

Universidade Federal de Santa Catarina – UFSC
Centro Sócio Econômico
Departamento de Ciências Econômicas

Redes Neurais Artificiais para Previsão de Séries Temporais no Mercado
Acionário

PEDRO HENRIQUE MARANGONI

Florianópolis, 2010

PEDRO HENRIQUE MARANGONI

**REDES NEURAS ARTIFICIAIS PARA PREVISÃO DE SÉRIES TEMPORAIS NO
MERCADO ACIONÁRIO**

Monografia apresentada ao Curso de Graduação em Ciências Econômicas da Universidade Federal de Santa Catarina, como requisito parcial para obtenção do grau de Bacharelado em Ciências Econômicas.

Orientador: Prof. Milton Biage

FLORIANÓPOLIS, 2010

UNIVERSIDADE FEDERAL DE SANTA CATARINA - UFSC
CURSO DE GRADUAÇÃO EM CIÊNCIAS ECONÔMICAS

A Banca Examinadora resolveu atribuir a nota 9,5 ao aluno Pedro Henrique Marangoni na Disciplina CNM 5420 – Monografia, pela apresentação deste trabalho.

Banca Examinadora:

Prof. Milton Biage, Dr.

Orientador

Prof. Louis Roberto Westphal, Dr.

Membro da Banca Examinadora

Prof. Thiago Fleith Otuki, Msc.

Membro da Banca Examinadora

RESUMO

Neste trabalho utilizou-se a técnica computacional das redes neurais artificiais para previsão de séries temporais do mercado acionário. Os dados selecionados como *inputs* foram os preços de fechamento diário da ação da Petrobras (PETR4), e o índice da bolsa de valores brasileira, o IBOVESPA. Também se utilizaram indicadores técnicos como *inputs*, estimados a partir do IBOVESPA e dos preços de fechamento da PETR4, para tornar a rede neural mais eficiente. Os dados alvos do modelo foram os preços de fechamento diários da PETR4. O modelo de Rede Neural Artificial desenvolvido mostrou-se eficiente ao indicar as tendências de curtíssimo prazo com alto grau de exatidão de até 20 dias. O período compreendido da análise foi de janeiro de 1999 a maio de 2010. O principal objetivo do estudo foi verificar se as redes neurais artificiais, com sua habilidade de aprendizado, são capazes de prever o preço futuro de fechamento da ação da empresa escolhida. A análise compreende a comparação entre a previsão e o preço de fechamento efetivo dentro do período estudado. Ao fim do trabalho conclui-se que as redes neurais artificiais utilizadas para previsão de mercado acionário são capazes de mostrar resultados muito próximos da realidade, e que essa metodologia pode ser utilizada por investidores individuais e coletivos para aumentar os lucros na compra e venda de ações no curto prazo. O poder de previsão alcançado foi de 20 dias futuros.

Palavras chave: redes neurais artificiais, previsão de mercado acionário, BOVESPA.

ABSTRACT

This work uses the computational technique of artificial neural networks to forecasting time series of stock market. The Data inputs were chosen as the closing prices daily of Petrobras (PETR4), and the index of the Brazilian stock exchange, the IBOVESPA. Also, this work used technical indicators as inputs, estimated from the BOVESPA and the closing prices of PETR4 to make the neural network more efficient. Data Targets in the model was the price closing of the PETR4. The Artificial Neural Network model developed was efficient in indicating trends of short-term with high degree of accuracy up to 20 days. The period of analysis was from January 1999 to May 2010. The main objective was ascertained whether the artificial neural networks, with their ability to learning, are able to predict the future price of closing of the chosen company's action. The analysis includes a comparison between the forecast and closing prices within the effective period. At the end, this paper concludes that the artificial neural networks used for forecast the stock market are able to show results very close to reality, and this methodology can be used by collective and individual investors to increase profits in the purchase and sale of shares in the short term. The predictive power achieved was 20 days ahead.

Keywords: artificial neural networks, forecasting the stock market, BOVESPA.

LISTA DE ILUSTRAÇÕES

Figura 1. Neurônio Biológico.....	39
Figura 2. Neurônio Artificial.....	39
Figura 3. Rede Neural Artificial Multicamada.....	41
Figura 4. Parâmetros de uma rede neural.....	43
Figura 5. Rede Neural Artificial usando <i>Backpropagation</i>	45
Figura 6. Funcionamento de uma RNA com Backpropagation.....	48
Figura 7. Entradas normalizadas.....	53
Figura 8. Desempenho do erro no treinamento.....	54
Figura 9. R ² Ajustado.....	56
Figura 10. MSE da previsão (%).	56
Figura 11. Comparação Previsão x Preço Real PETR4, outubro de 2000 a março de 2001.....	58
Figura 12. Comparação Previsão x Preço Real PETR4, novembro 2001 a abril de 2002.....	59
Figura 13. Comparação Previsão x Preço Real PETR4, fevereiro de 2005 a julho de 2005.....	60
Figura 14. Comparação Previsão x Preço Real PETR4, dezembro de 2005.....	60
Figura 15. Previsão PETR4 de 31/05/2010 à 01/07/2010.....	63
Figura 16. Previsão PETR4 de 31/05/2010 a 01/07/2010, ampliada.....	64
Figura 17. Comparação da Previsão PETR4 x Preços Reais de 31/05/2010 a 18/06/2010.....	65
Figura 18. Previsão PETR4 de 21/06/2010 a 20/07/2010.....	66
Figura 19. Comparação Previsão x Preço Real PETR4, 16/06/2003 à 02/12/2003.....	75
Figura 20. Comparação Previsão x Preço Real PETR4, setembro de 2006 a fevereiro de 2007.....	76
Figura 21. Comparação Previsão x Preço Real PETR4, 16/06/2003 à 02/12/2003.....	77
Figura 22. Comparação Previsão x Preço Real PETR4, 28/11/2008 à 30/12/2008.....	78
Figura 23. Comparação Previsão x Preço Real PETR4, 28/11/2008 à 30/12/2008.....	79
Figura 24. Comparação Previsão x Preço Real PETR4, junho a dezembro de 2009.....	80

LISTA DE TABELAS

Tabela 1. Últimos 10 valores de entrada da rede sem normalização.....	52
Tabela 2. Últimos 10 valores de entrada da rede normalizados.....	52
Tabela 3. Parâmetros da RNA escolhidos para o modelo.	55
Tabela 4. Funções de Ativação para RNA.	72

LISTA DE ABREVIATURAS E SIGLAS

AR – Autoregressive

ARCH – Autoregressive Conditional Heteroscedasticity

ARMA – Autoregressive Moving Average

BOVESPA – Bolsa de Valores de São Paulo

EMH – Efficient Markets Hypothesis

GARCH – Generalized Autoregressive Conditional Heteroskedasticity

IA – Inteligência Artificial

IBOVESPA – Índice da Bolsa de Valores de São Paulo

LTB – Linha de Tendência de Baixa

MLP – *Multi Layer Perceptron*

MA – Moving Average

RNA – Rede Neural Artificial

RNAs – Redes Neurais Artificiais

SUMÁRIO

1 INTRODUÇÃO	10
1.1 TEMA E PROBLEMA	11
1.2 OBJETIVOS	13
1.2.1 <i>Objetivo Geral</i>	13
1.2.2 <i>Objetivos Específicos</i>	14
1.2.3 <i>Justificativa</i>	14
1.3 METODOLOGIA	15
2 O MERCADO DE CAPITAIS	18
2.1 AÇÕES.....	19
2.2 TIPOS DE AÇÕES	20
2.3 FORMAS DE CIRCULAÇÃO DAS AÇÕES	20
2.4. VALOR DAS AÇÕES.....	21
2.5 RENDIMENTOS DAS AÇÕES E RISCO	23
2.6 DIREITOS DE SUBSCRIÇÃO	24
2.7 BONIFICAÇÃO	25
2.8 DESDOBRAMENTO DE AÇÕES – <i>SPLIT</i>	26
2.9 MERCADO PRIMÁRIO E SECUNDÁRIO.....	27
2.10 ABERTURA DE CAPITAL.....	28
2.11 MERCADO SECUNDÁRIO – BOLSA DE VALORES.....	29
2.12 MERCADO DE DERIVATIVOS E A BM&F.....	30
2.13 <i>HOME BROKER</i> E <i>AFTER MARKET</i>	31
2.14 MERCADOS EFICIENTES	32
3 REDES NEURAS PARA PREVISÕES DE SÉRIES TEMPORAIS.....	35
3.1 APLICAÇÕES	37
3.2 DEFINIÇÃO DE REDES NEURAS	38
3.3 FATORES QUE INFLUENCIAM O DESEMPENHO DAS RNAs.....	42
3.3 REDES NEURAS COM <i>BACKPROPAGATION</i>	44
4 REDE NEURAL IMPLEMENTADA E RESULTADOS.....	48
4.1 DEFINIÇÕES DAS VARIÁVEIS DE ENTRADA E SAÍDA	49
4.2 MODELO DE RNA PARA PREVISÃO DA AÇÃO PETR4.....	53
4.3 ANÁLISES DOS RESULTADOS DE PREVISÃO.....	57
5 CONCLUSÃO.....	67
REFERÊNCIAS	69
ANEXOS	71

1 INTRODUÇÃO

Importante fonte de captação financeira para empresas e pessoas físicas, o mercado de capitais vem crescendo consideravelmente no Brasil. Segundo dados da BM&FBOVESPA (Bolsa de Mercadorias e Futuro do Brasil)¹, nas operações do mercado acionário os investidores individuais tiveram participação de 30% do volume negociado na BOVESPA nos três primeiros meses de 2010. De fevereiro de 2008 a fevereiro de 2010, o aumento de contas de investidores pessoa física com posição de custódia foi de 19%, tudo isso mostra o crescente interesse dos investidores individuais.

Para aumentar os lucros no mercado acionário é fundamental utilizar ferramentas de previsão. Porém previsão de mercado acionário é um tema complexo. As variáveis que interferem nesse mercado são inúmeras e suas inter-relações dificultam previsões precisas. Fatos políticos, informações assimétricas e expectativas dos investidores podem alterar os preços e as tendências. Essas alterações são difíceis de identificar, medir, e quase impossível é fazer previsões 100% precisas. Por outro lado, mesmo previsões com um certo grau de imprecisão são valiosas.

E estudos utilizando redes neurais, que definidos como um subconjunto da Inteligência Artificial, têm se limitado ao escopo universitário, empresas de pesquisa e grandes empresas de investimentos. Nosso desafio é mostrar que o investidor individual pode também utilizar esse recurso. Com o crescimento do acesso aos computadores, diversos programas computacionais estão sendo desenvolvidos com objetivo de usar as redes neurais para previsões em várias áreas da ciência. Porém o que não é destacado são as habilidades necessárias do projetista e o esforço despendido para construção de um modelo eficiente.

A proposta deste trabalho é estabelecer previsões com redes neurais artificiais de séries temporais do mercado de ações. A análise aqui conduzida compreendeu o preço da ação PETR4, seu índice de liquidez, médias móveis e outros índices indicadores de tendências, que são explicados na metodologia. Esses dados são utilizados como entradas para a rede neural, e uma vez treinada e testada, foram feitas previsões do comportamento futuro do preço de fechamento diário para a ação em questão.

¹ Mais informações nos informes técnicos da BOVESPA, disponível em www.bovespa.com.br

Os trabalhos de Cartacho (2001) e Freitas (2001) são bons exemplos quanto ao uso de redes neurais artificiais para previsão de valores futuros de ativos financeiros (ações, índices, opções, etc.). Esses bons resultados têm motivado novos estudos utilizando redes neurais, como é o caso deste trabalho.

A rede neural artificial (RNA) é um método computacional para analisar sistemas não lineares. Baseada no funcionamento do cérebro humano, a RNA possui um processo de aprendizado (análise dos dados), generalização (validação dos dados), teste e por último a fase de previsão dos resultados. A saída final da rede representa o valor da função de ativação. A malha de neurônios tem a capacidade de aprendizado, reajustando os pesos quando necessário. É esse aprendizado que faz das redes neurais uma poderosa ferramenta para análise de dados ruidosos, que no nosso caso, são as oscilações dos preços das ações na bolsa de valores. A habilidade de aprendizado das redes neurais é tratada com mais detalhes no capítulo 3.

O bom desempenho das redes neurais vem da capacidade de lidar com dados com muitas oscilações e perturbações periódicas. Essas características tornam as RNAs uma poderosa ferramenta para previsão de séries temporais, não apenas no mercado financeiro, mas também, por exemplo, em diagnósticos médicos, reconhecimento de padrões visuais, sistemas de segurança, robótica, avaliação de crédito, entre outros.

Neste trabalho utilizou-se o software MATLAB para construir uma RNA capaz de identificar pontos de entrada (compra da ação) e saída (venda da ação) do mercado acionário, informações que possibilitam aumentar os lucros dos investimentos no mercado acionário, a curto e longo prazo, diminuindo os riscos, premissas fundamentais para quem aplica em ativos do mercado financeiro.

1.1 Tema e Problema

Fazer previsões sempre foi um desafio para todas as áreas do conhecimento. Previsões adequadas em economia e finanças aumentam os ganhos e reduzem os riscos nas operações.

Sabe-se que os eventos não são iguais, porém não são completamente diferentes. Para Refenes (1993, p. 5), existem “fenômenos que parecem aleatórios, sem aparente periodicidade, embora recorrentes em um sentido geral.” Ou seja, os eventos que alteram os preços no mercado, embora muitas vezes desconexos num sentido restrito, possuem característica em comum com eventos passados. Essa não-aleatoriedade dos preços faz com que os mercados sejam previsíveis. A dependência não-linear é justificativa para utilização de modelos econométricos e redes neurais artificiais.

Para prever o comportamento de um determinado sistema, a melhor maneira é encontrar o conhecimento de suas leis subjacentes, subentendidas e pré-definidas. No caso dos sistemas econômicos, tais como bolsas de valores, o conhecimento do que rege as regras não estão bem definidos ou prontamente disponíveis. Torna-se, portanto, difícil de prever os sistemas financeiros, pois não há regularidade devido a sua complexidade, incerteza e fragmentação dos dados.

Grande parte dos modelos clássicos para predição utiliza apenas equações lineares, especificadas pelo usuário. No caso de modelos econômicos, pode-se levar muito tempo para resultados significativos. Com o avanço das tecnologias de informação, tornou-se possível desenvolver métodos mais apurados no sentido de aproximar as previsões. Para tentar diminuir as dificuldades dos sistemas lineares e melhorar a qualidade dos resultados, desenvolveu-se a rede neural artificial, capazes de processar grande quantidade de dados através da computação e identificar modelos e tendências, facilitando a tomada de decisões. Muitos bancos e empresas estão usando as redes neurais para identificar tendências complexas, com objetivo de diminuir suas perdas, computar análises de volatilidade, melhorar o desempenho financeiro, avaliar riscos, etc.

A rede neural artificial tem a característica de “copiar” o comportamento do cérebro humano através de neurônios artificiais utilizando algoritmos de aprendizado². Aplicando-se esses algoritmos sobre os dados de entrada (*inputs*), após um processamento desses dados através de uma função de ativação e alvos (*targets*) pré-definidos, a rede neural retorna valores esperados (*outputs*) e os respectivos erros.

² Para Haykin (2001, p. 24), algoritmo de aprendizagem é “o procedimento utilizado para realizar o processo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de forma ordenada para alcançar o objetivo desejado”.

Diversas teorias estão no âmbito da discussão sobre análise e previsão do mercado acionário, todas com o objetivo de diminuir riscos e aumentar os lucros no menor espaço de tempo. Este trabalho também prima por esses objetivos através das redes neurais artificiais.

Entre as teorias de otimização de carteiras com a hipótese de mercados eficientes, o modelo mais utilizado é o chamado “*Capital Asset Pricing Model*”, o CAPM. Esse modelo desenvolvido durante os anos 60 tem como objetivo dar uma forma específica à existência de um *trade-off* (troca conflituosa) entre ganhos e riscos. O modelo estabelece uma relação linear positiva entre o ganho esperado de uma carteira de ativos diversificado num mercado dito eficiente.

Diversos autores testaram a eficiência do CAPM e constataram que a hipótese dos mercados eficientes³ dificilmente é mantida. A limitação desse modelo está na relação linear entre retorno e o beta, pois não mostra com precisão os diferentes retornos entre os ativos. É nessa perspectiva da limitação de modelos lineares que os modelos baseados em redes neurais tornaram-se mais eficientes.

Existem diversas teorias que procuram testar a eficiência do mercado financeiro, porém não é objetivo deste trabalho o debate teórico acerca das correntes teóricas. A análise aqui compreendida limitou-se ao desenvolvimento de um modelo para previsão do preço de fechamento da ação comparativamente aos preços reais de fechamento.

1.2 Objetivos

1.2.1 Objetivo Geral

³ A hipótese dos mercados eficientes proposta por Fama (1970) afirma que o mercado é eficiente na alocação dos recursos, onde o preço dos ativos sempre reflete inteiramente todas as informações disponíveis, e todos os investidores dispõem dessas informações para tomada de decisão e não há informações assimétricas ou privilegiadas.

Utilizar as redes neurais artificiais para previsão do preço de fechamento futuro no curto prazo da ação da Petrobras (PETR4) do mercado acionário brasileiro - BOVESPA.

1.2.2 Objetivos Específicos

- a) Desenvolver um algoritmo capaz de treinar, testar e prever comportamento de níveis de preços da BOVESPA.
- b) Treinar e listar a série meta do estudo (o nível de preços) para estabelecer-se um conjunto de testes de previsão, envolvendo o preço de fechamento da ação da Petrobras (PETR4) no período de 04/01/1999 a 31/05/2010.
- c) Quantificar a performance das previsões estabelecidas, por meio de escores e erro padrão médio (MSE).

