relação entre as operações de mercado aberto no total de passivos, capital de giro, despesa financeira, variação real do PIB, inflação, taxas de juros e de câmbio.		Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, custo da intermediação financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.	
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50
Convergência após 222.790 iterações	O modelo não converge	O modelo não converge	O modelo não converge	Convergência após 225 iterações	Convergência após 252 iterações

Fonte: Elaboração Própria

A utilidade dos modelos de redes neurais artificiais como potencial sistema de *early warning* será testada utilizando-se o seguinte procedimento de classificação. A probabilidade estimada de um banco entrar em estado de insolvência, dados os indicadores daquele banco, é comparada com um valor de corte (nesse caso, assume-se 10%). Se essa probabilidade for maior que o valor de corte, o banco será classificado como provável insolvência (ou banco com problemas) e se essa probabilidade for menor que o corte, o banco será classificado como uma insolvência improvável.

Como nos demais estudos sobre previsão de falência bancária, um erro tipo I é definido como a classificação equivocada de um banco insolvente como um banco solvente e um erro tipo II é definido como a classificação errada de um banco solvente como um banco insolvente. Segundo a literatura, o erro tipo I é considerado mais grave para o sistema financeiro do que um erro do tipo II em um processo de *early warning*. Segundo Rocha (1999), prever que um banco vai sobreviver quando, na verdade, ele entra em processo de liquidação implica demora na resolução e, conseqüentemente, maiores custos. A autora afirma ainda que uma vez que os recursos para o exame dos bancos são escassos, os erros tipo II também devem ser minimizados a fim de evitar exames desnecessários. A autora conclui por afirmar que se um erro do tipo II se tornar público, um processo de corrida ao banco classificado erroneamente como insolvente pode gerar problemas para um banco que era, efetivamente, solvente. A tabela abaixo apresenta os resultados de classificação obtidos utilizando-se os modelos estimados nos conjuntos de dados de um ano atrás para avaliações dentro da amostra (essas avaliações consideram os dados das observações utilizadas para o treinamento da rede neural). Os dados entre parênteses dizem respeito ao número de bancos solvente e insolventes utilizados na estimação do modelo, respectivamente. Os valores observados e estimados de cada modelo estão no apêndice 3.

Tabela 4 – Resultados de classificação para dados dentro da amostra

Modelo 1		Modelo 3			
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	
<b>Resultados dentro da amostra</b>		<b>Resultados dentro da amostra</b>		<b>Resultados dentro da amostra</b>	
Erro tipo I: 0 (19,30)	Erro tipo II: 2 (19,30)	Erro tipo I: 0 (19,30)	Erro tipo II: 8 (19,30)	Erro tipo I: 0 (19,30)	Erro tipo II: 1 (19,30)

Fonte: Elaboração Própria

Através da análise da tabela, observa-se que o primeiro modelo e o terceiro modelo com grau de convergência de 0,99 e 50 neurônios intermediários fornecem resultados similares para a análise dentro da amostra, embora o terceiro modelo apresente menor quantidade de erros do tipo II. As tabelas seguintes apresentam os resultados dos modelos para a análise fora da amostra (essas avaliações utilizam as observações reservadas para o teste da rede neural), além de considerar o erro quadrado médio da previsão de cada modelo.

Tabela 5 – Resultados de classificação para dados fora da amostra

Modelo 1		Modelo 3			
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	
<b>Resultados fora da amostra</b>		<b>Resultados fora da amostra</b>		<b>Resultados fora da amostra</b>	
Erro tipo I: 1 (2,2)	Erro tipo II: 1 (2,2)	Erro tipo I: 0 (2,2)	Erro tipo II: 1 (2,2)	Erro tipo I: 0 (2,2)	Erro tipo II: 1 (2,2)

Fonte: Elaboração Própria

Tabela 6 – Erro quadrado médio dos modelos

Modelo 1		Modelo 3	
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	
<b>Erro Quadrado Médio</b>		<b>Erro Quadrado Médio</b>	
0,723399		0,083683	

Fonte: Elaboração Própria

Analisando as tabelas acima, pode-se observar que os modelos 3 apresentam melhor desempenho quando comparado com o modelo 1 em relação aos resultados fora da amostra (não possuem erros do tipo 1). Quando comparado o Erro Quadrado Médio (EQM) da previsão dos modelos, observa-se que o modelo 3 com grau de convergência de 0,99 e 50 neurônios intermediários possui menor EQM quando comparado aos demais modelos. Dessa forma, pode-se afirmar que, embora os neurônios de entrada desse modelo possuam alto grau de correlação linear entre si, ainda assim, esse modelo apresenta alta eficiência na previsão de insolvência bancária no Brasil. Vale ainda salientar que o modelo que apresenta menor erro quadrado médio da previsão possui maior complexidade em sua estrutura neural (maior nível de convergência e maior quantidade de neurônios intermediários).

#### ***4.2. Previsão de Falência II: Modelo de previsão de insolvência para bancos privados comparados com amostra aleatória de bancos privados***

De forma semelhante aos modelos de redes neurais estimados na análise de falência bancária utilizando os maiores bancos privados como base de comparação, essa seção objetiva analisar o desempenho dos mesmos modelos quando associados a um processo de amostragem aleatória dos bancos privados solventes. Assim, tem-se por finalidade analisar se o processo de escolha dos bancos solventes que irão compor a amostra influenciará nos resultados da rede neural.

Nesse sentido, os três modelos de redes neurais estimados anteriormente foram re-estimados com base na segunda amostra. A tabela abaixo apresenta os principais resultados da estimação. Em seguida, as figuras apresentam o nível de ajustamento das redes neurais estimadas para o primeiro modelo, terceiro modelo com graus de convergência de 0,95 0,99. Mais uma vez, a linha escura mostra os dados observados no processo de insolvência bancária brasileira (falência) e a linha azulada apresenta os resultados da rede neural após o processo de treinamento (ANN).

Tabela 7 – Resultados dos Modelos de Redes Neurais para amostra com bancos insolventes associado à amostra aleatória de bancos privados

Modelo 1		Modelo 2		Modelo 3	
Variáveis utilizadas: despesa financeira, patrimônio líquido, a relação entre as operações de mercado aberto no total de passivos e o índice Bovespa.		Variáveis utilizadas: consolidado, relação entre as operações de mercado aberto no total de passivos, capital de giro, despesa financeira, variação real do PIB, inflação, taxas de juros e de câmbio.		Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, custo de intermediação financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.	
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50
Convergência após 1.506.395 iterações	O modelo não converge	O modelo não converge	O modelo não converge	Convergência após 274 iterações	Convergência após 757 iterações

Fonte: Elaboração Própria

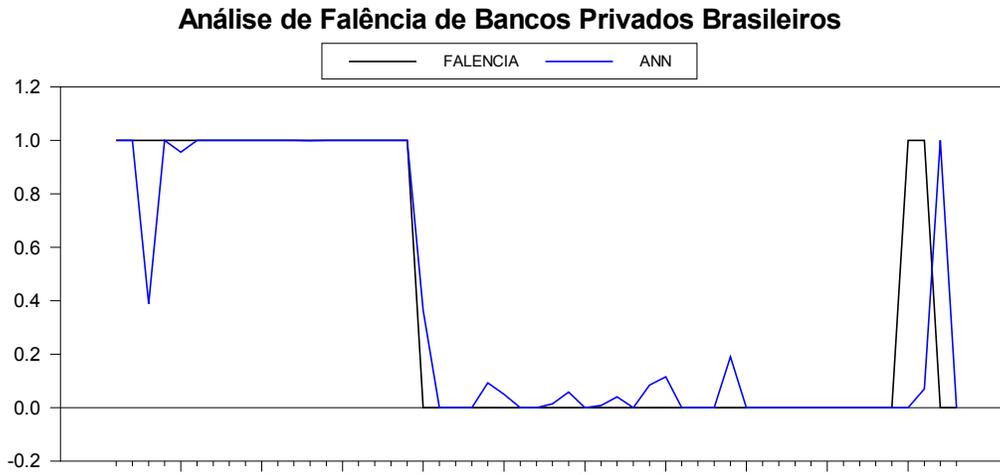


Figura 9 – Modelo de Previsão de Falência Bancária, primeiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.  
Fonte: Elaboração Própria

