

Aplicação de Redes Neurais na Previsão das Ações do Setor de Petróleo e Gás da Bm&FBovespa

Application of Neural Networks in Forecasting the Shares of the Oil and Gas Sector of Bm&FBovespa

João Gonçalves Silva Muntaser

Mestrado em Administração pela Universidade Federal de Uberlândia
Graduado em Administração pela Universidade Federal de Uberlândia
joao.gsm@hotmail.com

Valter Pereira da Silva

Mestrado em Administração pela Universidade Federal de Uberlândia
Graduado em Administração pela Universidade Federal de Uberlândia
valter1609@gmail.com

Antônio Sérgio Torres Penedo

Doutor em Engenharia de Produção Universidade Federal de São Carlos
Professor da Universidade Federal de Uberlândia
drpenedo@gmail.com

Endereço: João Gonçalves Silva Muntaser

Universidade Federal de Uberlândia, Faculdade de
Gestão e Negócios. Av. João Naves de Ávila, 2121 Santa
Mônica 38400902 - Uberlândia, MG - Brasil

Endereço: Valter Pereira da Silva

Universidade Federal de Uberlândia, Faculdade de
Gestão e Negócios. Av. João Naves de Ávila, 2121 Santa
Mônica 38400902 - Uberlândia, MG - Brasil

Endereço: Antônio Sérgio Torres Penedo

Universidade Federal de Uberlândia, Faculdade de
Gestão e Negócios. Av. João Naves de Ávila, 2121 Santa
Mônica 38400902 - Uberlândia, MG - Brasil

Editor Científico: Tonny Kerley de Alencar Rodrigues

**Artigo recebido em 09/08/2017. Última versão
recebida em 20/09/2017. Aprovado em 21/09/2017.**

**Avaliado pelo sistema Triple Review: a) Desk Review
pelo Editor-Chefe; e b) Double Blind Review
(avaliação cega por dois avaliadores da área).**

Revisão: Gramatical, Normativa e de Formatação

RESUMO

Devido à importância do processo de previsão do mercado financeiro e ao fato de que redes neurais artificiais vêm sendo amplamente utilizadas em detrimento de técnicas estatísticas tradicionais, este estudo tem como objetivo principal desenvolver um modelo de redes neurais artificiais baseado no proposto por Oliveira, Nobre e Zárate (2013) para previsão de preços das empresas brasileiras que atuam no setor de petróleo e gás da bolsa de valores. Para tanto, o presente trabalho utilizou todas as empresas que compõem o setor Petróleo e Gás da BM&FBovespa, expandindo a seleção do trabalho de Oliveira, Nobre e Zárate (2013), que selecionou apenas a Petrobrás. A amostra foi composta pelos preços das ações das seguintes empresas brasileiras: Companhia de Gás de São Paulo (CGAS5), a OGX Petróleo (OGXP3), a Refinaria de Petróleos Manguinhos (RPMG3), a PetroRio (PRIO3) e a Queiroz Galvão Exploração e Produção (QGEP3). Constatou-se que o modelo de rede neural artificial proposto obteve resultados satisfatórios, com erros ínfimos e um POCID maior do que 1. Com isso, pode-se inferir que as redes neurais artificiais são uma ferramenta eficaz na previsão do comportamento do mercado de ações brasileiro para o setor em análise.

Palavras-chave: Redes Neurais Artificiais. Mercado de Ações Brasileiro. Setor de Petróleo e Gás, Previsão.

ABSTRACT

The importance of the financial market prediction process and the fact that artificial neural networks have been widely used to the detriment of traditional statistical techniques, this study has as main objective to develop a model of artificial neural networks based on the one proposed by Oliveira, Nobre and Zárate (2013) to forecast prices of Brazilian companies that operate in the oil and gas sector of the stock exchange. For this purpose, the present study used all the companies the Oil & Gas sector of BM&FBovespa, expanding the selection of the work of Oliveira, Nobre and Zárate (2013), which selected only Petrobrás, the sample was composed by the stock prices of the following Brazilian companies: Companhia de Gás de São Paulo (CGAS5), a OGX Petróleo (OGXP3), a Refinaria de Petróleos Manguinhos (RPMG3), a PetroRio (PRIO3) e a Queiroz Galvão Exploração e Produção (QGEP3). It was found that the proposed artificial neural network model obtained satisfactory results, with minor errors and a POCID more than 1. With this, it can be inferred that the artificial neural networks are an effective tool in predicting the behavior of the stock market for the sector under analysis.