1.2.3 Justificativa

Da mesma forma que os trabalhos de Cartacho (2001) e Freitas (2001) chegaram a resultados importantes com o uso das redes neurais para previsões do mercado acionário, esse trabalho também se justifica na medida em que esse modelo pode atingir um grau de previsão muito melhor que os modelos clássicos de séries temporais, cujas relações lineares limitam sua usabilidade. A capacidade de modelagem de valores com relações não lineares justifica o uso de redes neurais, que apresentam níveis de erros extremamente baixos. Além disso, as RNAs acompanham alterações contínuas e bruscas nas oscilações do mercado financeiro, o que não pode ser medido por um modelo matemático linear e pré-definido.

Não somente em economia, mas também em diversas outras áreas do conhecimento, é visível o crescimento do uso das redes neurais para auxílio na tomada de decisões. Seu uso vem auxiliando a medicina, por exemplo, no cruzamento de dados de pacientes com quadros clínicos parecidos, os médicos fazem prescrições mais adequadas; no sistema financeiro é utilizada para conter fraudes no sistema de cartão de crédito. Também é utilizada para aplicações climáticas.

Portanto, esses bons resultados das redes neurais justificam sua utilização nesse trabalho.

1.3 Metodologia

A pesquisa se baseou num banco de dados de preços de fechamento diário da ação da Petrobras (PETR4), fechamento do IBOVESPA e volume das operações. O período selecionado foi de 04/01/1999 a 31/05/2010. Os valores foram coletados no software Economática, fora ajustados os dividendos e preços da PETR4, organizados e classificados em planilha para utilização no programa MATLAB R2009a (versão 7.8.0.347 de 12/02/2009).

A partir dos dados coletados foram utilizados índices técnicos e funções de normalização para tratamento dos dados. Essa estratégia se mostrou eficiente na medida em que a rede obteve melhor resultado ao identificar tendências quando adicionado esses indicadores. Utilizaram-se os seguintes índices e funções:

- a) IN – Índice de Negociabilidade mede a importância da ação no mercado quanto ao volume financeiro e número de negócios (ou seja, a liquidez da ação no mercado). Quanto maior for esse índice, mais liquidez tem a respectiva ação. Esse índice é utilizado na metodologia de cálculo das ações que compõem o índice BOVESPA (IBOVESPA).

- b) ROC(n)⁴ – Rate of Change. Esse indicador da teoria de análise técnica considera o grau de mudança médio dos “n” dias passados, ou seja, mostra que as oscilações médias passadas tem relevância na formação dos preços futuros. Utilizaram-se o ROC3 e o ROC10, para 3 e 10 dias respectivamente.
- c) RSI(t) – Relative Strength Index. Quando esse indicador for maior que 50, ele induz que o mercado está com tendência de alta e se o contrário, ele caracteriza que o mercado está com tendência de baixa.
- d) %R(t) – Percentual R. Esse índice evidencia os limites das oscilações passadas, para identificar tendências nas relações futuras. Valores baixos significam que os preços estão perto do valor máximo, próximo a resistência; enquanto valores altos significam que os preços estão próximos do suporte, do valor mínimo.
- e) $\text{mapminmax}(y)$ para normalização dos dados para o intervalo [-1,1].

Preparou-se uma Rede Neural Artificial (RNA) com um potencial de treinamento, teste e previsão, com níveis de erro baixos. O algoritmo do modelo foi elaborado, de modo que facilitasse a análise dos resultados. Portanto, o código computacional foi estruturado com saídas gráficas que permitem:

- i. Estabelecer a comparação entre os resultados previstos com aqueles que realmente ocorreram no mercado financeiro; e
- ii. Observar a evolução das previsões, tal que se possam identificar as aparentes tendências futuras de reversão de crescimento e de queda nas séries de preço, por meio de cruzamento de média móvel. Para tal, introduziram-se as estimativas de médias móveis de 4, 9 e 18 dias, conforme proposto por Murphy (1999).

Todos os valores de entrada (*input*) e alvo (*target*) foram normalizados no intervalo -1 e 1 através da função *mapminmax*. Este procedimento é obrigatório, pois a função de ativação usada na RNA processa somente valores entre -1 e +1.

Após a fase de normalização dos dados, montou-se uma matriz para os dados de entrada e outra com o alvo. Utilizando a metodologia das redes neurais, desenvolveu-se no código computacional do MATLAB R2009a (versão 7.8.0.347 de 12/02/2009), um algoritmo

⁴ A metodologia foi proposta por RAO (1995) e mostrou-se muito eficiente, por isso se utilizou neste trabalho.

capaz de identificar as tendências da série temporal em questão. A partir do aprendizado da rede neural, foram feitos testes de significância estatística dos valores encontrados, com objetivo de saber se os valores são confiáveis ou meras coincidências.

Foi utilizada a rede neural do tipo *backpropagation*, que além de utilizar os dados de entrada, também tem um dispositivo de retroalimentação que considera os dados de saída para auxiliar na previsão. A formulação matemática desse tipo de rede neural está detalhada no capítulo 3.

Após a conclusão dos testes da RNA comparou-se os resultados de treinamento, teste e previsão, com os valores reais até o dia 31/05/2010, tomando sempre um conjunto de 100 valores, escolhidos aleatoriamente e em sequência, de um determinado período, com duração de treinamento de 75% dos dados – 75 dias, 25% para teste – 25 dias, para chegar a 20 dias de previsão.

2 O MERCADO DE CAPITAIS

Desde o princípio do funcionamento dos mercados de capitais, tornou-se tarefa imprescindível analisar as cotações e desenvolver ferramentas de previsão dos preços futuros. O índice Dow Jones⁵, por exemplo, foi criado em 1884 por Charles Dow que analisava os preços de 11 empresas, no papel milimetrado, sem qualquer auxílio de computadores. No caso brasileiro, a Bolsa de Valores do Rio de Janeiro surge em 1845 e a BOVESPA em 1890. Naquela época as cotações eram registradas com giz em um quadro negro. O IBOVESPA (índice da bolsa de valores de São Paulo) foi criado em 1968 com o valor base 100 em 02 de janeiro do mesmo ano.

Investidores, especuladores, cientistas e curiosos sempre tiveram interesse em prever o rumo dos mercados. Não é difícil encontrar análises, sugestões, “palpites” de compra e venda e demais informações referente ao futuro do mercado acionário. Com o avanço da tecnologia da informação e o crescente uso dos computadores, diversos programas foram desenvolvidos para facilitar as análises do mercado acionário. As RNAs estão dentro desse processo evolutivo e tem se apresentado como um método eficaz na previsão do mercado acionário, conforme estudos de Rao (1995) e Abelém (1994).

Prever o futuro, especialmente as séries temporais econômicas, é imprescindível para análises complexas e tomadas de decisões. Ainda é um desafio para a ciência estatística e a computação desenvolver um método 100% eficaz para previsão do mercado financeiro, porém as RNAs têm retornado valores surpreendentes, quase sempre melhores que os métodos estatísticos convencionais, conforme os trabalhos de Cartacho (2001) e Freitas (2001).

À medida que a economia se expande, torna-se mais relevante o sistema de distribuição de valores mobiliários, como um fator multiplicador da riqueza nacional. O sucesso dos investimentos produtivos está cada vez mais relacionado com a participação dos acionistas, cujos interesses de participação nos resultados impulsionam o crescimento das

⁵ Índice da Bolsa de Valores dos Estados Unidos, calculado com base nas 30 maiores e mais importantes ações do mercado norte americano.

empresas. As empresas têm diversas alternativas de financiamento, obtidas principalmente de empréstimos (capital de terceiros), geração e reinvestimentos de lucros e aporte de capital de acionistas.

A função básica do mercado de capitais é a de promover a riqueza nacional por meio da participação da poupança de cada agente econômico. Nesse mercado, os principais ativos negociados são as ações, representativos do capital das empresas.

2.1 Ações

As ações são títulos representativos da menor fração do capital social de uma empresa (sociedade anônima, sociedade por ações ou companhia). O acionista não é um credor da companhia, mais um co-proprietário com direito na participação de seus resultados.

As ações podem ser emitidas sob a forma física de cautelas ou certificados, que comprovam a existência e a posse de certa quantidade especificada de ações, ou do tipo escritural, que dispensa sua emissão física, mantendo o controle das ações em contas de depósitos em nome de seus titulares em uma instituição depositária.

Uma ação não tem prazo de resgate, sendo convertida em dinheiro mediante negociação no mercado. O investidor pode alterar sua participação acionária, desfazendo-se de títulos possuídos ou mesmo vendendo as ações de uma empresa e adquirindo de outras.

As sociedades anônimas emitentes de ações podem ser de dois tipos: abertas ou fechadas. Uma companhia é aberta quando tem suas ações distribuídas entre um número mínimo de acionistas, podendo ser negociadas em Bolsas de Valores. Essas sociedades devem ser registradas na Comissão de Valores Mobiliários como capital aberto e fornecerem ao mercado, de forma periódica, uma série de informações de caráter econômico, social e financeiro. As companhias de capital fechado, por outro lado, são tipicamente empresas familiares, com circulação de suas ações restrita a um grupo restrito de investidores.

2.2 Tipos de Ações

As ações são classificadas basicamente em dois tipos: ordinárias e preferenciais.

Os acionistas detentores de ações ordinárias são quem comandam a assembléia de acionistas de uma empresa, conferindo ao seu titular o direito de voto. Os acionistas ordinários podem eleger e destituir os membros da diretoria e do Conselho Fiscal da companhia; decidir sobre o destino dos lucros; reformar o estatuto social; autorizar emissões de debêntures⁶ e aumentos de capital social; votar contas patrimoniais, etc.

Cada ação ordinária equivale a um voto. O poder de decisão concentra-se no investidor (ou grupo de investidores) que detenha a maior quantidade de ações. Sociedades que tenham suas ações ordinárias concentradas nas mãos de um número reduzido de investidores têm seu controle bastante identificado, dificultando as livres negociações de mercado e os movimentos dos preços.

Uma maior pulverização das ações, de outro modo, permite que os investidores (ou grupo) com menor participação acionária assumam o controle da empresa, incentivando uma maior participação no capital votante. À medida que o mercado de capitais se desenvolve, aumenta-se a quantidade de acionistas, caracterizando uma maior distribuição das ações entre investidores e induzindo uma menor concentração no capital votante que exercerá o controle acionário de uma empresa.

2.3 Formas de Circulação das Ações

⁶ Debêntures são títulos de crédito de empréstimo que uma empresa contratou de terceiros, que garante aos detentores os direitos contra a emissora, de acordo com as condições da escritura de emissão.

Quanto à forma de circulação, as ações podem ser nominativas, nominativas endossáveis e escriturais.

As ações nominativas trazem o nome do investidor registrado em livro de registro das ações nominativas. Sua transferência dá-se pela averbação do nome do novo titular neste livro, conferindo todos os direitos de acionista.

As ações nominativas endossáveis registram somente o nome do primeiro acionista, sendo as transferências de titularidades processadas mediante endosso na própria cautela.

As ações são emitidas por meio de cautelas, as quais devem ser registradas no referido livro de registro de ações nominativas para que se caracterize, formalmente, a propriedade do título. No entanto, existem ações anônimas sem suas respectivas cautelas, são as denominadas de escriturais. Essas ações têm seu controle executado por uma instituição fiel depositária das ações da companhia, a qual mantém uma conta de depósito em nome de seus proprietários. Todas as movimentações com essas ações ocorrem mediante extratos bancários emitidos pelas instituições depositárias. Atualmente a maioria das ações são da forma escritural.

2.4. Valor das ações

Podem ser definidos, de acordo com os objetivos da análise, os seguintes valores monetários para as ações: nominal, patrimonial, intrínseco, de liquidação, de subscrição e de mercado.

O valor nominal é o valor atribuído a uma ação previsto no estatuto social da companhia. Uma ação pode ser emitida com e sem valor nominal, sempre de acordo com o regulamento no estatuto da empresa. Na hipótese de emitir ações sem valor nominal, todas as ações deverão ter o mesmo valor, não sendo permitidas ainda novas emissões com valores diferentes.

Quando as ações não possuem valor nominal, ainda, o preço de emissão é definido pelos sócios fundadores da sociedade, e no momento de capital, pela assembléia geral de acionistas (ou Conselho de Administração). Nessa alternativa de emissão, a companhia pode estabelecer qualquer valor para suas ações, não havendo obrigatoriedade de se respeitar um valor mínimo, como no caso descrito das ações com valor nominal. A parcela do preço de emissão da ação sem valor nominal que ultrapassar o montante definido ao capital social, será considerada como reserva de capital.

Uma companhia pode adquirir suas próprias ações no mercado, retirando-as de circulação. Essa operação é conhecida por resgate de ações. Enquanto mantidas em contas patrimoniais da empresa, essas ações não podem exercer seus direitos de voto e recebimento de dividendos. O resgate das ações pode ser efetuado com redução ou não do capital social, ao critério da sociedade.

O valor patrimonial de uma ação representa a parcela do capital próprio (patrimônio líquido) da sociedade que compete a cada ação emitida. É determinado pelo valor do patrimônio líquido dividido pelo número de ações emitidas. Por exemplo, se o patrimônio líquido de uma empresa for de \$ 80 milhões e ela tiver 40 milhões de ações emitidas, determina-se um valor patrimonial de \$ 2,00 por ação, indicando que cada ação emitida participa com \$ 2,00 do patrimônio da sociedade.

Deve ser registrado que a realização financeira total do valor patrimonial de uma ação somente ocorre em caso de dissolução da sociedade. A cada exercício, parte do capital próprio é distribuído aos acionistas sob a forma de dividendos, verificando-se, ao mesmo tempo, um crescimento do patrimônio líquido pela retenção de lucros e integralização de novas ações.

O valor intrínseco de uma ação equivale ao valor presente de um fluxo esperado de benefícios de caixa. Esse fluxo é descontado a uma taxa de retorno mínima requerida pelos investidores, a qual incorpora o risco associado ao investimento. Com isso, o valor intrínseco embute o potencial de remuneração da ação, fundamentando-se nas possibilidades de desempenho da empresa no futuro e no comportamento esperado da economia.

De outra forma, o valor de mercado representa o efetivo preço de negociação da ação. Coincide, necessariamente, com seu valor intrínseco, sendo definido a partir das percepções dos investidores e de suas estimativas com relação ao desempenho da empresa e da economia.

Uma decisão de investimento em ação exige que se localize papéis que estejam sendo negociados no mercado, a um preço inferior a seu valor intrínseco, identificando-se uma recomendação de compra.

O valor de liquidação é determinado quando do encerramento de atividade de uma companhia, indicando quando compete do resultado da liquidação para cada ação emitida.

O valor de emissão é o preço definido no lançamento de ações em operações de abertura de capital de uma empresa. Esse valor é determinado principalmente com base nas perspectivas da empresa emitente, do volume de emissão, preço corrente de mercado da ação, e de outras variáveis de mercado.

2.5 Rendimentos das ações e risco

Ação é um título de renda variável que oferece resultado (ganho ou perda) ao investidor baseados no comportamento de seus preços de mercado. Esses resultados dependem de diversos fatores ligados ao desempenho esperado da empresa emitente, das condições de mercado e evolução geral da economia.

Essencialmente, uma ação oferece duas formas de rendimentos aos seus investidores: dividendos e valorização de seu preço de mercado. Um benefício que o título também pode proporcionar aos seus titulares é o direito de subscrição em casos de aumento de capital por integralização.

Os dividendos representam distribuição de lucros auferidos pela empresa aos seus acionistas, sendo normalmente pagos em dinheiro.

A decisão de uma política de dividendos envolve basicamente uma decisão sobre o lucro líquido da empresa: retê-lo, visando ao reinvestimento em sua própria atividade; ou distribuí-lo, sob a forma de dividendos em dinheiro aos acionistas.

O índice de *payout* mede a porcentagem do lucro líquido a ser distribuída aos acionistas de uma empresa.

Quanto maior se apresentar esse indicador de dividendos, menor será a proporção de recursos próprios, proveniente de decisões de retenção de lucros, utilizada pela empresa em sua atividade. Baixos índices de *payout* (ou nulos) atribuem normalmente uma elevada opção de reter lucros como fonte de financiamento de uma empresa.

Todos os acionistas (ordinários e preferenciais) têm o direito de receber dividendos em cada exercício, tornando-se uma prática obrigatória para as sociedades por ações. A atual legislação brasileira sobre distribuição de dividendos encontra-se prevista basicamente na lei das sociedades por ações (Lei n.º 6.404/76). Os lucros são distribuídos com base no previsto nos estatutos sociais, tendo como percentual mínimo obrigatório 25% sobre o lucro líquido ajustado do período. No caso do estatuto da companhia ser omissivo com relação a esse dividendo, a legislação prevê a distribuição de 50% desse resultado ajustado a todos os acionistas.

2.6 Direitos de Subscrição

A subscrição é o direito de todos os acionistas em adquirir novas ações emitidas por uma companhia. Por meio da elevação de seu capital social, a sociedade emite e oferece para subscrição novas ações aos investidores, comprometendo-se a dar preferência de compra aos atuais acionistas na proporção das ações possuídas. A aquisição, no direito de preferência, é efetuada pelo preço definido de subscrição, geralmente inferior ao valor de mercado, promovendo um ganho ao subscritor pela diferença verificada nesses valores.

Os recursos dos pagamentos efetuados pelos acionistas à sociedade emitente das novas ações são direcionadas para financiar projetos de investimentos e reforço de capital de giro.