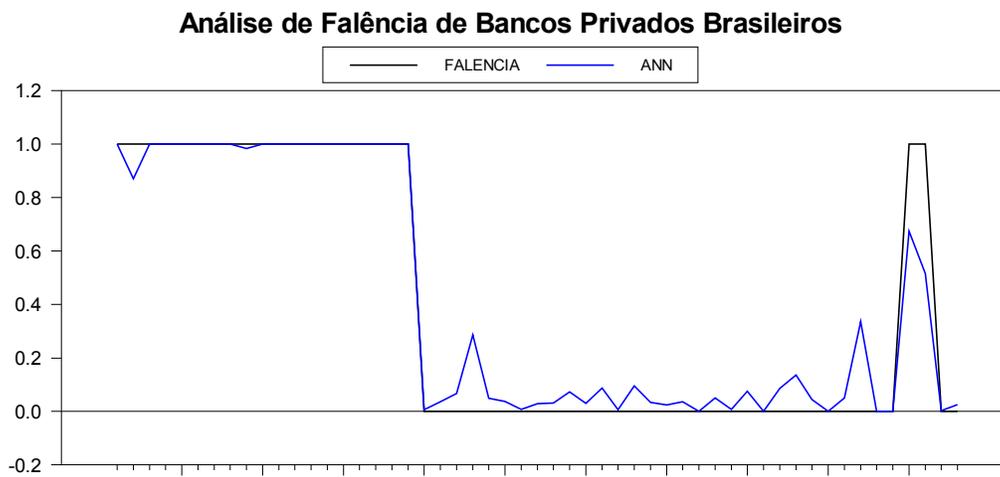


Figura 10 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.  
Fonte: Elaboração Própria

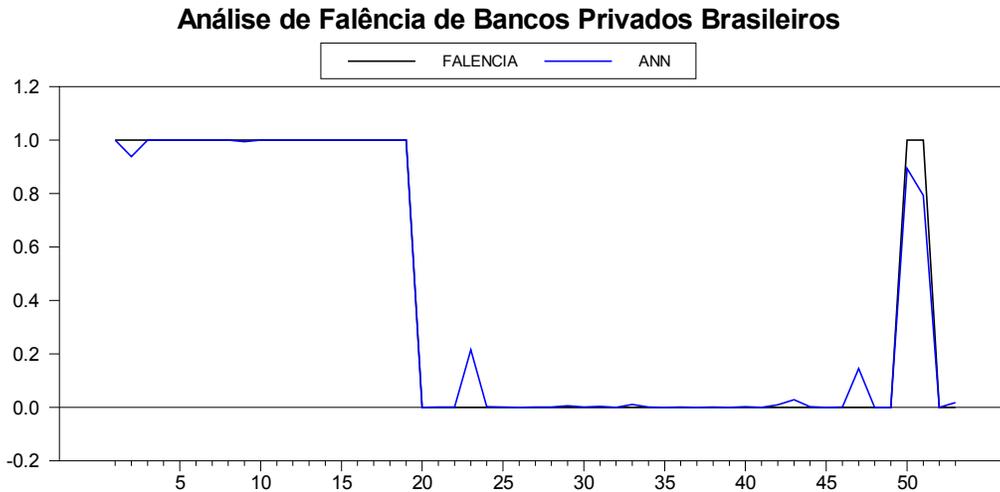


Figura 11 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,99. Neurônios intermediários: 50.

Fonte: Elaboração Própria

A partir das informações da tabela acima, observa-se que o ajustamento da rede neural necessitou de mais processos de iteração quando comparado com a amostra com os maiores bancos. No que diz respeito aos ajustamentos dos modelos estimados, assim como para a primeira amostra de dados, o segundo modelo também não convergiu em 0,95 e em 0,99 no processo de treinamento da rede. A tabela a seguir apresenta os resultados de classificação obtidos utilizando-se os modelos estimados nos conjuntos de dados de um ano atrás para avaliações dentro da amostra. Os valores observados e estimados de cada modelo estão no apêndice 4.

Tabela 8 – Resultados de classificação para dados dentro da amostra

Modelo 1		Modelo 3			
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	
<b>Resultados dentro da amostra</b>		<b>Resultados dentro da amostra</b>		<b>Resultados dentro da amostra</b>	
Erro tipo I: 0 (19,30)	Erro tipo II: 3 (19,30)	Erro tipo I: 0 (19,30)	Erro tipo II: 4 (19,30)	Erro tipo I: 0 (19,30)	Erro tipo II: 2 (19,30)

Fonte: Elaboração Própria

Através da análise da tabela acima, observa-se que, o primeiro modelo e o terceiro modelo com 50 neurônios intermediários apresentam uma maior quantidade de erros do tipo II em

detrimento ao observado na amostra composta pelos maiores bancos privados. A melhora do modelo só pôde ser constatada para o terceiro modelo com 30 neurônios intermediários e nível de convergência de 0,95. As tabelas seguintes apresentam os resultados dos modelos para a análise fora da amostra, além de considerar o erro quadrado médio da previsão de cada modelo.

Tabela 9 – Resultados de classificação para dados fora da amostra

Modelo 1		Modelo 3			
Especificações do Modelo: Nível de convergência da Série: 0,95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0,95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0,99 Quantidade de Neurônios Intermediários: 50	
<b>Resultados fora da amostra</b>		<b>Resultados fora da amostra</b>		<b>Resultados fora da amostra</b>	
Erro tipo I: 1 (2,2)	Erro tipo II: 1 (2,2)	Erro tipo I: 0 (2,2)	Erro tipo II: 0 (2,2)	Erro tipo I: 0 (2,2)	Erro tipo II: 0 (2,2)

Fonte: Elaboração Própria

Tabela 10 – Erro quadrado médio dos modelos

Modelo 1		Modelo 3	
Especificações do Modelo: Nível de convergência da Série: 0,95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0,95 Quantidade de Neurônios Intermediários: 30	
<b>Erro Quadrado Médio</b>		<b>Erro Quadrado Médio</b>	
0,71639		0,084972	

Fonte: Elaboração Própria

Nesse caso, a análise das tabelas acima mostra que, assim como na amostra anterior, os modelos 3 apresentam melhor desempenho quando comparado com o modelo 1 em relação aos resultados fora da amostra (não possuem erros do tipo I nem erro do tipo II). Vale salientar que o Erro Quadrado Médio da previsão observado para cada um desses modelos é bastante similar ao observado para a amostra com os principais bancos privados. Para o segundo processo de amostragem vale ainda enfatizar que o modelo que possui melhor poder de previsão de falência bancária possui, assim como para o primeiro processo de amostragem, maior complexidade em sua estrutura neural.

### ***4.3. Previsão de Falência III: Modelo de previsão de insolvência para bancos privados e públicos estaduais comparados com amostra aleatória de bancos***

Diferentemente ao realizado até então, a terceira amostra de dados é composta por um total de sessenta observações entre bancos públicos e privados. Desses, cinquenta e quatro foram utilizados no processo de treinamento e seis serão utilizados no processo de teste. Assim como para o processo de treinamento da rede para o caso de falência dos bancos privados, a preferência pela parcela de dados destinada à fase de teste decorreu da observação de que tal procedimento permitia acelerar o aprendizado da rede, diminuindo, dessa forma, o risco de surgimento do fenômeno de super ajustamento da rede.

Com o objetivo de prever o processo de insolvência bancária em bancos públicos estaduais e privados, essa seção objetiva analisar o desempenho dos mesmos modelos de redes quando associados a um processo de amostragem aleatória cujos dados são compostos por bancos de características institucionais diferenciadas. Assim, o propósito dessa parte é verificar se a falência bancária dos bancos estaduais está associada unicamente a fatores fiscais, como aponta a literatura, ou pode estar vinculado a variáveis reais, macroeconômicas e financeiras e, desta forma, ser previsto.

Nesse sentido, os três modelos de redes neurais estimados anteriormente foram novamente estimados com base na última amostra. A tabela abaixo apresenta os principais resultados da estimação.

Tabela 11 – Resultados dos Modelos de Redes Neurais para amostra com bancos insolventes associado à amostra aleatória de bancos privados e públicos estaduais

Modelo 1		Modelo 2		Modelo 3	
Variáveis utilizadas: despesa financeira, patrimônio líquido, a relação entre as operações de mercado aberto no total de passivos e o índice Bovespa.		Variáveis utilizadas: consolidado, relação entre as operações de mercado aberto no total de passivos, capital de giro, despesa financeira, variação real do PIB, inflação, taxas de juros e de câmbio.		Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, custo de intermediação financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.	
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50
O modelo não converge	O modelo não converge	O modelo não converge	O modelo não converge	Convergência após 1106 iterações	Convergência após 885 iterações

Fonte: Elaboração Própria

A partir das informações da tabela acima, observa-se que, diferentemente ao que ocorreu com as amostras anteriores, o primeiro modelo não apresentou convergência. Para o caso do terceiro modelo, observa-se que a rede neural sofreu um maior número de iterações tanto para o nível de convergência de 0,95 como para 0,99. As figuras abaixo apresentam os gráficos para os dois graus de convergência do terceiro modelo. Note-se que a linha escura mostra os dados observados no processo de insolvência bancária brasileira (falência) e a linha azulada apresenta os resultados da rede neural após o processo de treinamento (ANN).