Keywords: Neural Networks. Brazilian Stock Market. Oil & Gas Sector. Forecast.

1 INTRODUÇÃO

A capitalização das empresas através da emissão de ações apresentou como uma interessante estratégia, não apenas em volume de negócios, como também na eficiência de suas alocações, fator esse que foi fundamental para o desenvolvimento econômico do Brasil (NUNES; COSTA JR; MEURER, 2005).

Sobre essa questão, Bekaert *et al.* (1995) afirma que esse processo de desenvolvimento teve início a partir dos anos 1980, período em que a inflação e a taxa de crescimento real começaram um processo de estabilização. O autor afirma, ainda, que parte dessa evolução está relacionada à expansão dos mercados financeiros, que contribuíram para melhorar a alocação dos recursos disponíveis aos setores produtivos da economia.

Neste cenário, Ferson (2008) comenta que houve um aumento no interesse pela previsão de preços das ações, e que esse fato é, provavelmente, tão antigo quanto os próprios mercados financeiros. Bodyanskiy e Popov (2006), afirmam que o principal objetivo da previsão é reduzir o risco das decisões tomadas as quais, segundo os autores, são especialmente importantes para empresas e investidores, cuja atividade é conectada com mercados financeiros.

Cavalheiro *et al.* (2010) afirmam que o uso de redes neurais em modelos de previsão tem se mostrado cada vez mais presente na literatura e nas modelagens empíricas. Adicionalmente, as pesquisas de Pendharkar (2005) e Paliwal e Kumar (2009) apontam que, desde o final dos anos 1990, redes neurais artificiais vêm sendo utilizadas como alternativa aos modelos estatísticos tradicionais.

Tendo em vista a importância do processo de previsão do mercado financeiro e o fato de que redes neurais artificiais vêm sendo amplamente utilizadas em detrimento de técnicas estatísticas tradicionais, este estudo tem como objetivo principal desenvolver um modelo de redes neurais artificiais baseado no modelo proposto por Oliveira, Nobre e Zárate (2013) para previsão de preços das empresas brasileiras do setor de petróleo e gás da BM&FBovespa no período de 2010 a 2015.

Especificamente, objetiva-se: i) coletar os dados referentes às variáveis propostas por Oliveira, Nobre e Zárate (2013), que podem impactar no comportamento dos preços no mercado de ações; ii) elaborar um modelo de redes neurais artificiais para prever o comportamento das ações das empresas brasileiras que atuam no setor de petróleo e gás da BM&FBovespa; iii) analisar os resultados obtidos.

Espera-se que as informações e discussões desse trabalho sejam úteis para os agentes econômicos que atuam direta e indiretamente no mercado de ações brasileiro. Entre esses agentes, destacam-se empresas de capital aberto, instituições financeiras especializadas em corretagem, como também pessoas físicas interessadas em investir no mercado de ações. A partir dos resultados dessa pesquisa, o pequeno investidor poderá, por exemplo, utilizar as informações geradas durante a tomada de decisão no momento de compra, manutenção ou venda de seus ativos.

A estrutura deste artigo consiste nesta introdução, seguida de referencial teórico. Posteriormente foi descrita a metodologia utilizada no estudo, bem como os dados referentes ao mesmo, uma breve descrição de cada um deles e onde foram coletados. Feito isso, foram expostos os resultados atingidos e, por fim, as considerações finais acerca da pesquisa.

2 REFERENCIAL TEÓRICO

Nesta seção, dividida em duas subseções, são apresentados uma descrição conceitual de redes neurais artificiais, seus principais tipos, como também o processo de aprendizagem e teste. Na segunda subseção, são descritos estudos anteriores que utilizaram redes neurais na previsão do mercado financeiro.

2.1 Redes neurais

Haykin (2001) define uma Rede Neural Artificial (RNA) como sendo um processador maciço e paralelamente distribuído, constituído de unidades de processamento simples, com propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. O autor afirma, ainda, que uma rede neural se assemelha ao cérebro humano devido ao fato de que o conhecimento é adquirido pela rede, a partir de seu ambiente, através de um processo de aprendizagem, e que forças de conexão entre neurônios, conhecidos como pesos sinápticos, são utilizados para armazenar esse conhecimento adquirido.