Os direitos de subscrição podem ser negociados mediante a emissão de "bônus de subscrição", títulos negociáveis no mercado de capitais que dá a seu titular o direito de subscrever ações pelo preço de lançamento.

2.7 Bonificação

A bonificação é um direito do acionista em receber ações, proporcionais aos títulos possuídos, em decorrência do aumento de capital de uma empresa mediante incorporação de reservas. A bonificação não deve promover qualquer alteração no valor de mercado da ação, representando simplesmente uma transferência de contas patrimoniais, para atualização da participação do acionista no capital da empresa. Não promove qualquer alteração na estrutura econômica e financeira da empresa, não devendo, por conseguinte, determinar variações em seu preço de mercado.

O aumento do capital social de uma companhia por incorporação de reservas patrimoniais pode ser processado de três formas:

- Pela emissão de novas ações e conseqüente distribuição gratuita a seus atuais titulares, na proporção da participação acionária mantida por titular. É a denominada "bonificação em ações". Essa operação não produz alteração alguma na participação relativa dos acionistas, elevando unicamente a quantidade de ações possuídas;
- Mediante alteração do valor nominal da ação, não havendo necessidade de a sociedade emitir novos títulos. O reajuste do valor da ação deve refletir o valor da elevação do capital;
- Se as ações não apresentarem valor nominal, a quantidade de ações emitidas pela sociedade permanece inalterada, elevando-se unicamente o montante contábil do capital social.

2.8 Desdobramento de Ações – “Split”

O “Split”, por seu lado, é a emissão de novas ações em razão da representação do capital social em um número maior de ações. Nessa operação, cada ação antiga é desdobrada em uma ou mais ações novas sem apresentar nenhuma interferência no capital social da companhia. O *split* altera unicamente o valor individual da ação, mantendo inalterado o capital da sociedade. As ações desdobradas são distribuídas aos atuais acionistas na proporção de cada ação possuída, não alterando também a participação acionária de cada um deles.

O objetivo principal de uma sociedade em efetuar um “split” de suas ações é dar maior liquidez a seus papéis, aproximando seu valor de mercado à cotação média da bolsa.

Por exemplo, suponha que uma empresa tenha suas ações negociadas em Bolsa de Valores a uma cotação média de \$ 16,00 cada uma, e que seu valor nominal atinja a \$ 12,00 por ação. Diante desses valores elevados para os padrões médios vigentes no mercado, a empresa constata dificuldades em melhorar a liquidez de seus papéis no mercado, e observa ainda que a maioria de suas ações se encontram em poder de investidores institucionais (fundos de pensão, carteiras de bancos, etc.).

A solução empregada pode ser o uso do “split” por meio do desmembramento de cada ação em 12 ações de valor nominal de \$ 1,00 cada uma. Com essa medida, a quantidade de ações negociadas diariamente eleva-se muito e seu preço de mercado sofre uma redução paralela, de maneira a possibilitar um maior número de negócios com o papel.

O “split” não deve ser confundido com bonificação em ações. Apesar de as duas práticas não alterarem o patrimônio líquido total da empresa, a bonificação é consequência de um aumento de capital social por incorporação de reservas, e o desdobramento é uma forma de reduzir o preço de mercado das ações mediante alterações em seu valor nominal e na quantidade física emitida. Conforme foi colocado acima, o objetivo do uso do “split” é melhorar os índices de liquidez de uma ação para torná-la acessível a uma taxa de investidores.

2.9 Mercado Primário e Secundário

O mercado financeiro pode ser classificado segundo diversos critérios. Pela natureza dos títulos negociados, tem-se o mercado de ações, mercado de renda fixa, mercado de créditos, etc. Ao se considerar a maturidade dos títulos são identificados principalmente o mercado monetário, que opera no curto prazo, e o mercado de capitais, com operações de crédito de médio e longo prazos.

Uma outra classificação do mercado financeiro envolve o momento da negociação do título no mercado. O lançamento de um novo ativo financeiro ocorre no mercado primário; essencialmente, todo ativo financeiro é colocado no mercado (negociado pela primeira vez) por meio do mercado primário. Negociações posteriores, envolvendo compras e vendas de títulos já lançados entre investidores, são realizadas no mercado secundário.

Nesse critério, o mercado acionário pode também ser identificado por meio desses dois segmentos distintos de operações. No mercado primário, ocorre a canalização direta dos recursos monetários superavitários, disponíveis aos poupadores, para o financiamento das empresas, por meio da colocação (venda) inicial das ações emitidas. É nesse setor do mercado que as empresas buscam, mais efetivamente, os recursos próprio necessários para a consecução de seu crescimento, promovendo, a partir do lançamento de ações, a implementação de projetos de investimentos e o conseqüente incremento da riqueza nacional.

No mercado secundário são estabelecidas as renegociações entre os agentes econômicos das ações adquiridas no mercado primário. Os valores monetários das negociações realizadas nesse mercado não são transferidos para o financiamento das empresas, sendo identificados como simples transferências entre os investidores. A função essencial do mercado secundário é dar liquidez ao mercado primário, viabilizando o lançamento de ativos financeiros.

Na verdade, a existência de um mercado secundário mais dinâmico somente é possível mediante certas condições de liquidez para as ações emitidas, as quais são verificadas fundamentalmente por meio das transações nas Bolsas de Valores. Dessa forma, é nas Bolsas

que uma ação, representativa de determinado empreendimento, tem seu desempenho avaliado pelos investidores, assumindo maior demanda e, conseqüentemente, maior liquidez, em função do sucesso econômico alcançado pela empresa emitente.

2.10 Abertura de capital

O financiamento de uma empresa mediante recursos próprios pode se desenvolver pela retenção de seus resultados líquidos (autofinanciamento) e, principalmente, pelo lançamento de ações ao público. A colocação de ações no mercado pode ocorrer tanto pela emissão de novas ações pela empresa, como pela oferta pública de ações detidas por um investidor.

O lançamento público de novas ações, conhecido também por *underwriting*, é uma operação na qual a sociedade emitente coloca seus valores mobiliários no mercado primário, mediante a intermediação de uma instituição financeira. Nesse esquema, a sociedade atrai novos sócios pela subscrição e integralização de novas ações (capital), cujos recursos financeiros são direcionados para financiar seu crescimento.

O lançamento de ações no mercado pode ocorrer, também, pela oferta de lote de ações possuídas por um acionista (ou grupo de acionistas). Essa modalidade de oferta pública constitui-se, em verdade, em uma distribuição secundária de ações conhecida por *block trade*. Não resulta na entrada de novos recursos à empresa, restringindo-se os resultados financeiros da operação no âmbito dos investidores.

Essa transação secundária envolvendo um expressivo lote de ações é adotada geralmente em processos de transferência de controle acionário no mercado, em que um grupo controlador de uma sociedade coloca à venda as ações detidas em carreira, portanto, fora da negociação normal do mercado. A operação, ainda, ganhou maior notoriedade nos processos de privatização de empresas públicas executadas pelo Governo brasileiro nas décadas de 80 e 90. O controle público foi oferecido ao mercado por meio de leilões em Bolsas de Valores, constituindo-se em excelentes alternativas de investimento.

2.11 Mercado Secundário – Bolsa de Valores

O mercado secundário registra unicamente a transferência de propriedade dos títulos e valores mobiliários, não determinando variações diretas sobre os fluxos de recursos das sociedades emitentes. Uma empresa somente obtém novos recursos por meio de subscrição de capital no mercado primário, não se beneficiando diretamente das negociações do mercado secundário. O funcionamento do mercado secundário ocorre principalmente nas Bolsas de Valores, as quais viabilizam aos investidores a oportunidade de realizarem novos negócios com títulos anteriormente emitidos.

As Bolsas de Valores constituem-se em associações civis sem fins lucrativos, cujo objetivo básico é o de manter um local em condições adequadas para a realização, entre seus membros, de operações de compra e venda de títulos e valores mobiliários.

É preocupação das Bolsas de Valores, ainda, a preservação dos valores éticos nas negociações realizadas em seu âmbito, e a divulgação rápida e eficiente dos resultados de todas as transações realizadas.

Outros objetivos são:

- Promover uma segura e eficiente liquidação das várias negociações realizadas em seu ambiente;
- Desenvolver um sistema de registro e liquidação das operações realizadas;
- Fiscalizar o cumprimento, entre seus membros e as sociedades emissoras dos títulos, das diversas normas e disposições legais que disciplinam as operações em bolsa.

As Bolsas de Valores são supervisionadas pela CVM – Comissão de Valores Mobiliários, atuando como uma entidade fiscalizadora do mercado de ações. São membros das Bolsas de Valores as Sociedades Corretoras que tenham adquirido título patrimonial.

2.12 Mercado de Derivativos e a BM&F

Podem-se definir derivativos como

instrumentos financeiros que se originam (dependem) do valor de um outro ativo, tido como ativo de referência. Um contrato derivativo não apresenta valor próprio, derivando-se do valor de um bem básico (commodities, ações, taxas de juros, etc.). (ASSAF NETO, 2001, p.331).

Em uma definição mais estreita, derivativos são instrumentos financeiros que utilizam os mercados futuros e de opções principalmente para gerenciar riscos. Seu valor depende (*ou deriva*) de outros ativos aos quais eles se referem. São contratos que refletem o comportamento futuro da bolsa de valores, da taxa de juros, do valor da moeda.

Um exemplo bem clássico e simples de derivativos pode ser a operação executado por um importador brasileiro que terá de remeter aos Estados Unidos, num prazo de um mês, a quantia de um milhão de dólares. Com o risco de uma possível alta do dólar, o importador faz uma operação de proteção contra a variação cambial, por exemplo: compra hoje aquele um milhão de dólares para pagar em um mês, acertando no momento a cotação. Se o dólar subir, então ele ganha; se cair, então ele perde a diferença.

Os derivativos podem ser negociados tanto no mercado primário como no secundário. Eles podem ser utilizados para quatro finalidades básicas: proteção, alavancagem, arbitragem e especulação.

Entre os tipos de derivativos destacam-se as opções, que fornecem um direito de comprar ou vender um ativo. Se a opção for de compra (*call*), o detentor possui o direito de comprar, se a opção for de venda (*put*), possui o direito de vender. O comprador de uma opção de compra, ou titular dessa opção, tem o direito de comprar certa quantidade de ações, a um preço pré-fixado até uma data determinada. O vendedor de uma opção de compra (o lançador de opção) fica com a obrigação de vendê-la. O titular tem sempre os direitos, e o lançador sempre as obrigações.

O mercado de opções negocia esses direitos de compra ou de venda, mas não as ações diretamente. Os direitos são negociados por um preço, o prêmio, que é o valor pago pelo titular e recebido pelo lançador. As obrigações assumidas pelo lançador podem ser extintas de três formas: pelo exercício da opção pelo titular; pelo seu vencimento sem que tenha havido o exercício ou pelo encerramento (reversão) da posição. Os lançadores são obrigados a depositar garantias de forma a que se dê o cumprimento das obrigações assumidas. O valor da garantia corresponde ao dobro do valor do prêmio médio do mercado ou do seu valor arbitrado pela bolsa, sendo que essas posições margeadas terão que manter o nível até o vencimento, com os ajustes sendo calculados diariamente.

Esses derivativos são negociados no Mercado Futuro de Ações, que é o mercado no qual se negociam com datas de liquidação futura, durante o horário de funcionamento da BOVESPA, em lotes padrão nela já negociado, as ações autorizadas para tal. Cada uma das partes envolvidas, em um contrato no mercado futuro de ações da BOVESPA, se relaciona com a Companhia Brasileira de Liquidação e Custódia – CBLC, e não diretamente com a outra parte do contrato. O encerramento total ou parcial de um contrato, antes do dia de seu vencimento, também é conhecido reversão da posição de um contrato futuro.

No Brasil as negociações de futuros aconteciam na Bolsa Mercantil de Futuros – BM&F, criada em de 1985, com operações a partir de 1986. Em 1991 a Bolsa de Mercadorias de São Paulo (BMSP) e a BM&F se unem criando a Bolsa de Mercadorias & Futuros, mantendo a mesma sigla – BM&F.

Em resumo o mercado futuro da BOVESPA traz a vantagem da maior liquidez, da liquidação antecipada a qualquer tempo antes da data de vencimento e a possibilidade de venda a descoberto.

2.13 Home Broker e After Market

Ao final de 1999 foram implementados no Brasil os conceitos do *Home Broker* e do *After Market*. No primeiro, os clientes passam a operar eletronicamente, via internet,

através dos sites das corretoras de valores, comprando e vendendo ações. No segundo, estende-se o horário do pregão eletrônico que passa a funcionar até as 22 horas, para atender o *Home Broker*. Além do horário, algumas regras iniciais foram estabelecidas de forma a garantir o fluxo e a segurança das operações, a saber:

- a) Só podem ser negociadas ações no mercado à vista e no mercado de opções;
- b) O limite de ordens é de R\$ 100 mil por investidor; e
- c) A cada intervalo de 15 minutos a BOVESPA controla o limite operacional de cada corretora.

2.14 Mercados Eficientes

A hipótese dos mercados eficientes proposta por Fama (1970) afirma que os preços se alteram de forma aleatória, ou seja, um mercado é eficiente quando não há autocorrelação entre os preços presentes e os preços passados. A definição de mercados eficientes diz que os preços são reflexos de toda a informação disponível, e esta a todos os investidores. Os investidores, por sua vez, tomam decisões baseando-se nas informações disponíveis. Isso explica as oscilações quando acontece um choque inesperado decorrente de um evento político, econômico ou incertezas quanto ao futuro.

A hipótese de mercados eficientes, EMH, formalizada por Fama (1970), relata a aleatoriedade dos preços dos ativos, onde eles dependeriam exclusivamente de seus preços passados. Com isso, um mercado seria eficiente se apresentasse um comportamento aleatório nos preços, e ineficiente se apresentasse autocorrelação entre as variáveis (preço presente e preços passados), ou seja, relações de dependências não-aleatórias.

A fraca hipótese EMH de Fama (1970) vem sendo muito contestada entre os economistas. Um argumento interessante de Lim e Brooks (2006a) refere-se ao esgotamento

quase que imediato dos lucros pelo processo de arbitragem⁷, em um mercado teoricamente eficiente nos moldes de Fama. Ora, com os preços previsíveis aos agentes de mercado, os mesmos na busca de lucros comercializariam um determinado ativo até o ponto de lucro zero. Dessa forma, a EMH prega a ausência de previsibilidade dos preços dos ativos de mercados financeiros (Lim e Brooks (2006a)).

A aleatoriedade dos preços está em concordância com a existência de um comportamento, conforme a hipótese de eficiência de mercado. Já a não-aleatoriedade, ou previsibilidade dos preços está ligada a um comportamento de dependência linear ou não-linear. Em particular, o aspecto da presença de eventos não-lineares na estrutura de mercado financeiro estabelece um potencial de previsão que tem gerado uma empolgação considerável na comunidade econométrica, o que estabeleceu uma explosão no desenvolvimento de modelos não-lineares (Lim e Hinich, 2005b). A aleatoriedade nos preços em determinados períodos específicos, de acordo com a EMH, é fruto de uma resposta imediata do mercado às novas informações surgidas. No entanto, após algum choque inesperado de algum evento político, ou de informações avassaladoras não esperadas, o processo de reajustamento nos preços dos ativos reage através de um comportamento de dependência não-linear, ocasionado pela demora da resposta dos agentes, fruto da cautela e precaução por parte do mercado (Antoniou *et al.*, 1997; Brooks *et al.*, 2000).

Portanto, o que se observa é que a comunidade econométrica encontra-se bastante interessada no desenvolvimento de novas técnicas que permitam estabelecer previsões de séries temporais financeiras, especialmente, que tenham potencial de previsibilidade dos comportamentos de impactos não lineares, frequentemente presentes nas séries financeiras. Entre as técnicas com maior potencial de simulação de efeitos não lineares encontram-se as RNAs.

Assim, este estudo parte do princípio de que a hipótese de mercado eficiente não é mantida e que existem relações entre os preços presentes e os preços passados, o que dá

⁷ Conforme Sutcliffe (2006, p. 53), “*the Arbitrage Process is a fundamental economic concept. If there are two identical products, the possibility of arbitrage requires them to have as identical price. If not, arbitrageurs will buy the cheap product and sell it as the dear product. Such action will raise the price of the cheap product and lower the price of the dear product, so equalizing prices and eliminating the arbitrage opportunity. In finance, arbitrage is viewed as the simultaneous purchase of one asset against the sale of the same or equivalent asset from zero initial wealth to create a riskless profit due to price discrepancies. Thus, arbitrage is riskless, requires zero wealth and so can be of arbitrary scale.*”

suporte para um estudo de modelação de séries temporais financeiras, com capacidade de simular fenômenos não lineares. Este fator fornece subsídios para a implementação de um algoritmo baseado nas RNAs, com a finalidade de estabelecer previsões de ativos de mercado financeiro, com forte característica de efeitos não lineares.

3 REDES NEURAIAS PARA PREVISÕES DE SÉRIES TEMPORAIS

Pode-se definir série temporal como uma seqüência de dados de uma determinada variável alocada num período. Diversos fenômenos científicos podem ser classificados como séries temporais. Na economia é possível identificar inúmeras séries temporais: PIB, inflação, taxa de juros, taxa de câmbio, etc.

Uma série temporal pode ser representada como uma seqüência de dados discretos, conforme Equação (1) abaixo.

$$X_t = \{x_1, x_2, x_3, \dots, x_t\} \quad (1)$$

onde cada valor de x_t é a representação de um valor num dado momento, de acordo com a temporalidade da série em estudo.