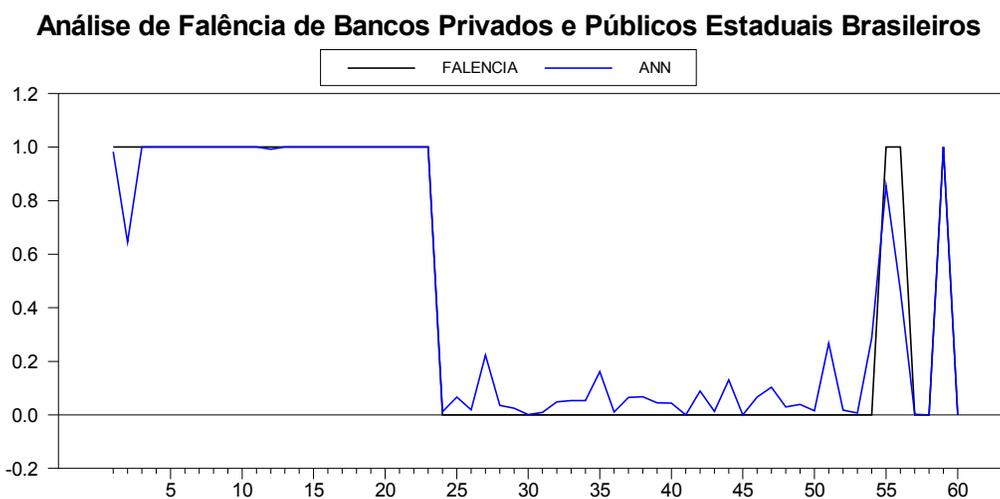


Figura 12 – Modelo de Previsão de Falência Bancária, primeiro modelo. Grau de convergência: 0,95. Neurônios intermediários: 30.

Fonte: Elaboração Própria

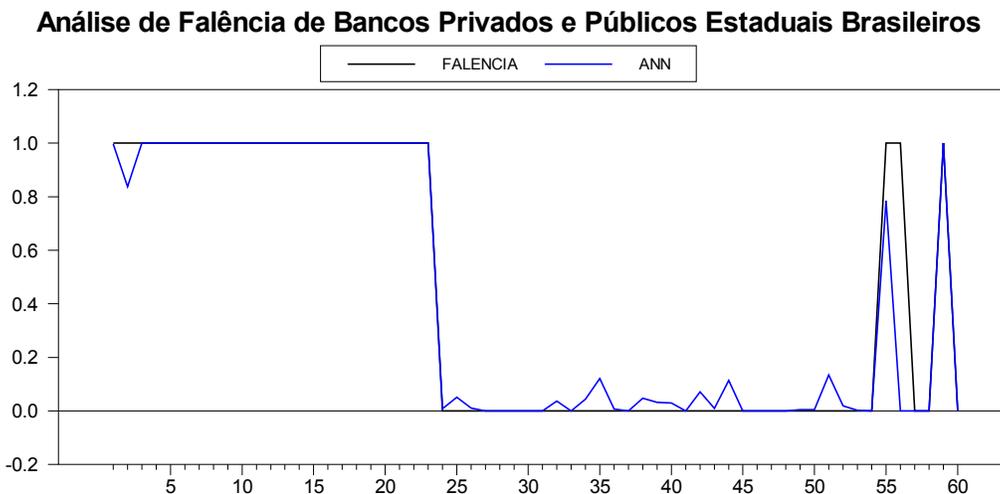


Figura 13 – Modelo de Previsão de Falência Bancária, terceiro modelo. Grau de convergência: 0,99. Neurônios intermediários: 50.

Fonte: Elaboração Própria

A tabela a seguir apresenta os resultados de classificação obtidos utilizando-se os modelos 3 estimados nos conjuntos de dados de um ano atrás para avaliações dentro da amostra. Os valores observados e estimados de cada modelo estão no apêndice 5.

Tabela 12 – Resultados de classificação para dados dentro da amostra

Modelo 3			
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	
<b>Resultados dentro da amostra</b>		<b>Resultados dentro da amostra</b>	
Erro tipo I: 0 (23,31)	Erro tipo II: 1 (23,31)	Erro tipo I: 0 (23,31)	Erro tipo II: 1 (23,31)

Fonte: Elaboração Própria

Através da análise da tabela acima, pode-se observar que os dois modelos possuem o mesmo desempenho quando se observa a classificação dos bancos dentro da amostra. Assim, tanto o modelo com apenas 30 neurônios intermediários como o modelo com 50 neurônios intermediários, e uma estrutura neural mais complexa, geram o mesmo resultado. As tabelas seguintes apresentam os resultados dos modelos para a análise fora da amostra, e consideram, ainda o Erro Quadrado Médio da previsão de cada modelo.

Tabela 13 – Resultados de classificação para dados fora da amostra

Modelo 3			
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30		Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	
<b>Resultados fora da amostra</b>		<b>Resultados fora da amostra</b>	
Erro tipo I: 0 (3,3)	Erro tipo II: 0 (3,3)	Erro tipo I: 0 (3,3)	Erro tipo II: 1 (3,3)

Fonte: Elaboração Própria

Tabela 14 – Erro quadrado médio dos modelos

Modelo 3	
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50
<b>Erro Quadrado Médio</b>	<b>Erro Quadrado Médio</b>
0,000656	0,175077

Fonte: Elaboração Própria

Para o caso da amostra composta por bancos públicos estaduais e privados, observa-se, através das informações das tabelas acima que o modelo de rede neural que desconsidera as relações lineares entre as variáveis e que possui estrutura mais simplificada e menor grau de convergência conseguiu prever todas as falências fora da amostra. Vale ainda mencionar que o erro quadrado médio de previsão desse modelo foi pouco superior a 0,5%, mostrando possuir forte poder preditivo.

#### **4.4. Considerações finais**

A partir dos resultados dos desempenhos dos modelos para os três processos de amostragem, é possível verificar que, dentre as redes neurais utilizadas para estimar risco de falência bancária, o modelo que considera uma maior quantidade de variáveis se destaca por possuir maior poder preditivo tanto dentro como fora da amostra quando comparado com os demais, além de possuir menor erro quadrado médio da previsão. A tabela a seguir mostra as atuações de todos os modelos para os três tipos de amostras especificadas.

Tabela 15 – Resultados dos Modelos de Previsão

<b>Modelos de previsão de insolvência para bancos privados comparados com as maiores instituições privadas</b>					
Primeiro Modelo		Segundo Modelo		Terceiro Modelo	
Variáveis utilizadas: despesa financeira, patrimônio líquido, a relação entre as operações de mercado aberto no total de passivos e o índice Bovespa.		Variáveis utilizadas: consolidado, relação entre as operações de mercado aberto no total de passivos, capital de giro, despesa financeira, variação real do PIB, inflação, taxas de juros e de câmbio.		Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, custo da intermediação financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.	
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50
Convergência após 222.790 iterações	O modelo não converge	O modelo não converge	O modelo não converge	Convergência após 225 iterações	Convergência após 252 iterações
<b>Modelo de previsão de insolvência para bancos privados comparados com amostra aleatória de bancos privados</b>					
Modelo 1		Modelo 2		Modelo 3	
Variáveis utilizadas: despesa financeira, patrimônio líquido, a relação entre as operações de mercado aberto no total de passivos e o índice Bovespa.		Variáveis utilizadas: consolidado, relação entre as operações de mercado aberto no total de passivos, capital de giro, despesa financeira, variação real do PIB, inflação, taxas de juros e de câmbio.		Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, custo de intermediação financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.	
Especificações do Modelo: Nível de convergência da Série: 0.95	Especificações do Modelo: Nível de convergência da Série: 0.99	Especificações do Modelo: Nível de convergência da Série: 0.95	Especificações do Modelo: Nível de convergência da Série: 0.99	Especificações do Modelo: Nível de convergência da Série: 0.95	Especificações do Modelo: Nível de convergência da Série: 0.99