A unidade de processamento de informação fundamental para a operação de uma rede neural é o neurônio. A partir do momento em que estes neurônios estão organizados em camadas, tem-se uma rede em camadas. Em sua forma mais simples, a rede em camadas dispõe de uma camada de entradas de nós (neurônios) que se projetam sobre uma camada de saída, porém, o inverso não ocorre (HAYKIN, 2001).

Pao (2008) afirma que, além dessa formação básica, a rede pode ter camadas ocultas

em sua composição. Segundo o autor, estas camadas têm a habilidade de capturar a relação não linear entre as variáveis que se deseja estudar. Nessa conjuntura, Malik e Nasereddin (2006) afirmam que a camada oculta está entre a camada de entrada e a camada de saída, e a sua finalidade é identificar atributos especiais dos dados.

O desenvolvimento da RNA depende da especificação da sua arquitetura, que é definida pelo número de neurônios que compõe as camadas de entrada e de saída, bem como o número de camadas escondidas e a quantidade de neurônios que fazem parte delas, além do valor ótimo dos pesos de interligação que melhor descrevam a relação entre entrada e saída (MALIK; NASEREDDIN, 2006).

Nesse contexto, Mc Nelis (2005) destaca que as redes neurais relacionam um conjunto de variáveis de entrada para um ou mais conjuntos de variáveis de saída. A diferença entre essa metodologia e as demais técnicas é que a rede neural faz uso de uma ou mais camadas ocultas, nas quais as variáveis de entrada são transformadas e, segundo o autor, essa camada escondida representa uma maneira muito eficiente para modelar processos estatísticos não lineares.

Dentre os diversos tipos de redes neurais artificiais existentes, Haykin (2001) destaca três principais, quais sejam: as redes alimentadas adiante com camada única, as redes alimentadas diretamente com múltiplas camadas e as redes recorrentes. Segundo o autor, redes alimentadas adiante com camada única são a forma mais simples de uma rede de camadas, em que se tem uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios, mas não o contrário.

O segundo tipo de RNA é a rede alimentada diretamente com múltiplas camadas. Esse modelo se distingue do anterior pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos. Através da adição de uma ou mais camadas ocultas, é possível extrair estatísticas de ordem elevada, de modo que a rede adquire uma perspectiva global apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais (CHURCHLAND; SEJNOWSKI, 1992). Já as redes recorrentes se distinguem das redes neurais alimentadas adiante por ter no mínimo um laço de realimentação. Uma rede recorrente pode, por exemplo, consistir de uma camada de neurônios, com cada um deles alimentando seu sinal de saída de volta para as entradas de todos os demais neurônios (HAYKIN, 2001).

Cavalheiro *et al.* (2010) afirmam que as redes neurais apresentam duas fases distintas em sua metodologia, a aprendizagem e o teste. Segundo os autores, na fase de aprendizagem são apresentados estímulos na entrada da rede, denominados padrões de treinamento, ou

input, que farão com que o método encontre os mesmos nos resultados ou *target* que serão testados na fase de teste. Nessa fase de teste, é demonstrada a capacidade de generalização da rede, pois seus resultados deverão ser significativos, visto que seus pesos foram ajustados na fase anterior.

O aprendizado de uma rede neural artificial ocorre à medida que os pesos sinápticos são ajustados com base em alguma regra pré-estabelecida (FRANCO; STEINER; 2014). Braga, Carvalho e Ludermir (2011) afirmam que o aprendizado é o processo pelo qual os parâmetros livres de uma rede neural são ajustados por meio de uma força continuada e estimulada pelo ambiente externo, sendo o tipo específico de aprendizado definido pela maneira particular como ocorrem os ajustes dos parâmetros livres.

Diversos métodos têm sido propostos para o processo de treinamento de redes neurais. Na maior parte deles, o treinamento é classificado como híbrido, uma vez que é dividido em dois estágios. No primeiro estágio, o número de funções e seus parâmetros são determinados por métodos não supervisionados; já no segundo estágio, os pesos dos neurônios de saída são ajustados. Devido ao fato de que a saída dos neurônios da camada intermediária é um vetor linearmente separável, os pesos podem ser determinados por modelos lineares (BRAGA; CARVALHO; LUDERMIR, 2011; HAYKIN, 2001).