Nota-se o crescimento nos últimos anos de diversas tentativas de fazer previsões do mundo econômico. Não só economistas, mas também matemáticos e estatísticos tem procurado desenvolver modelos para dirimir as dúvidas quanto ao rumo das economias. Sabe-se, contudo, que esta tarefa é muito difícil, pois as economias cada vez mais globalizadas são um desafio para previsão dos sistemas cada vez mais complexos. É nesta lógica que surge o estudo das séries temporais. Os modelos de auto-regressão, AR (autoregressive), MA (moving average), ARMA (autoregression moving average) e Box-Jenkis (1970) entre outros, tem sido utilizados para previsões nos mercados financeiros e de outras séries temporais.

Para o melhor entendimento das séries temporais, faz-se necessário a distinção de alguns conceitos como tendência determinística, tendência estocástica e volatilidade na variância.

Uma série temporal é dita estacionária quando a média e a variância são constantes ao longo do tempo e quando o valor da covariância entre dois períodos de tempo depende apenas

da distância, do intervalo ou da defasagem entre os dois períodos de tempo, e não do próprio tempo em que a covariância é calculada.

No caso de uma tendência determinística, os desvios em torno da linha de tendência (que representa a média não estacionária) são puramente aleatórios e diminuem rapidamente, não contribuindo para o desenvolvimento de longo prazo da série temporal.

Para as séries temporais com tendência estocástica, os desvios em torno da linha de tendência (que representa a média não estacionária) alteram o desenvolvimento de curto e longo prazo da série temporal. É fundamental, também, definir o conceito de volatilidade na variância, ele nos mostra se a série temporal é estacionária (variância não se altera com o tempo) ou é não estacionária (variância se altera com o tempo).

A partir dos conceitos de tendência estocástica e determinística apresentadas pode-se definir os tipos de processos de regressão. O processo auto-regressivo (AR) é aquele no qual o valor da variável dependente no período atual sofre impacto do seu valor no período anterior somado a um termo aleatório e os valores da variável dependente são expressos como desvios de seu valor médio. No processo de média móvel (MA) o valor da variável dependente no período atual é igual a uma constante mais uma média móvel dos termos de erro presentes e passados. Já no processo auto-regressivo e de médias móveis (ARMA), a variável dependente tem características tanto do processo auto-regressivo (AR) quanto do processo de média móvel (MA).

Os modelos AR, MA e ARMA não devem ser utilizados no mercado financeiro, pois muitas vezes as séries temporais financeiras apresentam o fenômeno de aglomeração de volatilidade, ou seja, períodos com grandes variações seguidos de períodos de relativa calma. Franses (1998, p. 155) observa que

uma vez que tais dados [de séries temporais financeiras] refletem o resultado do comércio entre compradores e vendedores, por exemplo, no mercado de ações, várias fontes de notícias e outros eventos econômicos exógenos podem causar um impacto sobre o padrão da série temporal de preços de ativos. Dado que notícias podem levar a várias interpretações, e dado também que eventos econômicos específicos como uma crise do petróleo, podem durar por algum tempo, frequentemente notamos que grandes observações positivas ou negativas em séries temporais financeiras tendem a aparecer em aglomerados. (*apud* GUJARATI, D. 2006, p. 856).

Para modelagem dessas séries temporais com fenômenos de aglomeração é necessário desenvolver modelos ARCH (autoregressive conditional heteroscedasticity) e GARCH (generalized autoregressive conditional heteroscedasticity). Porém não está no escopo deste

estudo detalhar esses modelos. Gujarati (2006, p. 834) mostra detalhadamente o funcionamento desses modelos para previsão de séries temporais.

A análise aqui compreende, portanto, o estudo das redes neurais artificiais e sua capacidade de previsão de séries temporais no domínio temporal, comparando-se com os valores reais dos preços da ação PETR4.

3.1 Aplicações

As aplicações de redes neurais são inúmeras. Muitos recebem sua primeira introdução lendo a respeito das técnicas no prognóstico de mercados financeiros. Grupos de investimento conhecidos utilizam redes neurais para analisar pelo menos uma parte do mercado financeiro e fazerem suas seleções.

O reconhecimento ótico de caracteres (OCR) é outro tipo de aplicação que já existe e está crescendo. Outras aplicações bem sucedidas das técnicas de redes neurais artificiais são: análise de pesquisa de mercado, controle de processos industriais, aplicações climáticas, e identificação de fraude de cartão de crédito. Um banco americano chamado Mellon Bank instalou um sistema de detecção de fraudes de cartão de crédito implementado com técnicas de redes neurais e os prejuízos evitados pelo novo sistema conseguiram cobrir os gastos de instalação em seis meses. Vários outros bancos começam a utilizar sistemas baseados em redes neurais para controlar fraudes de cartão de crédito. (Refenes (1993)).

Outro exemplo, da utilização de redes neurais para melhoria na tomada de decisões é no diagnóstico médico. Em seu aprendizado são submetidos uma série de diagnósticos de pacientes, de várias características, com vários sintomas e os resultados de seus testes. Também serão fornecidos os diagnósticos médicos para cada doença. Então quando forem apresentados os dados de um novo paciente, com seus sintomas, a rede fornecerá um diagnóstico para os novos casos. Isto essencialmente criará um sistema com o conhecimento

de vários médicos, e fornecerá um diagnóstico inicial em tempo real a um médico. É importante mencionar que com isso o que se pretende é implementar uma ferramenta de auxílio ao médico, e não um programa que o substitua. (Barreto (2000)).

Outras aplicações são: (i) análise e processamento de sinais; (ii) controle de processos; (iii) robótica; (iv) classificação de dados; (v) reconhecimento de padrões em linhas de montagem; (vi) filtros contra ruídos eletrônicos; (vii) análise de imagens; (viii) análise de voz; (ix) avaliação de crédito; (x) análise de aroma e odor. Neste trabalho utilizou-se redes neurais para previsão do preço futuro de fechamento da ação da Petrobras (PETR4), principal papel de negociação da BOVESPA.

3.2 Definição de Redes Neurais

Haykin (2001, p. 24) afirma que rede neural é

um processador maciçamente paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela assemelha-se ao cérebro em dois aspectos: (1) o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; (2) forças de conexão entre neurônios (os pesos sinápticos) são utilizadas para armazenar o conhecimento adquirido.

A base de uma rede neural são os neurônios artificiais que “copiam” o funcionamento dos neurônios biológicos do cérebro humano. As entradas (*inputs*) para os neurônios chegam através dos dendritos. Esses por sua vez também podem agir como saídas (*outputs*) interconectando os neurônios. Matematicamente, os dendritos seriam o somatório. Os axônios, por outro lado, são encontrados somente nas células de saída, eles tem função sináptica e quando ativos transmitem um sinal elétrico. São responsáveis também por conectar os demais neurônios através de seus dendritos. O cérebro humano dispõe de aproximadamente 10^{10} neurônios interconectados, criando uma imensa rede de processamento paralelo. (Jackson *et al.* 1990, p. 68). A Figura (1) ilustra um neurônio humano.



Figura 1. Neurônio biológico.
Fonte: desenvolvido pelo autor.

O neurônio artificial foi desenvolvido baseado no neurônio humano, a Figura (2) mostra suas características. As entradas W_{i1} , W_{i2} e W_{i3} mostradas na Figura (2) são multiplicadas pelos respectivos pesos sinápticos e então são somadas e processadas por uma função de ativação. A função de ativação avalia o resultado obtido de acordo com os limites definidos e valida ou não o teste, para depois calcular as saídas desejadas $F(\text{NET})$. As funções de ativação estão descritas no Anexo A detalhadamente.




Figura 2. Neurônio Artificial.
Fonte: adaptado de Abelém (1994).

Outros conceitos que são fundamentais para o entendimento do funcionamento e, conseqüentemente, para a implementação das RNAs (redes neurais artificiais), são descritos abaixo:

- a) Algoritmo, que se caracteriza como uma rotina para um processo computacional, consistindo uma série de operações primitivas, interconectadas devidamente, sobre um conjunto de objetos;
- b) Perceptron, que é uma rede com os neurônios dispostos em camadas. Os neurônios aprendem a responder um para verdadeiro e zero para falso, de acordo com as entradas;
- c) Redes “*feedforward*”, constituídas por *perceptrons* de várias camadas, onde os nós estão diretamente conectados as entradas e saídas, gerando a retroalimentação.

Freitas (2001) destaca três conceitos fundamentais para o entendimento do processo de aprendizagem:

- d) Algoritmo de treinamento ou algoritmo de aprendizado, constituído por um conjunto de procedimentos que são utilizados para ajustar os parâmetros das redes neurais, de maneira que possam realizar determinadas funções;
- e) Numero de épocas, que caracteriza o número de vezes que os padrões de treinamento serão apresentados às redes neurais, a fim de que se faça a atualização dos pesos; e
- f) Taxa de aprendizado, que controla a intensidade das alterações dos pesos – uma alta taxa de aprendizado acelera o processo, mas pode reduzir a capacidade de generalização da rede neural.

A rede neural artificial é um sistema de neurônios ligados por conexões sinápticas e divididos em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos ou *hidden* (ocultos) e neurônios de saída, que se comunicam com o exterior. A forma de arranjar perceptrons em camadas é denominada de *multilayer perceptron*. O *multilayer perceptron* foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico. Um único perceptron ou uma combinação das saídas de alguns perceptrons poderia realizar uma operação XOR (operação lógica em dois operandos que resulta em um valor lógico verdadeiro), porém seria incapaz de aprendê-la. Para isto são necessárias mais conexões, os quais só existem em uma rede de perceptrons

dispostos em camadas. Os neurônios internos são de suma importância na rede neural, pois se provou que sem estes se torna impossível a resolução de problemas linearmente não separáveis. (Smolensky, Mozer and Rumelhart 1996, p. 395). Em outras palavras, pode-se dizer que uma rede é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma RNA (rede neural artificial) vem das interações entre as unidades de processamento da rede.

A Figura (3) ilustra a topologia de uma rede MLP (*multilayer perceptron*). Percebe-se que existem ligações entre cada neurônio de entrada e a camada escondida, estes por sua vez são conectados à camada de saída para calcular os resultados esperados. A principal vantagem em se utilizar as redes *Multilayer Perceptron* advém do fato deste tipo de topologia ser capaz de realizar prognósticos confiáveis sobre valores futuros de séries temporais.




Figura 3. Rede Neural Artificial Multicamada.

Fonte: adaptado de Abelém (1994).

Os parágrafos acima mostram que existem diversos parâmetros a serem envolvidos na construção de uma rede neural. Esses parâmetros são mostrados na Figura (4) e os comentários são desenvolvidos brevemente na seção 3.3 a seguir.

3.3 Fatores que Influenciam o Desempenho das RNAs

As RNAs são influenciadas por três fatores: (i) convergência; (ii) generalização e (iii) escalabilidade.

A convergência está relacionada ao aprendizado da RNA de identificar padrões num conjunto de dados, definido no procedimento de treinamento. A convergência mostra se o processo de treinamento é capaz de identificar os padrões não lineares numa série de dados, que será fundamental para previsões mais precisas. Esse fator merece muita atenção, pois se a rede não consegue atingir uma boa convergência, é porque não aprendeu as relações existentes e, conseqüentemente, não atingirá bons resultados na fase dos testes.

A generalização é a etapa onde as RNAs reconhecem os padrões não existentes nos dados de treinamento. Esse aspecto é determinante para identificar os valores fora de padrão. Não há um consenso que mostre as condições ideais para encontrar boas generalizações. Refenes (1991) afirma que a probabilidade de generalizações corretas depende do número total de redes consideradas, do conjunto de RNAs que fornecem boas soluções e do número de exemplos do treinamento. Geralmente, a redução do número de conexões da rede melhora os resultados de generalização. Porém se deve evitar uma redução grande, que pode empobrecer o resultado final da previsão.

A escalabilidade, que une os dois conceitos mencionados, convergência e generalização, mostra a capacidade de ajuste dos parâmetros da RNA com objetivo de convergir e generalizar bem. Uma rede eficiente deve ser grande o suficiente para identificar as relações entre as variáveis, e ao mesmo tempo pequena o bastante para generalizar bem. (Abelém 1994, p. 42).

Para controlar esses fatores determinantes do desempenho, é necessário escolher adequadamente os parâmetros da rede. Esses parâmetros de uma rede neural são apresentados na Figura (4) e brevemente explicados na sequência.

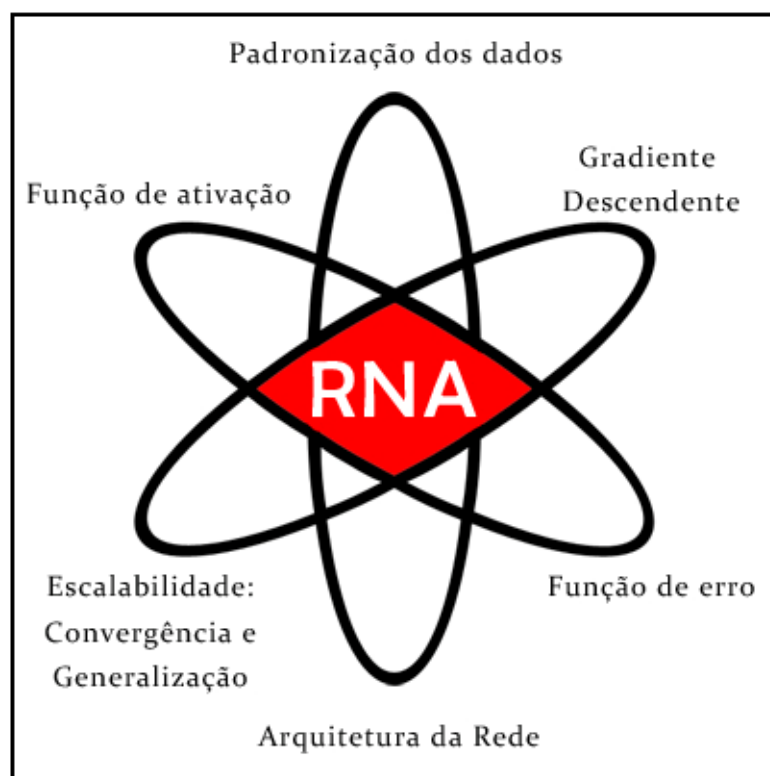


Figura 4. Parâmetros de uma rede neural.

Fonte: desenvolvido pelo autor.

A padronização dos dados deve ser muito bem adequada ao modelo em questão. Dados muito ruidosos, como é o caso das séries temporais financeiras, precisam ser ajustados através de técnicas como a normalização dos dados. A Figura (7) evidenciada no capítulo 4 mostra as entradas normalizadas entre o intervalo $[-1,1]$, que é fundamental para a rede ler os dados de forma adequada de acordo com a função de ativação escolhida. As funções de ativação mais utilizadas são mostradas no Anexo A, ao final deste trabalho.

O termo gradiente descendente, um algoritmo desenvolvido para identificar o mínimo local, deve também ser bem dimensionado. Azoff (1993) e Refenes (1991) destacam o uso do termo de “momentum” e da segunda derivada para reduzir o tempo de treinamento e o risco de mínimos locais, evitando erros de oscilações na rede. Outro fator importante que influencia o gradiente descendente é a taxa de aprendizado. As altas taxas de aprendizado implicam em grandes mudanças nos pesos sinápticos, reduzindo o tempo de treinamento e evitando os mínimos locais, podendo porém saturar o treinamento e reduzir a eficiência do processo de aprendizado; enquanto baixas taxas de aprendizado tornam o treinamento lento e aumentam a probabilidade de falsos mínimos locais.

O parâmetro função de erro informa qual a convergência da RNA, ou seja, mostra se a rede tem capacidade de aprendizado durante o treinamento. Geralmente a função utilizada é a MSE (Mean Square Error) definido conforme a Equação (2) abaixo, onde n é o número de padrões apresentados.

$$MSE = \frac{1}{n} \sum_{i=1}^n (alvo_i - saída_i)^2 \quad (2)$$

Entre os fatores expostos, a escolha da arquitetura da rede é o fator determinante de desempenho da RNA. Para alcançar bons resultados de previsão é necessário estudar as variáveis de entrada que determinam as relações do sistema em questão. Após a escolha ideal dessas entradas é fundamental definir o número de conexões entre os neurônios adequadamente. Existem alguns métodos propostos por Hertz (1991) e Refenes (1991), como a redução de neurônios redundantes e do compartilhamento de pesos, e também o uso de um algoritmo genético, proposto por Miller (1989), porém nenhum deles chegou a bons resultados. Portanto, a escolha ideal da arquitetura é um método de tentativa e erro que depende muito da habilidade do projetista em escolher as variáveis ideais e ajustá-las ao modelo.

3.3 Redes neurais com *Backpropagation*

As redes com algoritmo do tipo *backpropagation* visam minimizar o termo de erro entre a saída da rede neural e o valor real de saída desejado. O termo de erro é calculado pela comparação entre a saída e o resultado desejado e depois é realimentado através da rede fazendo com que os pesos sinápticos se alterem em um esforço para minimizar erro. O processo é repetido até que o erro atinja um valor mínimo.

Com o objetivo de ilustrar um procedimento de uma rede neural do tipo *backpropagation*, apresenta-se um exemplo simples, conforme Figura (5). Esta figura é constituída por dois nós de entrada, uma única camada de neurônios oculta, com um único neurônio, culminando num nó de saída. O que se pretende com este exemplo é ilustrar o procedimento de reajuste dos pesos, pela metodologia de *backpropagation*.