Quantidade de Neurônios Intermediários: 30	Quantidade de Neurônios Intermediários: 50	Quantidade de Neurônios Intermediários: 30	Quantidade de Neurônios Intermediários: 50	Quantidade de Neurônios Intermediários: 30	Quantidade de Neurônios Intermediários: 50
Convergência após 1.506.395 iterações	O modelo não converge	O modelo não converge	O modelo não converge	Convergência após 274 iterações	Convergência após 757 iterações
<b>Modelo de previsão de insolvência para bancos privados e públicos estaduais comparados com amostra aleatória de bancos</b>					
Modelo 1		Modelo 2		Modelo 3	
Variáveis utilizadas: despesa financeira, patrimônio líquido, a relação entre as operações de mercado aberto no total de passivos e o índice Bovespa.		Variáveis utilizadas: consolidado, relação entre as operações de mercado aberto no total de passivos, capital de giro, despesa financeira, variação real do PIB, inflação, taxas de juros e de câmbio.		Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, custo de intermediação financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.	
Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Especificações do Modelo: Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30	Especificações do Modelo: Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50
O modelo não converge	O modelo não converge	O modelo não converge	O modelo não converge	Convergência após 1106 iterações	Convergência após 885 iterações

Fonte: Elaboração Própria

Os resultados acima mostram que, para o caso das redes neurais, dada a sua estrutura semi-paramétrica, uma maior quantidade de informação nos neurônios de entrada proporciona, para esse caso, melhor ajustamento da rede à série. Essa constatação vale tanto para o caso dos bancos privados isoladamente como em conjunto com os bancos públicos estaduais. Vale notar que, com a maior heterogeneidade entre as observações que compõem a amostra, o modelo 1, com menor quantidade de variáveis, necessita de um número de iterações crescente até encontrar o padrão da rede neural quando se compara o primeiro e o segundo processos de amostragem, passando a não convergir no terceiro processo de amostragem que possui maior diversidade entre as observações.

Assim, pode-se concluir que uma vez selecionadas as informações que irão compor os neurônios de entrada, independentemente do processo de amostragem, é possível obter um modelo de previsão eficiente com erros dos tipos I e II mínimos tanto dentro como fora da amostra e baixo erro quadrado médio da previsão. A tabela abaixo resume os resultados dos terceiros modelos para os três processos de amostragem.

Tabela 16 – Resultados dos Modelos de Previsão

Amostras	Falência bancária associada aos maiores bancos privados	Falência bancária associada a bancos privados selecionados	Falência bancária associada a bancos públicos estaduais e privados selecionados
Especificação do Modelo	Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Nível de convergência da Série: 0.99 Quantidade de Neurônios Intermediários: 50	Nível de convergência da Série: 0.95 Quantidade de Neurônios Intermediários: 30
<b>Resultados dentro da amostra</b>			
Erro tipo I	0 (19,30)	0 (19,30)	0 (23,31)
Erro tipo II	1 (19,30)	2 (19,30)	1 (23,31)
<b>Resultados fora da amostra</b>			
Erro tipo I	0 (2,2)	0 (2,2)	0 (3,3)
Erro tipo II	1 (2,2)	0 (2,2)	0 (3,3)
<b>Erro Quadrado Médio da Previsão</b>			
	0,026514	0,013606	0,000656

Fonte: Elaboração Própria

## 5. CONCLUSÕES

Os efeitos da crise financeira, que teve seu ápice no ano de 2008, foram sentidos por todos os integrantes do sistema financeiro internacional. Uma das razões para esse impacto foram os repasses feitos pelos bancos norte-americanos de uma parte significativa dos títulos de dívida dos clientes *sub-prime* a outros integrantes do sistema financeiro. Esses ativos teriam sido transferidos a diversos intermediários internacionais que classificavam os papéis como arriscados, mas de altos rendimentos para o credor (Cherubine, 2009). Como resultado da crise financeira, muitos bancos privados em todo o mundo sofreram processo de liquidação ou foram passivos de intervenção do poder público a fim de manter sua solvência financeira.

Observando tal problemática, o presente trabalho buscou analisar a existência de modelos de previsão de falência bancária no Brasil. Para tanto, considerou-se, inicialmente, estudos teóricos e, em seguida, empíricos a fim de observar os determinantes de crises sistêmicas no sistema bancário no Brasil e no mundo. Como metodologia, foi utilizado o método computacional das redes neurais artificiais *Multilayer Perceptron* com algoritmos de retropropagação.

A revisão de literatura empírica indicou que, para o processo de estimação de falência bancária, o problema da relação linear entre as variáveis não deve ser desconsiderado uma vez que a presença de multicolinearidade pode gerar erros de previsão no modelo. Além disso, a literatura enfatiza ainda que o processo de seleção da amostra que irá compor os dados pode afetar a previsão.

Considerando tais restrições, o trabalho em tela treinou três redes neurais compostas por variáveis explicativas distintas (neurônios de entrada), além de analisar esses mesmos modelos para três processos de amostragem diferentes. O estudo verificou que, independentemente da amostra utilizada, o modelo que apresentou o melhor poder preditivo de falência bancária para o Brasil entre os anos de 1996 e 1999 era composto por variáveis com alto grau de correlação linear. Tal fato pode ser explicado seu poder de aproximação e ajuste a qualquer função não-linear a qualquer grau de precisão.

O resultado da boa performance no ajustamento da rede neural para o processo de avaliação de falência bancária no Brasil, chegando a um erro quadrado médio de previsão de 0,06%,

mostra a grande eficiência dessa ferramenta como instrumento de *early warning* para órgãos normativos do sistema financeiro. Para os casos dos três tipos de amostra, pôde-se observar que os modelos computacionais apresentaram baixo erro de previsão tanto para dados dentro como para observações fora da amostra. Vale ainda ressaltar que o modelo previu além de insolvências de bancos privados, processos de falência bancária de bancos públicos estaduais, fato nomeado pela literatura como de difícil previsão uma vez que, segundos estudos na área, esse processo estaria fundamentalmente integrado a questões de ordem fiscal.

Os resultados encontrados nesse trabalho ratificam aqueles encontrados na literatura internacional, em que as redes neurais apresentam melhor desempenho quando comparadas a métodos de previsão lineares, como os modelos logit ou probit. Uma crítica que pode ser feita à metodologia diz respeito a sua estrutura em “caixa preta”, que não permite a verificação dos determinantes individuais de crise bancária.

Contudo, é importante mencionar que os modelos de redes neurais artificiais possibilitam prever a probabilidade de falência bancária com erros mínimos. O método se destaca ainda pela sua flexibilidade: os modelos de RNA possuem a habilidade de superar as limitações dos dados, como observado no presente trabalho, além de reconhecer e compreender padrões e mudanças nas variáveis.

Esse estudo apresenta limitações, pois é analisado apenas o setor bancário brasileiro para os anos de 1996 a 1999 (período pós-plano real) e apenas um tipo de rede neural artificial. Dessa forma, necessita-se saber se outros modelos de redes neurais associados a outros processos de insolvência bancária obteriam mesmo poder de previsão como o encontrado nesse estudo. Para isso, é preciso uma investigação mais aprofundada sobre os métodos computacionais existentes além da realização de maiores testes com diferentes tipos de modelos de análise de falência bancária. É necessário também analisar outros processos de insolvência bancária na América Latina utilizando o mesmo método utilizado no presente trabalho a fim de estabelecer melhores parâmetros de comparação.

**REFERÊNCIAS**

ALEXANDRE, M., CANUTO, O., SILVEIRA J., **Microfundamentos de Falência de Bancos Atacadistas: A Experiência Brasileira nos anos 90**. Estudos Econômicos, v.33, n.2, 2003

ACHARYA, V. **A Theory of Systemic Risk and Design of Prudential Bank Regulation**, Working Paper, London Business School, 2001.

ACEMOGLU, D., P. AGHION, F.ZILIBOTTI. **Distance to frontier, selection, and economic growth**. Working Paper No. 9066. National Bureau of Economic Growth.

ALEXANDER, C. **Model of Markets**, BM&F, 2007.

AKERLOF, G. A.; ROMER, P.M. Looting: the economic underworld of bankruptcy for profit. **Brookings Papers on Economic Activity**, n. 2, p.1-73, 1993.

ARNAUD, A. **Abordagem Híbrida para Otimização de Redes Neurais Artificiais para Previsão de Séries Temporais**. UFPE, Dissertação de Mestrado, 2007.

BAER, W., NAZMI, N., **Privatization and restructuring of banks in Brazil**. The Quarterly Review of Economics and Finance, North-Holland, 2000.