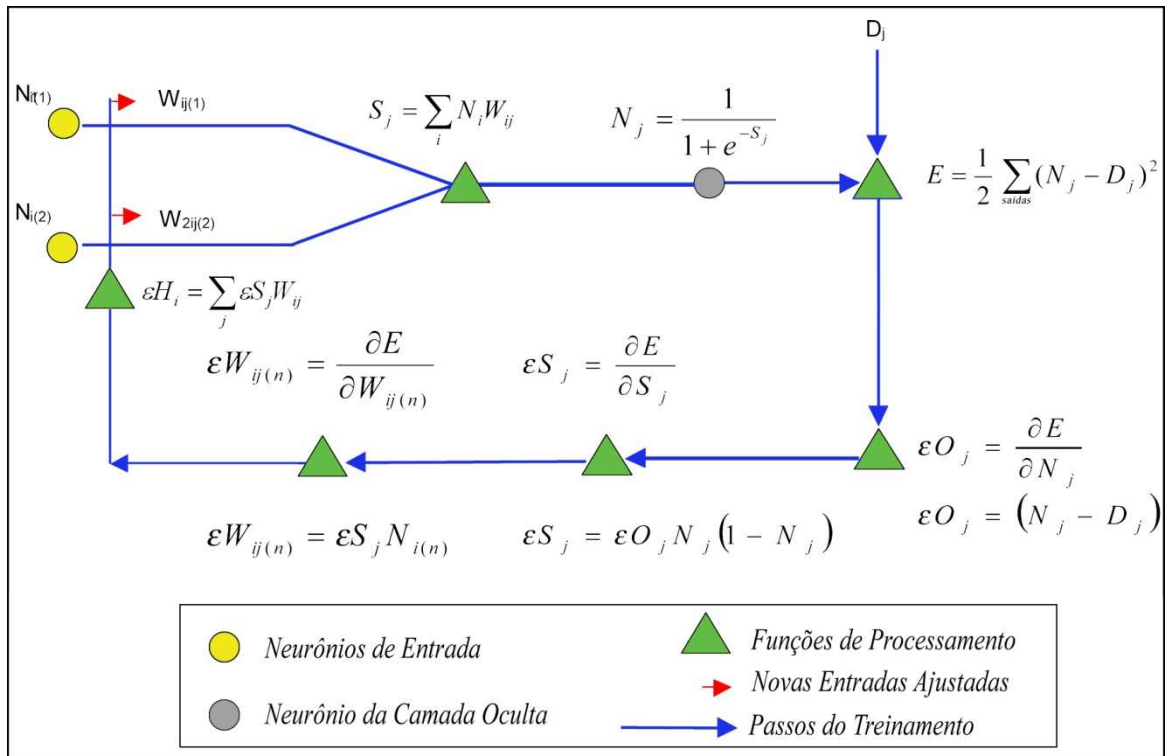


Figura 5. Rede Neural Artificial usando *Backpropagation*.

Fonte: desenvolvido pelo autor.

Portanto, conforme desenho esquemático apresentado na Figura (5) pode-se caracterizar que o desenvolvimento da rede neural exemplificada é constituída pelos seguintes passos:

Primeiro deve ser evidenciado que a rede utiliza a Equação (3), abaixo, para atualização do W_{ij} que é o peso de um dado nó N_i referente ao nó atual N_j , onde o sub-índice t refere-se ao número de vezes em que a rede foi atualizada e λ refere-se à taxa de aprendizagem, a ser fixada no código computacional preparado para simular a série de tempo tida como meta. Essa taxa de aprendizagem controla o peso e suas alterações.

$$W_{ij,(t+1)} = W_{ij,t} + (\lambda)(\varepsilon W_{ij})(N_i) \quad (3)$$

O valor total das entradas de cada nó é descrito pela Equação (4) e também mostrado na Figura (5), onde S_j é a soma de todas as entradas de cada nó, N_i é a saída do nó anterior e W_{ij} é o peso das conexões entre o i -ésimo nó da camada anterior.

$$S_j = \sum_i N_i W_{ij} \quad (4)$$

As saídas são transformadas usando uma função de ativação, e o total da saída do nó é representado pela Equação (5) e mostradas na Figura (5).

$$N_j = \frac{1}{1 + e^{-S_j}} \quad (5)$$

O erro global de cada teste é representado pela Equação (6) e mostrado na Figura (5), onde D_j é a saída desejada para o nó j .

$$E = \frac{1}{2} \sum_{saídas} (N_j - D_j)^2 \quad (6)$$

A partir do momento em que o erro foi calculado, esse valor retorna como entrada na rede para diminuir o erro. As equações diferenciais parciais necessárias para as alterações dos pesos são mostradas abaixo nas Equações (7 a 10) e também na Figura (5).

Primeiramente o termo de erro para cada nó O_j deve ser calculado. É necessário identificar a variação do erro com a respectiva variação em cada saída de cada nó. Esse cálculo é simplificado através da Equação (7).

$$\varepsilon O_j = (N_j - D_j) \quad (7)$$

Após esse cálculo, determina-se a variação do erro em relação às mudanças dos valores de entrada. Isso é feito determinando quanto a Equação (6) se altera em relação às mudanças do total da entrada do nó (Equação (4)). A Equação (8) simplificada mostra essa relação.

$$\varepsilon S_j = \varepsilon O_j N_j (1 - N_j) \quad (8)$$

O próximo passo é calcular os pesos ajustados para W_{ij} da camada atual N_i para o nó atual N_j . Esse cálculo é dado pela Equação (9).

$$\varepsilon W_{ij} = \varepsilon S_j N_i \quad (9)$$

Finalmente essa operação é repetida para todos os nós abaixo, permitindo que os nós das camadas ocultas interajam com o nó de saída. Todos os erros de todas as camadas escondidas são somados. Além disso, o erro de cada nó escondido é o quanto variou o erro do nó superior em relação a quanto variou o erro do nó oculto. A Equação (10) é usada para calcular as atualizações dos pesos de cada nó N_j , onde j representa os nós da camada escondida.

$$\varepsilon H_i = \sum_j \varepsilon S_j W_{ij} \quad (10)$$

Desta forma o erro da rede é propagado recursivamente para trás de toda a rede e todos os pesos são ajustados para minimizar o erro global da rede.

De forma geral, a operação de cada nó da rede é demonstrada de forma intuitiva na Figura (6). A ideia básica é que os valores são atualizados de acordo com cada nova entrada de cálculo para cada nó, somados e então recalculados. Se o erro ainda não tiver atingido um número máximo de épocas definido, os valores são recalculados.

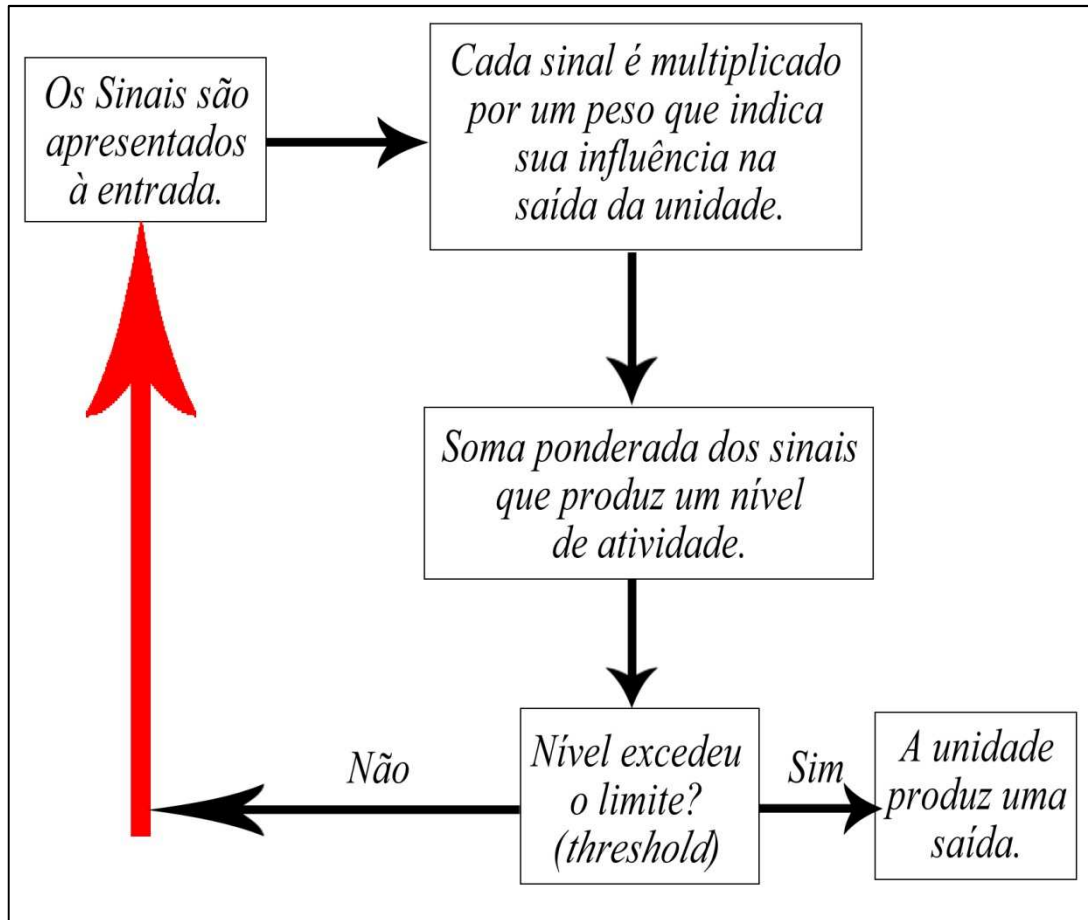


Figura 6. Funcionamento de uma RNA com Backpropagation.

Fonte: desenvolvido pelo autor.

Como os cálculos são complexos torna-se inviável montar uma rede neural sem o auxílio de um software específico para esse fim. Neste trabalho, esse processo de treinamento foi feito através do software MATLAB r2009a, criando-se um arquivo com mais de 300 linhas de programação em C++, que organiza os dados de entrada, define as entradas (*inputs*), o alvo (*target*), o nível de erro e o número máximo de épocas de treinamento para a rede convergir no valor ideal. A seção seguinte mostra os detalhes do desenvolvimento do modelo.

4 REDE NEURAL IMPLEMENTADA E RESULTADOS

Como mostrado no capítulo 3, sabe-se que o processo de desenvolvimento de uma rede neural eficaz é exaustivo, pois se trata de um método de tentativa e erro. Definir os parâmetros da RNA depende quase tão somente da habilidade do projetista em analisar os dados e definir quais são os mais importantes dentro do objetivo a ser alcançado. E como este trabalho objetiva montar um modelo de previsão do preço futuro de fechamento da ação PETR4, torna-se ainda mais complexo na medida em que as leis que regem esse tipo de mercado não são bem definidas, pois os preços das ações são, de certa forma, o reflexo das decisões dos agentes que são influenciados por diversos fatores (informações disponíveis, expectativas, previsões, etc.).

Porém, por se tratar de um método matemático, os números podem refletir com grande propriedade as oscilações do mercado através das redes neurais. Não se deve, todavia, analisar somente esses resultados da rede neural para montar previsões, deve-se utilizá-los para tomada de decisão juntamente com indicadores técnicos e análises fundamentalistas, reduzindo os riscos das operações.

O experimento aqui realizado utilizou o software MATLAB r2009a como ferramenta para desenvolvimento da RNA utilizando a ferramenta *Editor*. O programa desenvolvido possui mais de 300 linhas de comando em linguagem C++, nela encontram-se os procedimentos para montagem das matrizes de entrada a partir da leitura de dados em planilha Excel, também estão os demais procedimentos, como a definição da matriz alvo, todos os parâmetros da rede neural, treinamento e simulação. Também se utilizou a ferramenta *Plot Tools* para montar os gráficos de previsão.

4.1 Definições das variáveis de entrada e saída

Como proposto na metodologia, as entradas da rede são os preços de fechamento diários da ação PETR4, fechamento do IBOVESPA e volume das operações. O período escolhido foi de 04/01/1999 a 31/05/2010. Além desses dados obtidos no *software* Economática, foram utilizados índices técnicos e funções de normalização para tratamento dos dados. As fórmulas dos indicadores utilizados são apresentadas abaixo.

a) IN – Índice de Negociabilidade:

$$IN = \sqrt{\frac{ni}{N} \times \frac{vi}{V}} \quad (11)$$

Onde:

ni = número de negócios da ação “i” no mercado à vista;

N = número total de negócios da BOVESPA;

vi = volume financeiro da ação “i” no mercado à vista;

V = volume financeiro total do mercado à vista da BOVESPA.

O índice de negociabilidade mede a importância da ação no mercado quanto ao volume financeiro e número de negócios. Quanto maior for o resultado, maior liquidez tem essa ação. Esse índice é utilizado na metodologia de cálculo das ações que compõe o índice BOVESPA (IBOVESPA).

b) ROC(n) – *Rate of Change*:

$$ROC(n) = \frac{[p(t) - BA(t - n)]}{[p(t) + BA(t - n)]} \quad (12)$$

BA é a média móvel das últimas cinco cotações, $p(t)$ é o valor da ação no dia t e n é o número de dias escolhido para indicar o grau de mudança. Esse indicador considera o grau de mudança médio dos n dias passados, ou seja, mostra que as oscilações médias passadas tem

uma relevância na formação dos preços futuros. Utilizaram-se o ROC3 e o ROC10, para 3 e 10 dias, respectivamente.

c) $RSI(t)$ – *Relative Strength Index*;

$$RSI(t) = 100 - \frac{100}{1 + RS(t)} \quad (13)$$

$RS(t)$ é a divisão da média dos valores que fecharam em alta ou em baixa num período de t dias. Quando o resultado desse indicador é maior que 50 significa que o mercado está em tendência de alta, do contrário está em tendência de baixa. Utilizou-se 14 para o valor de t .

d) $\%R(t)$ – *Percentual R*;

$$\%R(t) = 100 \left(\frac{\max(t) - \text{preço}(n)}{\max(t) - \min(t)} \right) \quad (14)$$

$\max(t)$ e $\min(t)$ são os valores máximos e mínimos dentro de um período t , o valor $\text{preço}(n)$ corresponde ao valor de fechamento da ação no dia atual. Utilizou 14 para o valor de t . Valores baixos significam que os preços estão perto do valor máximo, próximo a resistência; enquanto valores altos significam que os preços estão próximos do suporte, do valor mínimo.

e) Normalização dos dados para o intervalo $[-1,+1]$ através da função $\text{mapminmax}(y)$ do MATLAB.

$$\text{mapminmax}(y) = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{(x_{\max} - x_{\min}) + y_{\min}} \quad (15)$$

Em algumas previsões que não apresentaram tendência futura clara, utilizou-se o cruzamento de médias móveis simples de 4, 9 e 18 dias, conforme proposto por Murphy (1999).

Todos os valores de entrada (*input*) e alvo (*target*) foram normalizados no intervalo -1 e 1 através da função mapminmax . Este procedimento é obrigatório, pois a função de ativação

usada na RNA (tan-sigmoid⁸) processa somente valores entre -1 e +1. A Tabela 1 mostra os últimos 10 valores de entradas da rede sem normalização. A Tabela 2 mostra os últimos 10 valores de entrada já normalizados. A Figura (7) mostra como os dados foram apresentados à rede. Observe-se que essa figura mostra valores aparentemente dispersos e sem nenhuma relação, é nesse sentido que a rede neural artificial é desenvolvida para identificar essas relações complexas, impossíveis de serem identificadas somente com gráficos.

Tabela 1. Últimos 10 valores de entrada da rede sem normalização.

Data	PETR4 R\$ Fechamento	IBOVESPA	IN	ROC3	ROC10	RSI14	%RSI14
18/05/2010	29,22	60.841	0,8171	-0,0114	-0,0288	28,5714	100,0000
19/05/2010	28,55	59.689	0,7677	-0,0216	-0,0304	28,5714	100,0000
20/05/2010	27,43	58.192	0,7745	-0,0371	-0,0459	35,7143	100,0000
21/05/2010	27,58	60.259	0,8042	-0,0256	-0,0405	35,7143	95,0166
24/05/2010	27,15	59.915	0,7841	-0,0247	-0,0473	35,7143	100,0000
25/05/2010	26,55	59.184	0,8526	-0,0263	-0,0591	42,8571	100,0000
26/05/2010	27,05	60.190	0,8447	-0,0074	-0,0509	50,0000	86,1111
27/05/2010	27,81	62.091	0,8282	0,0120	-0,0361	50,0000	65,0000
28/05/2010	28,20	61.946	0,7375	0,0175	-0,0278	57,1429	53,3898
31/05/2010	29,60	63.046	0,7742	0,0395	0,0010	50,0000	13,8418

Fonte: desenvolvido pelo autor.

Tabela 2. Últimos 10 valores de entrada da rede normalizados.

Data	PETR4 Fechamento	IBOVESPA	IN	ROC3	ROC10	RSI14	%RSI14
18/05/2010	-0,3167	0,4043	-0,1144	0,0397	-0,5668	0,0000	0,6166
19/05/2010	-0,0667	0,4533	0,0966	0,5120	-0,3445	-0,2500	0,1374
20/05/2010	-0,2133	0,4684	0,0289	0,2755	-0,4571	-0,2500	0,4185
21/05/2010	-0,1667	0,4957	0,3635	0,3878	-0,3084	-0,5000	0,3291
24/05/2010	-0,3967	0,3542	0,0931	-0,0112	-0,4185	-0,7500	0,7700
25/05/2010	-0,8000	-0,1689	0,2840	-0,6936	-0,7347	-0,5000	1,0000
26/05/2010	-0,7033	-0,1370	0,6722	-0,3866	-0,4898	-0,5000	0,8437
27/05/2010	-0,4933	0,1563	0,5073	0,1493	-0,1227	-0,5000	0,4121
28/05/2010	-0,5667	0,0568	0,8101	0,1214	-0,1420	-0,5000	0,3886
31/05/2010	-1,0000	-0,0341	0,1918	-0,4565	-0,6042	-0,5000	1,0000

Fonte: desenvolvido pelo autor.

⁸ As funções estão listadas no Anexo A.

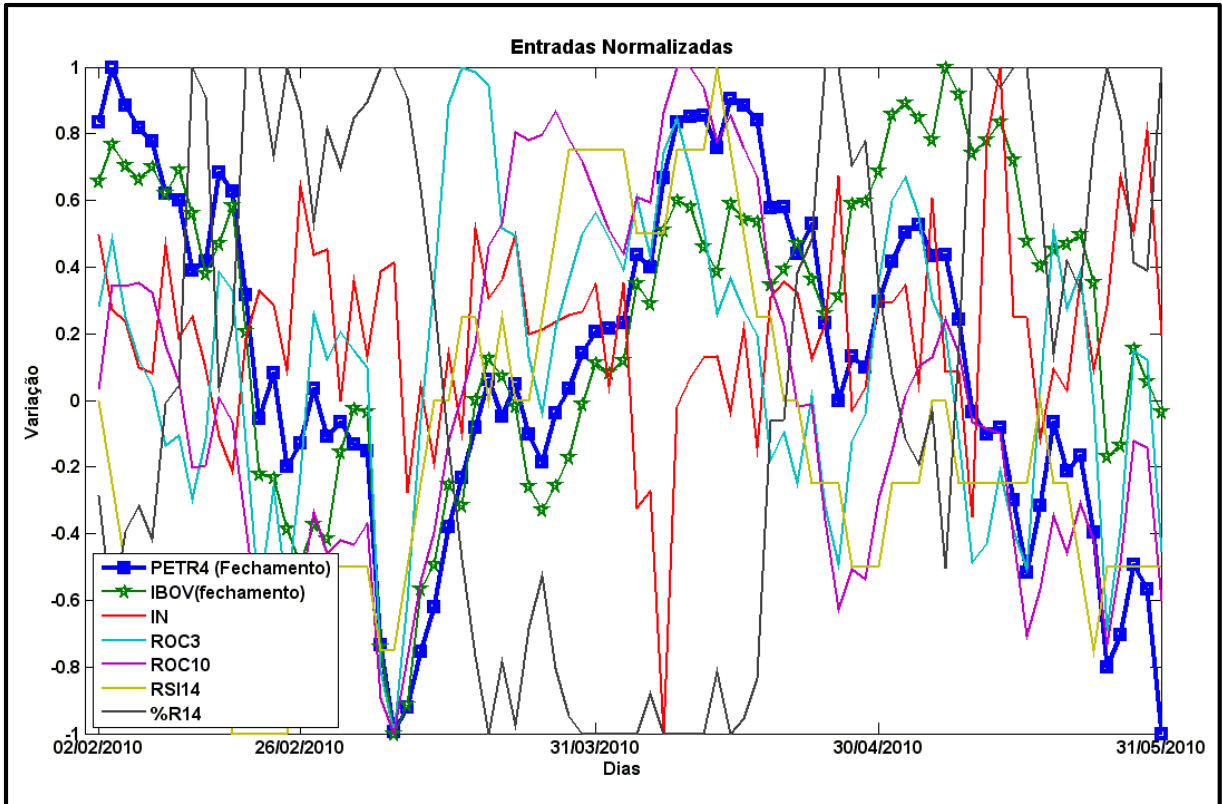


Figura 7. Entradas normalizadas.

Fonte: desenvolvido pelo autor.

Completada a fase de normalização dos dados, montou-se uma matriz para os dados de entrada e outra com o alvo. Utilizando a metodologia das redes neurais, desenvolveu-se um algoritmo capaz de identificar as tendências da série temporal em questão. A partir do aprendizado da rede neural, foram feitos testes de significância estatística dos valores encontrados, com objetivo de saber se os valores são confiáveis ou meras coincidências.

4.2 Modelo de RNA para Previsão da Ação PETR4

Após definir as variáveis de entrada da rede (*inputs*) e a variável meta, obtém-se uma rede que permite minimizar o MSE (erro quadrado médio). Para tanto, deve-se escolher um

modelo de rede ideal para previsão, por meio de um procedimento exaustivo de tentativa e erro. Nesse trabalho foram simuladas inúmeras redes neurais para alcançar o objetivo que é uma rede com alto grau de precisão. Antes de apresentar os dados à rede, são necessários vários ajustes para melhores previsões, o que se chamou de pré-processamento já descrito na metodologia. Também é fundamental a utilização de indicadores técnicos, conforme proposto por Murphy (1999).

Após inúmeras simulações, chegou-se ao modelo com melhores previsões. O termo de “momentum”, que deve ser ajustado entre 0 e 1, mede o mínimo local, ou seja, um termo de “momentum” igual a um resulta numa rede que não considera o gradiente descendente e não apresenta um bom processo de aprendizado, enquanto o valor zero mostra uma rede sem esse termo. As épocas de treinamento são o número de iterações do algoritmo *backpropagation*, ou seja, qual o limite do treinamento. O MSE (erro quadrado médio) é o erro de treinamento da rede, calculado através da Equação (2) mostrada no capítulo 3.

Observa-se na Figura (8) que a evolução do erro num dos casos simulados neste estudo, mostrou-se muito eficiente, pois o erro (MSE) atingido em todos os testes chegou rapidamente a valores iguais a 10^{-10} com 1.595 iterações entre os neurônios. O tempo de treinamento da rede foi menor que 1 minuto. Esse tempo depende da arquitetura da rede desenvolvida, do número de iterações escolhidos como limite, da capacidade de convergência e também está relacionado com a capacidade de processamento do computador.




Figura 8. Desempenho do erro no treinamento.

Fonte: gerado no MATLAB r2009a.

O valor R^2 é o coeficiente de determinação do ajuste do modelo entre os alvos observados e os alvos estimados, quanto mais próximo de 1, mais o modelo se ajusta perfeitamente, como mostrado na Figura (9). A Tabela 3 mostra os parâmetros do modelo desenvolvido, a arquitetura da RNA desenvolvida, os termos de erros e o tempo de previsão escolhido.

Tabela 3. Parâmetros da RNA escolhidos para o modelo.

Parâmetro	Valor
Dias de previsão	20
Dias para treinamento e validação	100
Neurônios	30
Camadas	2 (uma escondida)
Termo de momentum	0,6
Épocas de treinamento (iterações)	10.000
MSE	10^{-10}
R^2 estimado	1

Fonte: desenvolvido pelo autor.

O valor final mais importante da rede neural é a capacidade de previsão, ou seja, qual a precisão dos valores gerados pela RNA em comparação com os valores reais. As primeiras simulações de previsão foram feitas para períodos longos, de 100 a 300 dias, porém a rede não obteve bons resultados para previsões de longo prazo. Para aumentar a eficiência do modelo o tempo de previsão foi sendo reduzido, os valores do MSE foram sendo analisados e os resultados comparados. Chegou-se a conclusão que o tempo ideal para previsões muito próximas é de, no máximo, 20 dias, ou seja, o modelo aqui desenvolvido é capaz de prever 20 valores futuros de fechamento da ação PETR4 com alto grau de precisão. Essa exatidão foi medida através da Equação (16) e comparada de acordo com os dias de previsão. Os resultados analisados são mostrados na Figura (10). Nota-se claramente que na medida em que o tempo de previsão aumenta o MSE também aumenta, portanto limitou-se o modelo à previsões de 20 dias com erro médio quadrado máximo de 1%.

$$MSE = \frac{1}{n} \sum_{t=1}^n (real_t - previsto_t)^2 \quad (16)$$




Figura 9. R² Ajustado.
Fonte: gerado no MATLAB r2009a.




Figura 10. MSE da previsão (%).
Fonte: desenvolvido pelo autor.

Passada a etapa de testes e validação do modelo, foram feitas previsões com os dados reais. Utilizou-se os preços de fechamento da Petrobras (PETR4) de janeiro de 1999 a 31 de maio de 2010. Foram aplicados os indicadores técnicos para cada período e montada as matrizes com os valores de entrada, os alvos que são somente os preços de fechamento do dia e por fim os valores previstos. Foram escolhidos meses aleatórios, agrupados em 100 valores sequenciais destinados ao teste e validação para comparar a previsão de 20 dias, os resultados são apresentados na seção seguinte.

4.3 Análises dos resultados de previsão

A partir do modelo testado e validado através do bom resultado de previsão, simularam-se alguns períodos para demonstrar a qualidade da previsão. Mesmo quando o modelo não evidenciou a tendência clara de alta ou de baixa dentro do período, utilizou-se médias móveis para identificar os melhores pontos de entradas e saídas do mercado. Uma análise muito comum proposta por Murphy (1999) é o cruzamento da média simples de 4, 9 e 18 dias. Essa metodologia de cruzamento vai mostrar se o ponto analisado é um possível ponto de entrada ou saída do mercado, evitando perdas muito grandes. Porém, muitas vezes esse cruzamento de médias é atrasado ao identificar entradas e saídas, podendo identificar pontos muito antes ou muito depois do tempo ideal. E como a análise é de curto prazo, os erros devem ser muito pequenos para evitar entradas e saídas do mercado erradas, aumentando os custos da transação, o que inviabiliza *trades* de poucos dias, ou até mesmo *intraday* (compra e venda no mesmo dia).

A Figura (11) mostra os resultados de treinamento, teste e de previsão *versus* o preço real de fechamento da PETR4 no intervalo de 03/10/2000 à 30/03/2001. Os gráficos da Figura (11) foram obtidos, contendo um período de treinamento de 75% (75 valores dos preços de fechamento passados da ação PETR4), um período de teste de 25% (25 valores dos preços de fechamento passados da ação PETR4), e um período de previsão de 20 dias futuros, sem qualquer conhecimento desses dados.




Figura 11. Comparação Previsão x Preço Real PETR4, outubro de 2000 a março de 2001.

Fonte: desenvolvido pelo autor.

Como se observa nos resultados obtidos pela RNA que o nível do MSE entre os valores alvo e valores obtidos no período de previsão e teste é extremamente pequeno, sendo da ordem de 10^{-10} e poderiam ainda ser menores. Este fato pode ser constatado pela proximidade das duas linhas neste período, onde não se observa a interposição entre as linhas verde e azul, as quais se coincidem. Contudo, os valores previsto, caracterizado pela linha azul e os valores observados para ação PETR4, caracterizados pela linha verde no período de previsão apresentam-se levemente destoantes, mas com um nível de erro bastante pequeno, conforme já caracterizado na Figura (10). A imagem na Figura (11) mostra claramente que a diferença entre os dias previstos e o preço real de fechamento é pequena, o que é uma forte evidência de que a rede neural estruturada neste estudo mostrou-se com forte potencial de previsão do comportamento do preço futuro de fechamento da ação escolhida, no mínimo, para períodos em que o mercado esteja livre de fortes crises financeiras de impacto internacional e eventos políticos.

Da mesma forma, para mostrar que os valores não são meras coincidências, as Figuras (12) e (13) mostram os resultados para o período de 01/11/2001 à 30/04/2002 de fevereiro de

2005 a julho de 2005, respectivamente. Ao final da linha a tendência da previsão mostra uma possível reversão, que pode ser validada utilizando as médias móveis, conforme proposto na metodologia. Porém, como os valores podem ser recalculados na medida em que os dias de pregão são encerrados, o investidor pode entrar com os novos dados para aumentar a previsão dos dias e observar se a tendência de alta ou de baixa se confirma nos dias futuros.

A Figura (14) mostra de forma ampliada a previsão para o mês de dezembro de 2005. Observe-se que o preço (eixo das ordenadas) varia de R\$ 14,5 à R\$ 15,7, mostrando que o resultado da previsão ficou bem próximo dos valores reais. Inclusive no final dos dias de previsão, a tendência futura de alta se confirmou, novamente mostrando o poder de previsão do modelo proposto. No Anexo B se encontram mais figuras com comparações de previsões.




Figura 12. Comparação Previsão x Preço Real PETR4, novembro 2001 a abril de 2002.
Fonte: desenvolvido pelo autor.

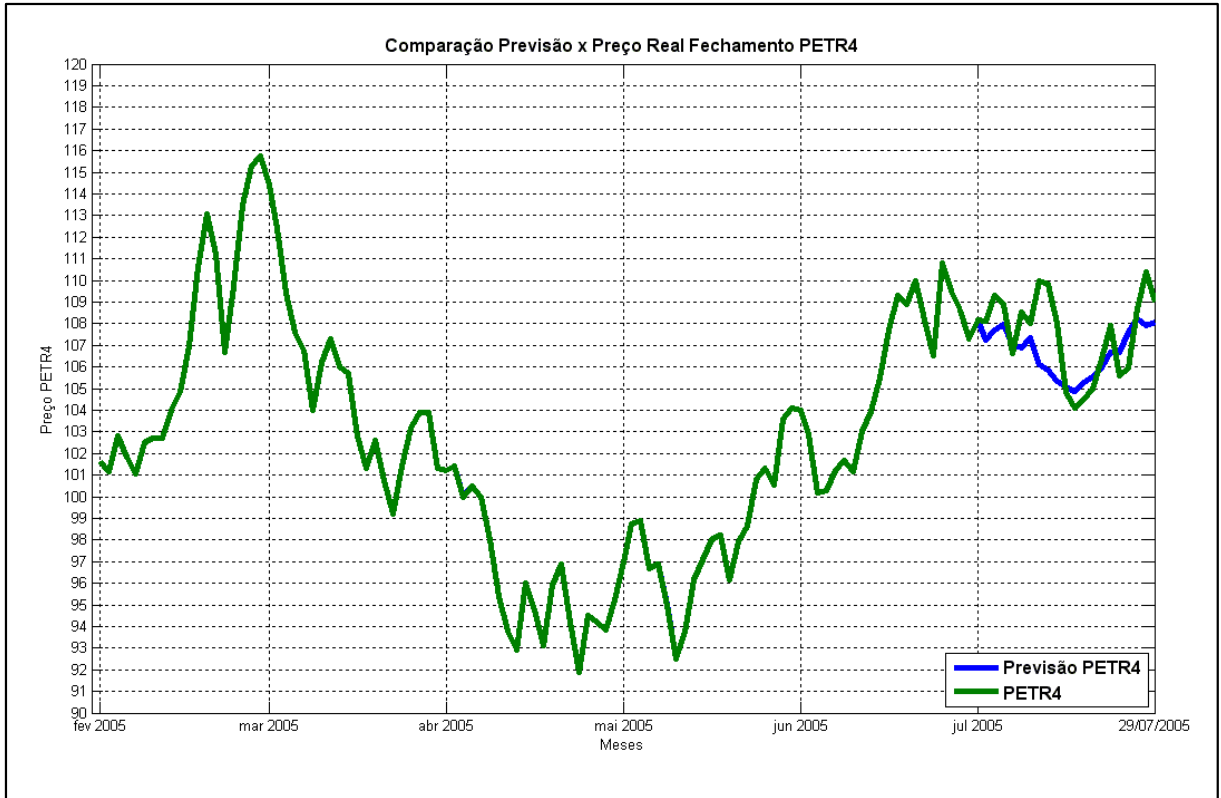


Figura 13. Comparação Previsão x Preço Real PETR4, fevereiro de 2005 a julho de 2005.
 Fonte: desenvolvido pelo autor.




Figura 14. Comparação Previsão x Preço Real PETR4, dezembro de 2005.
 Fonte: desenvolvido pelo autor.

Finalmente apresentam-se as Figuras (15) e (16) com a previsão de 20 dias futuros a partir de 31/05/2010, o último valor da série. Observe-se que na Figura (15) estão presentes as médias móveis de 18, 9 e 4 dias dos valores previstos. A Figura (16) mostra de forma ampliada somente o período de previsão. As médias móveis são utilizadas para auxiliar o estudo das tendências, nesse caso de curto prazo. Os dois pontos destacados correspondentes aos dias 08/06 e 23/06 mostram que podem ser evidências de reversões. A explicação está no cruzamento das linhas de médias móveis de 18, 9 e 4 dias. Essa relação foi proposta pela primeira vez por Allen (1972) e ganhou popularidade pelos bons resultados alcançados. A ideia proposta é de que quando a média de 4 dias cruza a de 9 e a de 18 dias para cima, há o primeiro sinal de tendência de alta. Quando a média móvel de 9 também cruza a média de 18 para cima é uma forte evidência que os preços irão continuar subindo, ou seja, é um momento de compra. Do contrário, se a média móvel de 4 dias cruzar para baixo a de 9 e a de 18, tem-se o primeiro sinal de tendência de queda. Entretanto quando a média móvel de 9 também cruza abaixo da média de 18 há forte evidência de uma tendência de queda, ou seja, um momento de venda do papel. Porém, o que se pode notar na Figura (15) é um falso sinal de tendência de alta no dia 08/06, quando as duas médias (4 e 9 dias) cruzam a média de 18 para cima, pois logo no dia 23/06 a rede neural prevê uma nova queda, quando as duas médias voltam a cruzar para baixo da média móvel de 18 dias. Se o investidor não está disposto a correr riscos, o momento é de cautela, pois a previsão mostra um momento de muitas oscilações acima e abaixo das médias. Por outro lado, se o investidor comprou esta ação à R\$ 27,00 ou menos, pode ser um bom momento de venda quando chegar em R\$ 30,00, rendendo 10% num curto período de tempo.