BAESENS, B., SETIONO, R., MUES, C., VANTHIENEN, J., Neural Network Rule Extraction and Decision Tables for Credit-Risk Evaluation. **Management Science**, v. 49, n°3, 2003

BAGEHOT, W. **Lombard Street**, 1962 ed. Irwin, Homewood, IL, 1873.

BARNDORFF-NIELSEN, O. E.; JENSEN, J. L.; KENDALL, W.S. **Networks and Chaos – Statistical and Probabilistic Aspects**. Chapman & Hall, Great Britain, 1993.

BARNHILL, T. **Modeling and Managing Sovereign Risk**, Working Paper, The George Washington University Global and Entrepreneurial Finance Research Institute, 2006.

BARNHILL, T. e G. KOPITS. **Assessing Fiscal Sustainability Under Uncertainty**, *Journal of Risk* 6 (4), 2004.

BARNHILL, T. e M. R. SOUTO. **Stochastic Volatilities and Correlations, Extreme Values and Modeling the Financial and Economic Environment under which Brazilian Banks Operate**, IMF Working Paper, 2007

BARNHILL, T. e W. MAXWELL. **Modeling Correlated Interest Rate, Exchange Rate, and Credit Risk in Fixed Income Portfolios**, *Journal of Banking and Finance* 26, 347-374, 2002.

BARNHILL, T., M. R. SOUTO, e B. TABAK. **An Analysis of Off-Site Supervision of Banks' Profitability**, *Risk and Capital Adequacy: a Portfolio Simulation Approach Applied to Brazilian Banks*, *Financial Stability Report* 5 (1), 209-236.

BARNHILL, T., M. R. SOUTO, e B. TABAK. **Modeling Business Loan Credit Risk in Brazil**, *Financial Stability Report* 2 (1), 159-174, 2003.

BARNHILL, T., P. PAPAPANAGIOTOU, e L. SCHUMACHER, **Measuring Integrated Market and Credit Risk in Bank Portfolios: an Application to a Set of Hypothetical Banks Operating in South Africa**, *Financial Markets, Institutions, and Instruments*, forthcoming.

BARNHILL, T., P. PAPAPANAGIOTOU, and M. R. SOUTO. **Preemptive Strategies for the Assessment and Management of Financial System Risk Levels: An Application to Japan with Implications to Emerging Economies**. *Review of Pacific-Basin Financial Markets and Policies* 7 (1), 1-42, 2004.

BEANDRY, P.; M. POITEVIN. **Competitive Screening in Financial Markets when borrowers can recontract**. *Review of Economic Studies*, 62, 401-423, 1995.

BIRCHLER, U.; M. BÜTLER. **Information Economics**. Routledge Press, 2007

BLACKBURN, K.; Y. HUNG. **A theory of growth, financial development and trade.** *Econômica* 65, 104-124, 1998.

CANUTO, O., LIMA, G., **Price stability and banking sector distress in Brazil after 1994.** Rio de Janeiro: UERJ, Instituto de Economia, Texto Para Discussão 388, 1996.

CAVALCANTI, T.; A. VILLAMIL. **On the welfare and distributional implications of intermediation costs** Anais do X Encontro Regional de Economia do Nordeste, Fortaleza, 2005.

CAVALCANTI, V., A. VIEIRA, A. SILVA NETO, D. MOTA, R. LIMA, **Modelos de previsão para dados de alta frequência: Um estudo comparativo utilizando os modelos de redes neurais e ARIMA para o caso do preço futuro do açúcar.** Anais do XLVII Congresso da Sober, 2009.

CHERUBINE, G., L. DOWBOR. **O mapa da crise financeira.** *Le Monde Diplomatique*, jan/2009.

COLE, R. A.; GUNTHER, J. W. Separating the likelihood and timing of bank failure. **Journal of Banking and Finance**, v. 19, p. 1073-89, Sept. 1995.

CORRAR, J., E. PAULO, E. DIAS FILHO, **Análise Multivariada: para os cursos de administração, ciências contábeis e economia**, 2007.

DEMIRGÜÇ-KUNT, A., L. LEAVEN; R. LEVINE. **Regulations, market structure, institutions, and the cost of financial intermediation.** *Journal of Money, Credit and Banking* 36(3), 593–622, 2004

DEMIRGÜÇ-KUNT, A., DETRAGIACHE, E., **The determinants of banking crises: evidence from developing and developed countries.** IMF Working Paper, 1997.

DEWATRIPONT, M. M.; TIROLE, J. **The prudential regulation of banks.** Cambridge: MIT Press, 1994.

DIAMOND, D. V, P. DYBVIK. **Bank Runs, Deposit Insurance, and Liquidity.** Journal of Political Economy 91 (3), 401-419, 1983.

DONALDSON, R. G. Costly liquidation, interbank trade, bank runs and panics. **Journal of Financial Intermediation**, v. 2, p. 59-82, 1992

DORFFNER, G., 1996, **Neural Networks for Time Series Processing**, University of Vienna and Austrian Research Institute for Artificial Intelligence, TPD.

DREES, B. W.; PAZARBASIOGLU, C. **The Nordic banking crises: pitfalls in financial liberalization?** Washington: International Monetary Fund, 1995. (IMF Working Paper, n. 61).

DURLAUF, S.; P. AGHION. **Handbook of Economic Growth.** Volume 1A. Elsevier North-Holland Press, 2005.

ELSINGER, H., A. LEHAR, M. SUMMER. **Risk Assessment for Banking Systems, Working Paper**, University of Vienna, 2003.

ENDERS, W. **Applied Econometric Time Series.** Wiley, 1995.

FRASCAROLI, B.; F. RAMOS; N. PAES. **A indústria brasileira e o racionamento de crédito: Uma análise do comportamento dos bancos sob informações assimétricas.** Anais do XIII Encontro Regional de Economia do Nordeste, Fortaleza, 2008.

FUCIDJI, J.; D. MENDONÇA. **Determinantes do Crédito Bancário: uma análise com dados em painel para as maiores instituições.** Anais do XII Encontro Regional de Economia do Nordeste, Fortaleza, 2007.

GALBIS, V. **High real interest rates under financial liberalization: is there a problem?** Washington: International Monetary Fund, 1993.(IMF Working Paper, n. 7).

GALETOVIC, A. **Specialization, intermediation and growth.** Journal of Monetary Economics 38, 549-559, 1996

GATELY, E. **Neural Networks for Financial Forecasting**. John Wiley & Sons, Inc, United States, 1996.

GIAMBIAGI, F., **Economia Brasileira Contemporânea**. Editora Campus, 2005.

GOLDSMITH, R. **Financial Structure and Development**. Yale University Press, New Haven, CT.

GORTON, G., **Banking Panic and Business Cycles**. Oxford Economic Papers, 1988.

GUJARATI, D. (2000) – **Econometria Básica** 3ª ed., MAKROW Books, São Paulo.

GURLEY, J., SHAW, E. **Financial aspects of economic development**. American Economic Review, 45, 515-538, 1955.

HALL, M., MULJAWAN, D., SUPRAYOGI & MOORDENA, L., **Using The Artificial Neural Network (ANN) to Assess Bank Credit Risk: A Case Study of Indonesia**, Loughborough University, Working Paper, 2008.

HARDY, D. C.; PAZARBASIOGLU, C. **Leading indicators of banking crises: was Asia different?** Washington: International Monetary Fund, 1998. (IMF Working Paper, n. 91)

HAUSMANN, R., **The Roots of Banking Crises: The Macroeconomic Context**. Inter-American Development Bank, Working Paper 318, 1996

JANDA, K. **Lender and Borrower as Principal and Agent**. IES Working Paper 24/2006, IES FSV. Charles University

JANOT, M., **Modelos de Previsão de Insolvência Bancária no Brasil**. Trabalhos para Discussão nº 13, Brasília: Banco Central do Brasil, 2001

JOHNSTON, J; J. DINARDO. **Métodos Econométricos**, 4.ª ed., Editora McGraw-Hill de Portugal, Amadora, 2001

KING, R.; R. LEVINE. **Finance and growth: Schumpeter might be right.** Journal of Monetary Economics 108, 717-738, 1993.

KRUGMAN, P. **Introdução à Economia**, Editora Campus, 2008.

LAFFONT, J.; D. MARTIMORT. **The Theory of Incentives – The Principal-Agent Model**, Princeton University Press, 2002.

LEVINE, R., Finance and Growth: Theory and Evidence. In.: AGHION, P., DURLAUF, S. (Ed.). **Handbook of Economic Growth**, Vol. 1A. Elsevier, 2005.

LI, Z.; ZHAO, X.. **Macroeconomic Effect in Corporate Default. Department of Economics**, York University, 2006.