A Figura (17) compara a previsão com os preços de fechamento até o dia 18/06, data em que se encerra este trabalho. Percebe-se que a acuidade da previsão é muito boa. Para enriquecer a análise da Figura (17), destaca-se uma linha de suporte de curto prazo (em vermelho), que evidencia o preço de R\$ 27,50 como um bom valor de compra para trades de períodos curtos.

O que se pretende mostrar é que utilizando os dois métodos, tanto as previsões das redes neurais quanto as médias móveis de 4, 9 e 18 dias, as tendências da previsão do modelo atingem um nível excepcional. De um lado as redes neurais evidenciam os valores futuros dos preços de fechamento, e de outro, o cruzamento das médias móveis dos valores previstos evidenciam se as tendências de alta ou de baixa se confirmam.

A Figura (18) mostra a previsão do comportamento futuro dos preços da ação PETR4 de 21/06 a 20/07/2010. Percebe-se novamente um período de muita volatilidade, com preços oscilando de R\$ 29,5 a R\$ 27,40. Destacaram-se alguns possíveis pontos de compra e venda, visando maximizar os lucros dentro de um período curto. Também se evidencia na Figura (18) uma Linha de Tendência de Baixa – LTB, mostrando que os preços devem seguir uma trajetória de queda no curto prazo, porém com bons momentos de altas e baixas, destacados nessa figura, onde o investidor pode auferir lucros.

Fica como sugestão para o leitor acompanhar os preços de fechamento da ação PETR4 até o dia 20/07/2010 e comparar com os valores previstos na Figura (18). Também se sugere a análise do Anexo B, onde são mostradas figuras com algumas previsões de 20 dias em comparação com os dados reais passados.

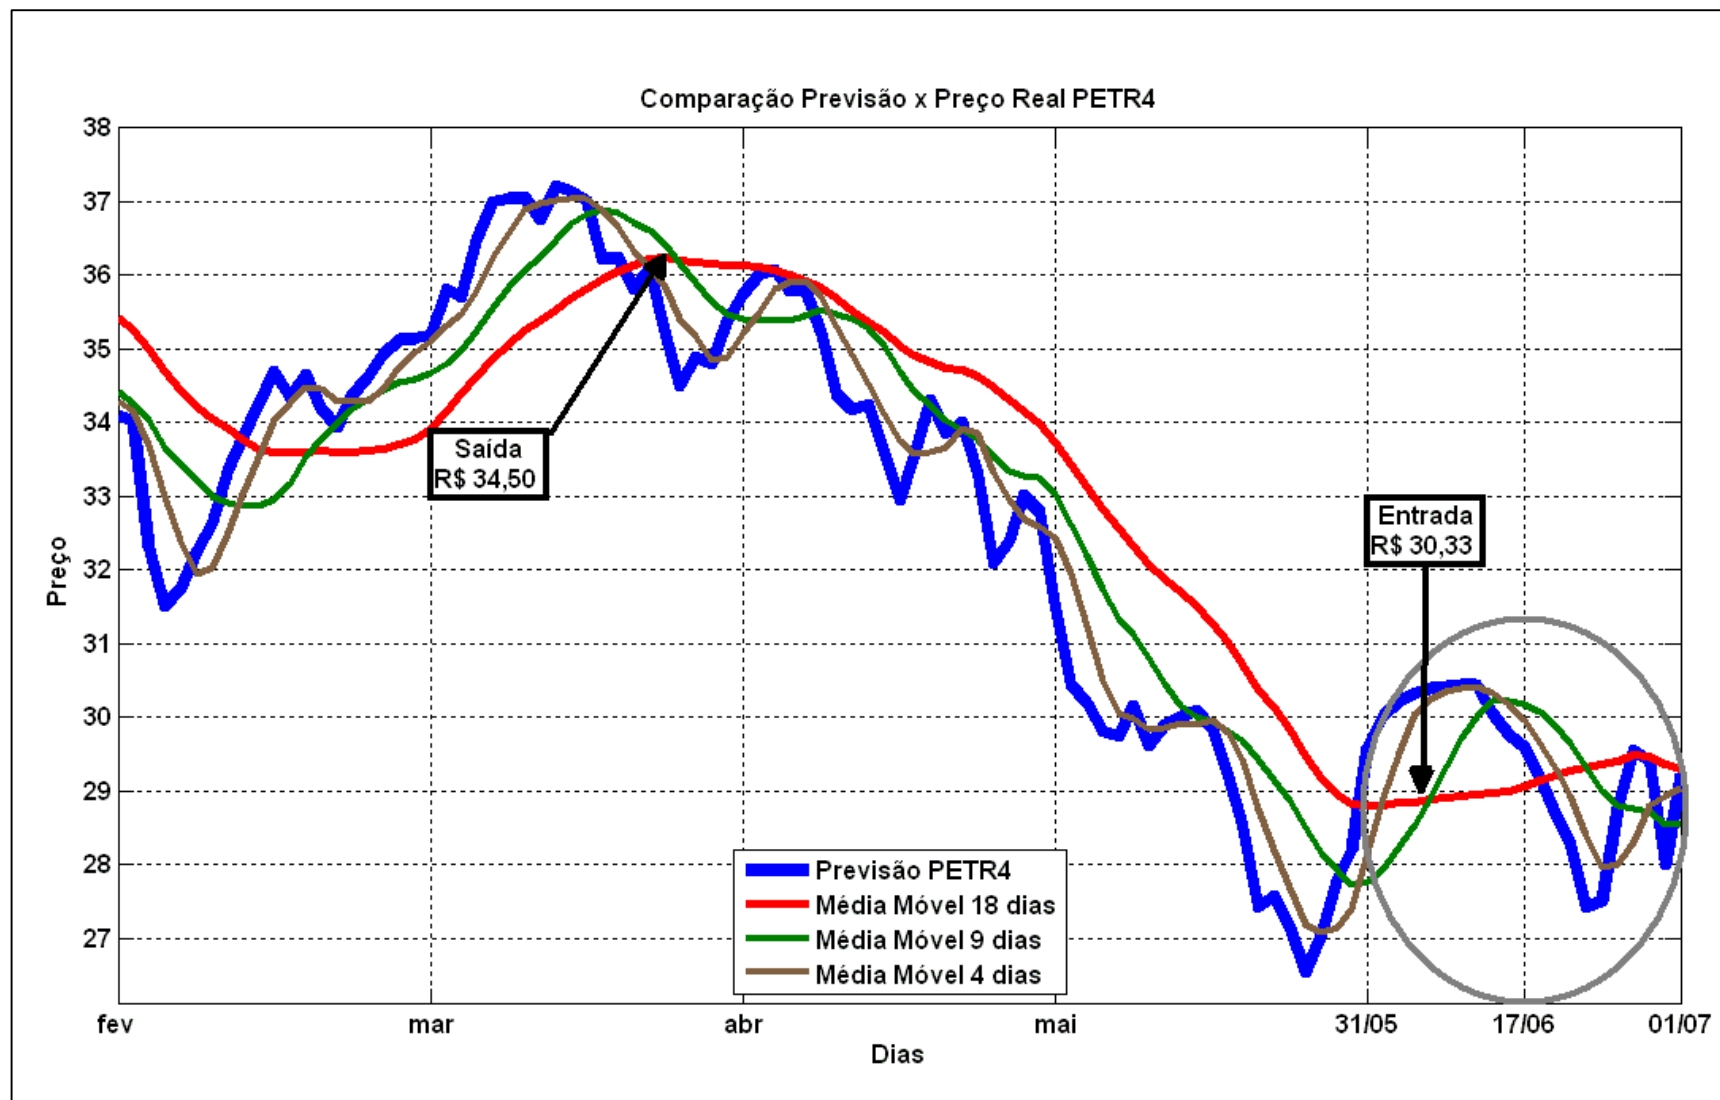


Figura 15. Previsão PETR4 de 31/05/2010 à 01/07/2010.

Fonte: desenvolvido pelo autor.

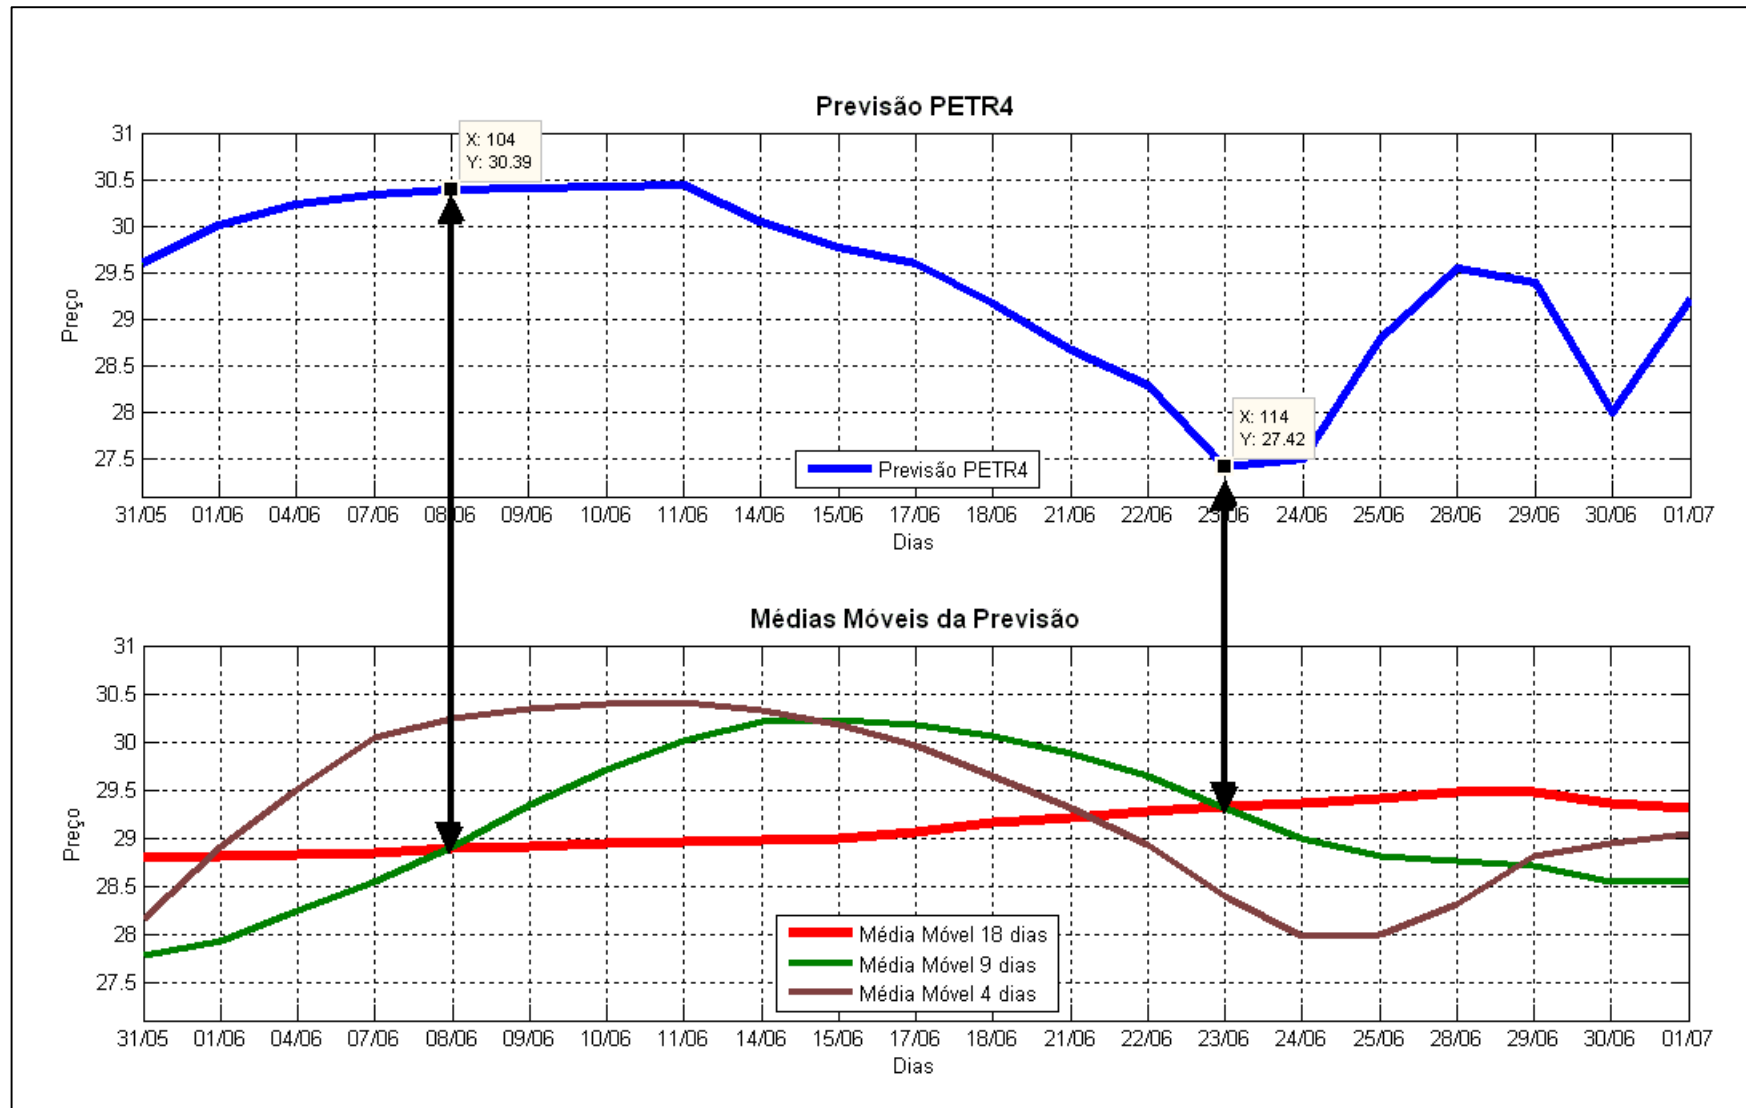


Figura 16. Previsão PETR4 de 31/05/2010 a 01/07/2010, ampliada.

Fonte: desenvolvido pelo autor.




Figura 17. Comparação da Previsão PETR4 x Preços Reais de 31/05/2010 a 18/06/2010.

Fonte: desenvolvido pelo autor.




Figura 18. Previsão PETR4 de 21/06/2010 a 20/07/2010.

Fonte: desenvolvido pelo autor.

5 CONCLUSÃO

Previsão de mercado acionário está longe de ser um tema simples e de soluções perfeitas. Sabe-se que os mercados de capitais internacionais, cada vez mais interligados pelas tecnologias de comunicação, oscilam imediatamente às mudanças nas expectativas dos agentes. As notícias correm o mundo inteiro em segundos, um simples discurso equivocado de uma autoridade econômica, ou um pacote financeiro bilionário de salvamento a um país pode rapidamente alterar o humor dos investidores e, conseqüentemente, alterar os preços das ações imediatamente. Prever essas manifestações é ainda uma tarefa difícil para a estatística, economia, matemática e áreas afins. Porém mesmo previsões com certo grau de erro podem ser de grande valor para os investidores. E nesse ponto as redes neurais artificiais aqui apresentadas alcançaram o objetivo proposto.

O poder de previsão de séries temporais financeiras com variações não lineares mostrou que as RNAs podem ser um método alternativo às análises convencionais, não somente utilizando os valores absolutos previstos, mas também estimando, a partir dos dados previstos, medidas de análise secundárias, como médias móveis. Assim, as redes neurais podem apresentar um poder de previsão considerável para períodos curtos, no caso deste estudo, de 20 dias e mesmo para períodos mais longos, em momentos em que o mercado se encontra livre de fortes crises econômicas e políticas de nível internacional.

Todavia, desenvolver uma rede neural é um trabalho exaustivo. Como não há um método consolidado para escolha das entradas, dos parâmetros, da arquitetura, etc., o procedimento dá-se através do *learnig-by-doing*, e depende quase que exclusivamente da habilidade do projetista em acertar os valores ideais para acurar as previsões do modelo.

Nesse sentido, não existe um padrão a ser proposto, porém há certos caminhos a serem seguidos. Uma rede neural grande, com muitos neurônios na camada oculta, por exemplo, pode levar ao *overtraining*, ocasionando o efeito memorização, reduzindo a exatidão da convergência do modelo. Por outro lado, uma rede pequena com poucos neurônios, pode gerar valores errados devido a um treinamento pobre e reduzidas iterações. O termo de “momentum” do gradiente descendente também é fundamental, se mal dimensionado, atingindo o mínimo local antecipadamente, irá reduzir a capacidade de previsão. O algoritmo

de treinamento *backpropagation* tem apresentado bons resultados em comparação com outros métodos, esta deve ser talvez a única unanimidade entre os trabalhos que usam redes neurais para previsão de séries não lineares. Outro ponto importante a ser destacado é o pré processamento dos dados, sempre recomendado pela literatura consultada.

Não há um horizonte promissor quanto a modelos 100% perfeitos. Porém o método aqui proposto utilizando redes neurais artificiais mostrou que em momentos de pouca agitação internacional, sem grandes choques, as previsões podem ser de grande valia para tomada de decisão ao entrar ou sair do mercado. Mais do que isso, este trabalho mostrou que os estudos envolvendo RNAs devem ser continuados na medida em que o conhecimento é difundido pelos diversos meios de comunicação. O desenvolvimento de *softwares* específicos nessa área também é um fator importante à continuidade dos estudos.