LUCAS, R. **On the mechanisms of economic development.** Journal of Monetary Economics. 22, 3-42, 1988.

MANDIC, D. P.; CHAMBERS, J. A. **Recurrent Neural Networks for Prediction.** John Wiley & Sons, LTD, (Baffins Lane, chichester, West Sussex) England, 2001.

MAS-COLELL, A.; M. WHINSTON, J. GREEN. **Microeconomic Theory.** Oxford Press, 1995.

MCKINNON R. **Money and Capital in Economic Development.** Brooking Institution, Washington DC, 1973

MEIER, G., SEERS, D., **Pioneers in Development.** Oxford University Press, New York, 1984.

MISHKIN, F. S. **Understanding financial crises: a developing country perspective.** Cambridge, Massachusetts: National Bureau of Economic Research, 1996. (NBER Working Paper, n. 5600).

MILLER, M. **Financial markets and economic growth**. Journal of Applied Corporate Finance 11, 8-14, 1998.

MCNELIS, P., **Neural Networks in Finance: Gaining Predictive Edge in the Market**, Elsevier Academic Press, 2005.

MORALES, F. **Financial intermediation in a model of growth through creative destruction**. Macroeconomics Dynamics 7, 363-393, 2003.

MOREIRA, T., Fatores determinantes de crises cambiais e bancárias. **Revista Econômica do Nordeste**, Fortaleza, v. 33, n. 2, 2002

NIELSEN, O., J. L. JENSEN, W. S. KENDALL, **Networks and Chaos: Statistical and Probabilistic Aspects**, Chapman & Hall, 1993.

PARK, S. Bank failure contagion in historical perspective. **Journal of Monetary Economics** n. 28, p. 271-286, 1991.

PORTUGAL, M., L. FERNANDES. **Redes Neurais Artificiais e Previsão de Séries Econômicas: Uma Introdução**. 2000

PINDYCK e RUBINFELD. **Econometria: Modelos e Previsões**, 4ª edição, Campus, Rio de Janeiro, 2004.

REINHART, C. M., KAMINSKY, G.; The twin crises: the causes of banking and balance-of-payments problems. **The American Economic Review**, v. 89, n. 3, p. 473-500, July 1999.

ROCHA, F., Previsão de Falência Bancária: Um modelo de risco proporcional. **Pesquisa e Planejamento Econômico**, Rio de Janeiro, v. 29. nº1, Abril, 1999.

ROCHET, J-C; J TIROLE. **Inter-bank Lending and Systemic Risk**, Journal of Money, Credit, and Banking 28 (4), 733-762, 1986.

RUMELHART, D. E., MCCLELLAND, J., **Parallel Distributed Processing**, vol. 1, MIT Press, 1986.

SAMUELSON, P., NORDHAUS, W. **Economics**. Berkeley Publication, 1991.

SCHUMPETER, J.; **Die Theorie der Wirtschaftlichen Entwicklung**, 1911

SILVA, E., PORTO JÚNIOR, S., **Sistema financeiro e crescimento econômico: uma aplicação de regressão quantílica**. Anais do IX Encontro Regional de Economia do Nordeste, Fortaleza, 2004.

SMITH, M., **Neural Networks for Statistical Modeling**, 1996

STIGLITZ, J.; B. GREENWALD. **Rumo a um novo paradigma em economia monetária**. Tradução por Laura Knapp e Cecília Camargo Bartalotti. Tradução de: *Towards a new paradigm in monetary economics*. Ed. Francis, São Paulo – SP, 2004.

The theory of incentives

STIGLITZ, J. E. Some aspects of the pure theory of corporate finance: bankruptcies and takeovers. **Bell Journal of Economics**, v. 3, p. 458-82, 1972.

VELASCO, A. Financial crises and balance of payments crises: a simple model of the southern cone experience. **Journal of Development Economics**, v. 27, p. 263-83, 1987.

VIROLAINEN, K. (2004). **Macro Stress Testing with a Macroeconomic Credit Risk Model for Finland**. Bank of Finland Discussion Paper, 2004.

WHALEN, G. A proportional hazards model of bank failure: an examination of its usefulness as an early warning tool. Economic Review, **Federal Reserve Bank of Cleveland**, First Quarter, p. 21-31, 1991.

WILSON, T., **Portfolio Credit Risk**. Social Science Research Network, 1997.

**APÊNDICE**

## Apendice 1: Lista de bancos que sofreram liquidação entre 1990 e 2000

<b>LIQUIDAÇÕES</b>	
<b>NOME DA INSTITUIÇÃO</b>	<b>DATA DE PUBLICAÇÃO</b>
BANCO SIBISA S.A.	18/09/90
BANCO DO ESTADO DO RIO GRANDE DO NORTE S.A	24/09/90
BANCO HÉRCULES S.A.	20/07/94
BANCO ATLÂNTIS S.A.	28/07/94
BRASBANCO S.A. BANCO COMERCIAL	16/09/94
BANCO GARAVELO S.A.	14/11/94
BANCO BANCORP S.A.	18/11/94
BANCO SELLER S.A.	21/11/94
BANCO ADOLPHO OLIVEIRA S.A.	22/11/94
BFC BANCO S.A.	23/01/95
BANCO GNPP S.A	04/02/95
BANCO MERCANTIL S.A	13/02/95
BANCO ROSA S.A.	01/03/95
BANCO SÃO JORGE S.A.	01/03/95
BANCO NACIONAL DE CRÉDITO COOPERATIVO	17/03/95
BANCO COMERCIAL BANCESA S.A	12/04/95
BANCO OPEN S. A.	25/08/95
BIG SA-BANCO IRMÃOS GUIMARÃES	25/08/95
BANCO AGRIMISA S.A.	18/11/95
BANCO INVESTCORP S.A.	06/12/95
BANCO ESTADO RIO DE JANEIRO S.A.	21/03/96
BANCO DRACMA S.A	22/03/96
BFI-BANCO FINANCIAMENTO INTERNACIONAL S.A.	18/04/96
BANCO COLUMBIA S.A.	16/05/96
BANCO INTERUNION S.A.	24/05/96
BANCO UNIVERSAL S.A.	20/06/96
BANCO ECONÔMICO S.A.	09/08/96
BANCO COMERCIAL DE SÃO PAULO S.A.	09/08/96
BANCO NACIONAL S.A.	13/11/96
BANCO BANORTE S.A.	30/12/96
BANCO DO PROGRESSO S.A.	21/02/97
BANCO VETOR S.A.	21/02/97
BANCO BAMERINDUS S.A.	27/03/97
BANFORT-BANCO FORTALEZA S.A.	15/05/97
BANCO EMPRESARIAL S.A.	15/05/97
BANCO VEGA S.A.	15/05/97
BANCO ESTADO DE ALAGOAS S.A.	22/07/97
BANCO INTERFINANCE S.A.	12/08/97
BANCO SHECK S.A.	13/08/97

BANCO DO ESTADO DO AMAPÁ S.A.	03/09/97
BANCO APLICAP S.A.	28/01/98
BANCO BRASILEIRO COMERCIAL S.A.	15/05/98
BANCO BRASILEIRO-IRAQUIANO S.A.	15/05/98
BANCO ESTADO DO MATO GROSSO S.A.	30/10/98
BANCO BMD S.A.	30/10/98
MILBANCO S.A.	19/11/98
BANCO CREFISUL S.A.	23/03/99
BANCO PONTUAL S.A.	29/10/99
BANCO MARTINELLI S.A.	29/10/99
BANCO LAVRA S.A.	14/04/00
BANCO HEXABANCO S.A.	14/07/00

Fonte: Banco Central do Brasil



Apêndice 3 – Valores observados e valores estimados das redes neurais – Amostra com os maiores bancos

**Modelo 1:**

Especificações do Modelo:

Variáveis utilizadas: despesa financeira, patrimônio líquido, a relação entre as operações de mercado aberto no total de passivos e o índice Bovespa.

**Nível de convergência da Série: 0.95**

**Quantidade de Neurônios Intermediários: 30**

Resultado do Modelo de Redes Neurais

ENTRADA	FALENCIA	ANN
1	1	1,000000000000
2	1	0,999753565385
3	1	0,391296264167
4	1	1,000000000000
5	1	0,951187884713
6	1	1,000000000000
7	1	1,000000000000
8	1	1,000000000000
9	1	0,999939252968
10	1	1,000000000000
11	1	1,000000000000
12	1	1,000000000000
13	1	0,999604907859
14	1	1,000000000000
15	1	1,000000000000
16	1	1,000000000000
17	1	1,000000000000
18	1	1,000000000000
19	1	1,000000000000
<b>20</b>	<b>0</b>	<b>0,369450620195</b>
21	0	0,000000000000
22	0	0,000000000000
23	0	0,000000000000
24	0	0,074446248601
25	0	0,038457903742
26	0	0,000000000000
27	0	0,001721347427
28	0	0,000000022271
29	0	0,090344009539
30	0	0,000000000000
31	0	0,000000010376
32	0	0,031341618505

33	0	0,000000000000
34	0	0,066356462990
35	0	0,096297196401
36	0	0,000000000000
37	0	0,000000000000
38	0	0,000000000000
<b>39</b>	<b>0</b>	<b>0,205858339124</b>
40	0	0,000000000000
41	0	0,000000000000
42	0	0,003345397823
43	0	0,000000371422
44	0	0,000000000000
45	0	0,000000000000
46	0	0,000000000000
47	0	0,000000000000
48	0	0,000000000000
49	0	0,000000000000
50	1	0,000000000000
<b>51</b>	<b>1</b>	<b>0,054697601679</b>
<b>52</b>	<b>0</b>	<b>1,000000000000</b>
53	0	0,000000000000

Obs.: Os valores em negrito mostram os erros do modelo.

### Modelo 3:

Especificações do Modelo:

Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.

**Nível de convergência da Série: 0.95**

**Quantidade de Neurônios Intermediários: 30**

Resultado do Modelo de Redes Neurais

ENTRADA	FALENCIA	ANN
1	1	0.999999983515
2	1	0.683947418563
3	1	0.999999983932
4	1	0.999999983831
5	1	0.999999983930
6	1	0.999999983947
7	1	0.999999983867
8	1	0.999999983947
9	1	0.999999332843
10	1	0.999999983947

11	1	0.999999983947
12	1	0.999999983947
13	1	0.999999983759
14	1	0.999999983947
15	1	0.999999983720
16	1	0.999999983853
17	1	0.999999983896
18	1	0.999999983900
19	1	0.999999983947
20	0	0.000000090933
21	0	0.024848385545
22	0	0.000000092976
23	0	0.000000090958
24	0	0.001089761095
25	0	0.000026351969
26	0	0.018424042164
27	0	0.000351750439
28	0	0.000000299016
29	0	0.000000094943
30	0	0.000000119487
31	0	0.000042158876
32	0	0.000026229481
33	0	0.095553650128
34	0	0.000000248740
<b>35</b>	<b>0</b>	<b>0.116000017695</b>
36	0	0.097036538577
37	0	0.035712212367
<b>38</b>	<b>0</b>	<b>0.101120958413</b>
<b>39</b>	<b>0</b>	<b>0.111049219809</b>
<b>40</b>	<b>0</b>	<b>0.260941808422</b>
<b>41</b>	<b>0</b>	<b>0.105183596730</b>
42	0	0.001492915895
<b>43</b>	<b>0</b>	<b>0.121361755706</b>
<b>44</b>	<b>0</b>	<b>0.145882875972</b>
45	0	0.000003199724
<b>46</b>	<b>0</b>	<b>0.115378186187</b>
47	0	0.057768702114
48	0	0.020974679058
49	0	0.090672249099
50	1	0.548736622121
51	1	0.928789906027
52	0	0.009902874829
<b>53</b>	<b>0</b>	<b>0.354857551058</b>

Obs.: Os valores em negrito mostram os erros do modelo.

**Modelo 3:**

Especificações do Modelo:

Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.

**Nível de convergência da Série: 0.99****Quantidade de Neurônios Intermediários: 50**

Resultado do Modelo de Redes Neurais

ENTRADA	FALENCIA	ANN
1	1	1,000000000000
2	1	0,929638570244
3	1	1,000000000000
4	1	1,000000000000
5	1	1,000000000000
6	1	1,000000000000
7	1	1,000000000000
8	1	1,000000000000
9	1	0,989575950766
10	1	1,000000000000
11	1	1,000000000000
12	1	1,000000000000
13	1	1,000000000000
14	1	1,000000000000
15	1	1,000000000000
16	1	1,000000000000
17	1	1,000000000000
18	1	1,000000000000
19	1	1,000000000000
20	0	0,000000000005
21	0	0,013680258485
22	0	0,000000000005
23	0	0,000000000005
24	0	0,000000519691
25	0	0,000000001141
26	0	0,000110871571
27	0	0,000000041735
28	0	0,000000000008
29	0	0,000000000005
30	0	0,000000000005
31	0	0,000000001529
32	0	0,000000000771

33	0	0,007844151084
34	0	0,000000000007
35	0	0,009595087933
36	0	0,005925217891
37	0	0,000387527935
38	0	0,006165532897
39	0	0,008223654567
<b>40</b>	<b>0</b>	<b>0,119684570206</b>
41	0	0,006873545175
42	0	0,000000750366
43	0	0,010612383061
44	0	0,017070559169
45	0	0,000000000051
46	0	0,009314806400
47	0	0,001502073628
48	0	0,000039149640
49	0	0,004543750000
50	1	0,785918805667
51	1	0,898306520079
52	0	0,000191066971
<b>53</b>	<b>0</b>	<b>0,223348025610</b>

Obs.: Os valores em negrito mostram os erros do modelo.

### Modelo 3:

Especificações do Modelo:

Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.

**Nível de convergência da Série: 0.999**

**Quantidade de Neurônios Intermediários: 50**

Resultado do Modelo de Redes Neurais

ENTRADA	FALENCIA	ANN
1	1	1,0000000000
2	1	0,9869759543
3	1	1,0000000000
4	1	1,0000000000
5	1	1,0000000000
6	1	1,0000000000
7	1	1,0000000000
8	1	1,0000000000

9	1	0,9963383963
10	1	1,0000000000
11	1	1,0000000000
12	1	1,0000000000
13	1	1,0000000000
14	1	1,0000000000
15	1	1,0000000000
16	1	1,0000000000
17	1	1,0000000000
18	1	1,0000000000
19	1	1,0000000000
20	0	0,0000000000
21	0	0,0029569787
22	0	0,0000000000
23	0	0,0000000000
24	0	0,0000000004
25	0	0,0000000000
26	0	0,0000000479
27	0	0,0000000001
28	0	0,0000000000
29	0	0,0000000000
30	0	0,0000000000
31	0	0,0000000000
32	0	0,0000000000
33	0	0,0000342878
34	0	0,0000000000
35	0	0,0000300173
36	0	0,0000114468
37	0	0,0000003030
38	0	0,0000142260
39	0	0,0000227768
40	0	0,0047528620
41	0	0,0000277366
42	0	0,0000000003
43	0	0,0000377776
44	0	0,0001031735
45	0	0,0000000000
46	0	0,0000265727
47	0	0,0000012846
48	0	0,0000000641
49	0	0,0000091667
50	1	0,9279928021
51	1	0,9790543657
52	0	0,0000032278
53	0	0,0825692173

Apêndice 4 – Valores observados e valores estimados das redes neurais – Amostra com os bancos selecionados

**Modelo 1:**

Especificações do Modelo:

Variáveis utilizadas: despesa financeira, patrimônio líquido, a relação entre as operações de mercado aberto no total de passivos e o índice Bovespa.

**Nível de convergência da Série: 0.95**

**Quantidade de Neurônios Intermediários: 30**

Resultado do Modelo de Redes Neurais:

ENTRADA	FALENCIA	ANN
1	1	1,000000000000
2	1	0,999754492669
3	1	0,388514940756
4	1	1,000000000000
5	1	0,956551497423
6	1	1,000000000000
7	1	1,000000000000
8	1	1,000000000000
9	1	1,000000000000
10	1	1,000000000000
11	1	1,000000000000
12	1	1,000000000000
13	1	0,998800179099
14	1	1,000000000000
15	1	1,000000000000
16	1	1,000000000000
17	1	1,000000000000
18	1	0,999704105531
19	1	1,000000000000
<b>20</b>	<b>0</b>	<b>0,364432272464</b>
21	0	0,000000000000
22	0	0,000000000000
23	0	0,000000000000
24	0	0,093012904426
25	0	0,049259590993
26	0	0,000000000000
27	0	0,000000000000
28	0	0,013735993749
29	0	0,058339252676
30	0	0,000000000000
31	0	0,008399717440

32	0	0,040226067935
33	0	0,000000000000
34	0	0,083729560084
<b>35</b>	<b>0</b>	<b>0,115620063103</b>
36	0	0,000000000000
37	0	0,000000000000
38	0	0,000000000000
<b>39</b>	<b>0</b>	<b>0,190472340421</b>
40	0	0,000000000000
41	0	0,000000000000
42	0	0,000191005909
43	0	0,000001064942
44	0	0,000000000000
45	0	0,000000000000
46	0	0,000000000000
47	0	0,000000000000
48	0	0,000000000000
49	0	0,000000000000
50	1	0,000000000000
<b>51</b>	<b>1</b>	<b>0,069644208436</b>
<b>52</b>	<b>0</b>	<b>1,000000000000</b>
53	0	0,000000000000

**Modelo 3:**

Especificações do Modelo:

Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.