Dentro desse universo de previsões através de redes neurais artificiais, sabe-se que seu poder adaptativo é imenso, cujo método pode ser aplicado a diversas áreas do conhecimento. Por isso, recomendam-se estudos envolvendo essa metodologia com outros parâmetros expostos abaixo:

- a) desenvolver mais de uma rede neural e fazer previsões conjuntas, por exemplo, relacionar previsões do preço de fechamento com previsões de taxas de câmbio.
- b) utilizar uma base de dados de 5, 10 e 15 minutos para prever oscilações dentro de um dia, auxiliando os *trades* do tipo *intraday* (compra e venda no mesmo dia);
- c) previsões dos preços no mercado de derivativos;
- d) testar outras variáveis de entrada, tais como: câmbio, preço do barril de petróleo, índices de bolsas de outros países, taxas de juros internas e externas, etc.
- e) montar uma carteira com *blue chips*, e outra com ações de maior risco e comparar as previsões;
- f) utilizar outros indicadores técnicos, como *Bollinger Bands*, *MACD*, *IFR*, *Fibonacci*, etc.

REFERÊNCIAS

- ANTONIOU, A., ERGUL, N. and HOLMES, P., 1997, **Market efficiency, thin trading and nonlinear behaviour: evidence from an emerging market**, *European Financial Management* 3, 175-190.
- ABELÉM, Antônio Jorge Gomes. **Redes Neurais Artificiais na previsão de séries temporais**. 1994. Tese (Mestrado em Engenharia Elétrica) - Curso de Mestrado em Engenharia Elétrica, PUC-Rio, Rio de Janeiro.
- ASSAF NETO, Alexandre. **Mercado financeiro**. 4. ed. São Paulo: Atlas, 2001.
- AZOFF, E. M. **Reducing error in neural network time series forecasting**. *Neural Computing & Applications*, Londres, n. 1, p. 240-247, 1993.
- BEALE, R.; JACKSON T., **Neural Computing: An Introduction**, Adam Hilger, Bristol, England, 1990.
- BARRETO, J, M. **Introdução às Redes Neurais Artificiais**. Florianópolis: Departamento de Informática e Estatística, 2002. Disponível em: <www.inf.ufsc.br/~barreto/tutoriais/Survey.pdf> Acesso em: 27 set. 2009.
- BOLSA DE VALORES DE SÃO PAULO. Disponível em: <<http://www.BOVESPA.com.br>>. Acesso em: 25 set. 2009.
- BROOKS, C., HINICH, M.J., MOLYNEUX, R., 2000. **Episodic nonlinear event detection: political epochs in exchange rates**. In: Richards, D. (Ed.), *Political Complexity: Political Epochs in Exchange Rates*. Michigan University Press, Ann Arbor, MI.
- CAVALCANTE, F.; MISUMI, J. Y.; RUDGE, L. F. **Mercado de Capitais: O que é, como funciona**. 6. ed. São Paulo: Elsevier, 2005. 371 p. ISBN 13: 97885-352-1673-8.
- CARTACHO, M. S. **A utilização de um modelo híbrido Algoritmo Genético/Redes Neurais no processo de seleção de carteiras**. 2001. Dissertação (Mestrado em Administração) – Faculdade de Ciências Econômicas, UFMG, Belo Horizonte.
- CARTER, C. e CATLETT J. **Assessing Credit Card Applications Using Machine Learning**. *IEEE Expert*, E.U.A., IEEE Press, p. 71-79, 1987.
- FAMA, E. F. **Efficient Capital Markets: a review of theory and empirical work**. *Journal of Finance*: 1970, maio, pp. 383-417.
- FRANSES, P. H. **Times Series Models for Busines and Economic Forecasting**. Nova York: Cambridge University Press, 1998.
- FREITAS, S. O. **Utilização de um modelo baseado em Redes Neurais para a precificação de opções**. 2001. Dissertação (Mestrado em Administração) – Faculdade de Ciências Econômicas, UFMG, Belo Horizonte.

GUJARATI, D. N. **Econometria Básica**. 3.ed. São Paulo: Pearson Makron Books, 2000.

GUJARATI, D. N. **Econometria Básica**. Tradução de Maria José Cyhlar Monteiro. Rio de Janeiro: Elsevier, 2006. 4. ed.

HERTZ, J., KROGH, A. e PALMER, R. G. **Introduction to the theory of neural computation**. Redwood City: Addison-Wesley, 1991.

HONG, T. **Neural Network Model for Stock Forecasting**. 1995. 64f. Dissertação (Mestrado em Engenharia Elétrica) - Faculty of Texas Tech University - USA. Texas: 1995.

LIM, K.P., BROOKS, R.D., HINICH, M.J., 2006a. **Testing the assertion that emerging Asian stock markets are becoming more efficient**. SSRN, <http://ssrn.com/abstract=906515>.

LIM, K.P., HINICH, M.J., 2005b. **Non-linear Market Behavior: Events Detection in the Malaysian Stock Market**, Economics Bulletin Submission Number: EB-05G10005S.

MÁLAGA, F. K. **Retorno de ações no Brasil** - aplicação do modelo de Fama e French no mercado brasileiro. São Paulo: Saint Paul, 2005.

MILLER, G. F., TODD, P. M. e HEGDE, S. U. **Designing neural networks using genetic algorithms**. In: Third International Conference on Genetic Algorithms. Anais, p. 177-179. San Mateo: Morgan Kaufmann 1989.

MUELLER, A. **Uma aplicação de redes neurais artificiais na previsão do mercado acionário**. 1996. 103f. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Centro Tecnológico. Florianópolis: 1996.

MURPHY, J. J. **Technical Analysis of the financial market**. New York: New York Institute of Finance, 1999.

PALMA, A. A.; PORTUGAL, M. S. **Análise Empírica da Formação de Expectativas de Inflação no Brasil: uma aplicação de redes neurais artificiais a dados em painel**. Porto Alegre: Departamento de Economia da UFRGS. Disponível em: <<http://virtualbib.fgv.br/dspace/bitstream/handle/10438/1660/93.pdf?sequence=1>> Acesso em: 15 nov. 2009.

RAO, V.B. **C++ Neural Network and Fuzzy Logic**. M and T Press: 1995. ISBN: 10: 1558515526, pp: 549.

REFENES, A. N. et al. **Financial Modelling using Neural Networks**. London: [s.n.]. Department of Computer Sciences, University College London, 1993. p. 1 - 31.

SANDRONI, P. (Org.). **Novíssimo Dicionário de Economia**. São Paulo: Best Seller, 1999.

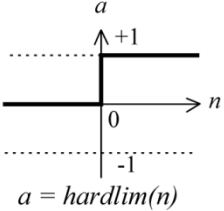
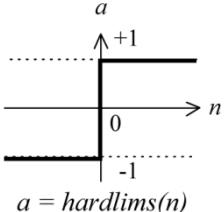
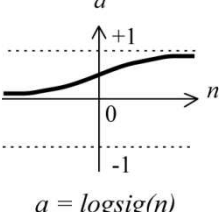
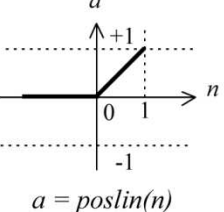
SMOLENSKY, P., MOZER, M. C., RUMELHART D. E., ed., **Mathematical Perspectives on Neural Networks**, Lawrence Erlbaum Associates, Mahwah, New Jersey, 1996.

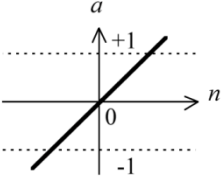
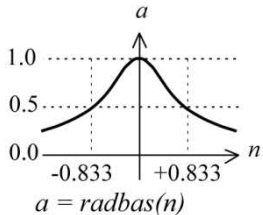
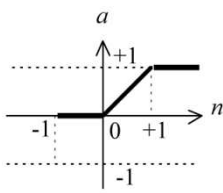
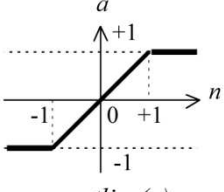
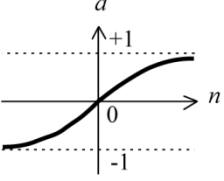
SUTCLIFFE, C. M.S. **Stock index futures**. 3 ed. England: Ashgate, 2006. 464p.


ANEXOS

ANEXO A – FUNÇÕES DE ATIVAÇÃO

Tabela 4. Funções de Ativação para RNA.

Gráfico	Algoritmo
 <p style="text-align: center;">$a = \text{hardlim}(n)$</p> <p style="text-align: center;">Hard-Limit Transfer Function</p>	<p>$\text{hardlim}(n) =$</p> <p>1 se $n \geq 0$ 0 para outros valores de n.</p>
 <p style="text-align: center;">$a = \text{hardlims}(n)$</p> <p style="text-align: center;">Symmetric Hard-Limit Transfer Function</p>	<p>$\text{hardlims}(n) =$</p> <p>1 se $n \geq 0$ -1 para outros valores de n.</p>
 <p style="text-align: center;">$a = \text{logsig}(n)$</p> <p style="text-align: center;">Log-Sigmoid Transfer Function</p>	<p>$\text{logsig}(n) = 1 / (1 + \exp(-n))$</p>
 <p style="text-align: center;">$a = \text{poslin}(n)$</p> <p style="text-align: center;">Positive Linear Transfer Function</p>	<p>Retorna o valor n se n for maior ou igual a 0. Retorna 0 se n for menor ou igual a 0.</p> <p>$\text{poslin}(n) =$</p> <p>n se $n \geq 0$ 0 se $n \leq 0$</p>

 <p style="text-align: center;">$a = \text{purelin}(n)$</p> <p style="text-align: center;">Linear Transfer Function</p>	$\text{purelin}(n) = n$
 <p style="text-align: center;">$a = \text{radbas}(n)$</p> <p style="text-align: center;">Radial Basis Function</p>	$\text{radbas}(n) = \exp(-n^2)$
 <p style="text-align: center;">$a = \text{satlin}(n)$</p> <p style="text-align: center;">Satlin Transfer Function</p>	$\text{satlin}(n) =$ $0 \text{ se } n \leq 0$ $n \text{ se } 0 \leq n \leq 1$ $1 \text{ se } 1 \leq n$
 <p style="text-align: center;">$a = \text{satlins}(n)$</p> <p style="text-align: center;">Satlins Transfer Function</p>	$\text{satlins}(n) =$ $-1 \text{ se } n \leq -1$ $n \text{ se } -1 \leq n \leq 1$ $1 \text{ se } 1 \leq n$
 <p style="text-align: center;">$a = \text{tansig}(n)$</p> <p style="text-align: center;">Tan-Sigmoid Transfer Function</p>	$\text{tansig}(n) = 2/(1+\exp(-2*n))-1$



$$a = \text{tribas}(n)$$

Triangular Basis Function

$\text{tribas}(n) =$

$1 - \text{abs}(n)$ se $-1 \leq n \leq 1$

0 para outros valores de n .

ANEXO B – GRÁFICOS DE PREVISÃO




Figura 19. Comparação Previsão x Preço Real PETR4, 16/06/2003 à 02/12/2003.

Fonte: desenvolvido pelo autor.




Figura 20. Comparação Previsão x Preço Real PETR4, setembro de 2006 à fevereiro de 2007.

Fonte: desenvolvido pelo autor.




Figura 21. Comparação Previsão x Preço Real PETR4, 16/06/2003 à 02/12/2003.

Fonte: desenvolvido pelo autor.




Figura 22. Comparação Previsão x Preço Real PETR4, 28/11/2008 à 30/12/2008.
Fonte: desenvolvido pelo autor.

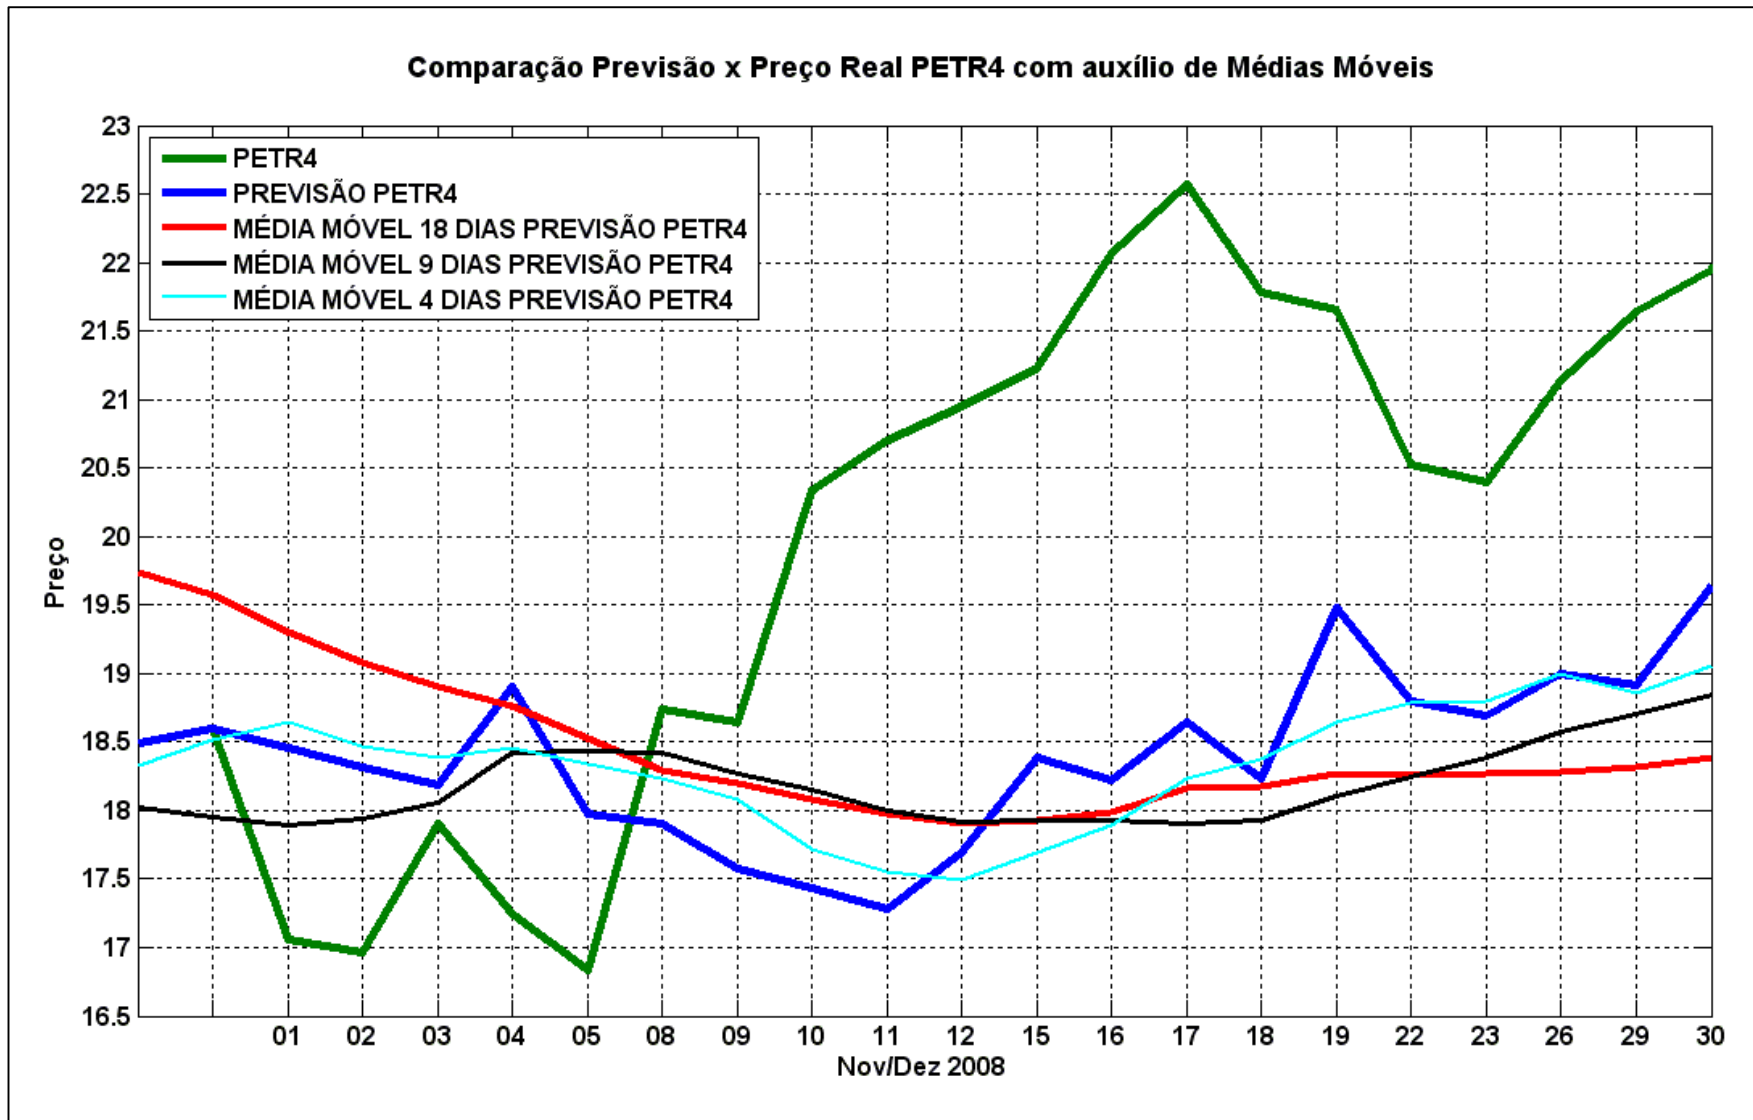


Figura 23. Comparação Previsão x Preço Real PETR4, 28/11/2008 à 30/12/2008.

Fonte: desenvolvido pelo autor.




Figura 24. Comparação Previsão x Preço Real PETR4, junho a dezembro de 2009.

Fonte: desenvolvido pelo autor.