**Nível de convergência da Série: 0.95****Quantidade de Neurônios Intermediários: 30**

Resultado do Modelo de Redes Neurais

ENTRADA	FALENCIA	ANN
1	1	1,0000000000
2	1	0,8746005524
3	1	1,0000000000
4	1	1,0000000000
5	1	1,0000000000
6	1	1,0000000000
7	1	1,0000000000
8	1	1,0000000000
9	1	0,9883831638
10	1	1,0000000000

11	1	1,0000000000
12	1	1,0000000000
13	1	1,0000000000
14	1	1,0000000000
15	1	1,0000000000
16	1	1,0000000000
17	1	1,0000000000
18	1	1,0000000000
19	1	1,0000000000
20	0	0,0060023996
21	0	0,0347873547
22	0	0,0563779263
<b>23</b>	<b>0</b>	<b>0,2881540463</b>
24	0	0,0497408575
25	0	0,0369915283
26	0	0,0046816240
27	0	0,0389941977
28	0	0,0287823826
29	0	0,0745031791
30	0	0,0294157847
31	0	0,0818074590
32	0	0,0061513457
<b>33</b>	<b>0</b>	<b>0,1078616808</b>
34	0	0,0324402104
35	0	0,0229501496
36	0	0,0336769255
37	0	0,0000008686
38	0	0,0475758398
39	0	0,0080308932
40	0	0,0747640380
41	0	0,0001932810
42	0	0,0881523505
<b>43</b>	<b>0</b>	<b>0,1408207096</b>
44	0	0,0511187661
45	0	0,0000033788
46	0	0,0498495912
<b>47</b>	<b>0</b>	<b>0,3380068790</b>
48	0	0,0000015509
49	0	0,0000001638
50	1	0,6673536324
51	1	0,5213818925
52	0	0,0052319581
53	0	0,0114427716

Obs.: Os valores em negrito mostram os erros do modelo.

Especificações do Modelo:

Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.

**Nível de convergência da Série: 0.99**

**Quantidade de Neurônios Intermediários: 50**

Resultado do Modelo de Redes Neurais:

ENTRY	FALENCIA	ANN
1	1	1,0000000000
2	1	0,9386670297
3	1	1,0000000000
4	1	1,0000000000
5	1	1,0000000000
6	1	1,0000000000
7	1	1,0000000000
8	1	1,0000000000
9	1	0,9938610449
10	1	1,0000000000
11	1	1,0000000000
12	1	1,0000000000
13	1	1,0000000000
14	1	1,0000000000
15	1	1,0000000000
16	1	1,0000000000
17	1	1,0000000000
18	1	1,0000000000
19	1	1,0000000000
20	0	0,0000085199
21	0	0,0003845508
22	0	0,0002572522
<b>23</b>	<b>0</b>	<b>0,2147972527</b>
24	0	0,0021134341
25	0	0,0009876074
26	0	0,0000009867
27	0	0,0003664526
28	0	0,0002408126
29	0	0,0058067995
30	0	0,0002474762
31	0	0,0032871092
32	0	0,0000092737
33	0	0,0098451482

34	0	0,0003723999
35	0	0,0001629124
36	0	0,0002637834
37	0	0,0000000000
38	0	0,0007666095
39	0	0,0000155114
40	0	0,0020587769
41	0	0,0000000078
42	0	0,0094110825
43	0	0,0277783294
44	0	0,0014086008
45	0	0,0000000000
46	0	0,0008302268
<b>47</b>	<b>0</b>	<b>0,1446338168</b>
48	0	0,0000000000
49	0	0,0000000000
50	1	0,8938839129
51	1	0,7930246636
52	0	0,0001314463
53	0	0,0179693277

Apêndice 5 – Valores observados e valores estimados das redes neurais – Amostra com os bancos públicos e privados

**Modelo 3:**

Especificações do Modelo:

Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.

**Nível de convergência da Série: 0.95**

**Quantidade de Neurônios Intermediários: 30**

Resultado do Modelo de Redes Neurais:

ENTRADA	FALENCIA	ANN
1	1	0,9263871490
2	1	0,9801573656
3	1	1,0000000000
4	1	1,0000000000
5	1	1,0000000000
6	1	1,0000000000
7	1	1,0000000000
8	1	1,0000000000
9	1	1,0000000000
10	1	1,0000000000
11	1	1,0000000000
12	1	0,9999999757
13	1	1,0000000000
14	1	1,0000000000
15	1	1,0000000000
16	1	1,0000000000
17	1	1,0000000000
18	1	1,0000000000
19	1	1,0000000000
20	1	1,0000000000
21	1	1,0000000000
22	1	1,0000000000
23	1	1,0000000000
24	0	0,0000484009
25	0	0,0025918333
26	0	0,0000232758
<b>27</b>	<b>0</b>	<b>0,1630431679</b>
28	0	0,0004904724
29	0	0,0002122272
30	0	0,0000005904

31	0	0,0000757996
32	0	0,0011057711
33	0	0,0014427715
34	0	0,0011900737
35	0	0,0460564293
36	0	0,0000431834
37	0	0,0031605877
38	0	0,0028652637
39	0	0,0009454685
40	0	0,0005016593
41	0	0,0000000860
42	0	0,0057576700
43	0	0,0000609552
44	0	0,0199288826
45	0	0,0000001555
46	0	0,0027009462
47	0	0,0083589186
48	0	0,0003632086
49	0	0,0215217788
50	0	0,0000144532
51	0	0,0481311061
52	0	0,0000897705
53	0	0,0000090469
54	0	0,0636551503
55	1	0,9999914231
56	1	0,9372697280
57	0	0,0000571911
58	0	0,0000000834
59	1	1,0000000000
60	0	0,0000000834

**Modelo 3:**

Especificações do Modelo:

Variáveis utilizadas: consolidado, ativo total, passivo total, despesa financeira, captação total, patrimônio líquido, ativo permanente, capital de giro, operações em mercado aberto, participação das operações em mercado aberto no total de passivos, variação real do PIB, inflação, taxas de juros e de câmbio, além do índice Bovespa.

**Nível de convergência da Série: 0.99****Quantidade de Neurônios Intermediários: 50**

Resultado do Modelo de Redes Neurais:

ENTRY	FALENCIA	ANN
1	1	0,981980428829

2	1	0,863349845779
3	1	0,999999999999
4	1	0,999999999999
5	1	0,999999999999
6	1	0,999999999999
7	1	0,999999999999
8	1	0,999999999999
9	1	0,999999999999
10	1	0,999999999999
11	1	0,999999999999
12	1	0,999999999993
13	1	0,999999999999
14	1	0,999999999999
15	1	0,999999999999
16	1	0,999999999999
17	1	0,999999999999
18	1	0,999999999999
19	1	0,999999999999
20	1	0,999999999999
21	1	0,999999999999
22	1	0,999999999999
23	1	0,999999999999
24	0	0,006313659012
25	0	0,039874446356
26	0	0,018941982040
27	0	0,000131534331
28	0	0,000019997940
29	0	0,000014576761
30	0	0,000371528890
31	0	0,000018897032
32	0	0,028432984906
33	0	0,000030575143
34	0	0,036104983492
35	0	0,097831725618
36	0	0,004996129733
37	0	0,000051771708
38	0	0,036214291221
39	0	0,024030864149
40	0	0,028637139614
41	0	0,000000000121
42	0	0,057968807070
43	0	0,007089136377
44	0	0,095678903673
45	0	0,000000009337
46	0	0,000036745300

47	0	0,000058552207
48	0	0,000026216774
49	0	0,001086253099
50	0	0,008675636111
<b>51</b>	<b>0</b>	<b>0,183901442626</b>
52	0	0,014141831779
53	0	0,003037881547
54	0	0,001106895677
55	1	0,773863206119
<b>56</b>	<b>1</b>	<b>0,000339115448</b>
57	0	0,000015461789
58	0	0,000000298951
59	1	0,999999999999
60	0	0,000000000002