2.2. Redes neurais na previsão do mercado financeiro: uma revisão

Diversos são os estudos que utilizam redes neurais artificiais como ferramenta de previsão do mercado financeiro. Sobre essa questão, Guresen *et al.* (2011) descrevem RNAs como uma das melhores técnicas para modelar o mercado de ações. Segundo os autores, uma rede neural não contém um padrão de fórmula e pode ser facilmente adaptada às mudanças que ocorrem no mercado devido, principalmente, à sua capacidade de aprendizagem e de fazer alterações de acordo com o que foi aprendido.

O primeiro modelo para a previsão do mercado de ações que utilizou redes neurais foi desenvolvido por White (1988). O autor utilizou uma rede neural sem realimentação para analisar os retornos diários e detectar mudanças nos preços das ações da IBM, com o objetivo de testar a teoria do mercado eficiente proposta por Fama (1970), que afirma que os preços das ações de um ativo refletem as informações disponíveis sobre a instituição emissora, impossibilitando aos investidores qualquer ganho anormal. Embora os resultados encontrados por White (1988) não tenham alcançado níveis altos de predição, a pesquisa destacou o potencial existente para este tipo de análise.

Um estudo posterior conduzido por Kolarik e Rudorfer (1994) objetivou desenvolver um sistema de previsão de séries temporais, baseado em históricos de ações da IBM entre maio de 1961 e novembro de 1962. Os autores utilizaram dois modelos para previsão dos preços: um, baseado em uma RNA sem realimentação, e outro, utilizando a metodologia de previsão ARIMA, que se baseia em princípios estatísticos para encontrar uma fórmula apropriada, para que os erros sejam minimizados e não apresentem padrões. O estudo concluiu que redes neurais obtiveram melhor resultado na previsão dos preços das ações.

Nessa conjuntura, Skabar e Cloete (2002) desenvolveram uma metodologia, utilizando redes neurais treinadas para determinar os momentos mais adequados para a compra e venda de ativos financeiros. Os autores utilizaram quatro séries financeiras em que o preço foi comparado com os retornos obtidos por meios de análise de dados aleatórios a partir de cada uma das séries. Os resultados indicaram que o índice Dow Jones foi significativamente mais elevado que o preço esperado da série aleatória, apoiando alegação de que algumas séries financeiras não são inteiramente aleatórias.

O trabalho de Ferreira, Vasconcelos e Adeodato (2005) apresentou um novo método de previsão a partir de séries temporais, que realiza um processo evolutivo, com o intuito de procurar um número mínimo necessário de dimensões a serem considerados no problema de determinar as características espaciais da série histórica. O método proposto consiste em um modelo híbrido inteligente composto de uma rede neural artificial. O erro médio obtido com a modelo foi de 1,85, o que sugere que redes neurais são capazes de prever a série o mercado de ações com precisão significativa.

Nesse contexto, a pesquisa de Oliveira, Nobre e Zárte (2013) propôs o desenho de um modelo baseado em RNA que permitiu prever o comportamento dos preços no curto prazo das ações da Petrobrás, através da combinação de análise técnica, fundamentalista e de séries temporais. Os autores obtiveram níveis de predição acima de 84% em todos os modelos construídos, sendo que o melhor resultado na previsão de preços da PETR4 foi de 93,62%.

Sob a mesma ótica, o estudo de Franco e Steiner (2014) utilizou modelos de redes neurais artificiais para previsão de séries temporais financeiras. Foi feito um experimento com o intuito de testar as redes em várias situações, principalmente no que diz respeito ao número de neurônios na camada oculta e às variações dos pesos iniciais. Para as simulações foram escolhidas as dez ações de maior peso na composição do Índice Bovespa e os dados de entrada da rede foram as cotações históricas das ações escolhidas. Os autores concluíram que as redes mostradas estão aptas a fazer previsões de razoável acuidade, mesmo em momentos de volatilidade no mercado.

O trabalho de Arnerić, Poklepović e Aljinović (2014) desenvolveu um modelo de rede neural que pôde capturar a relação não linear existente entre históricos de retornos e variância condicional de ações obtidas a partir do Índice CROBEX da Bolsa de Valores de Zagreb. Os autores conseguiram comprovar a superioridade da estimação da variância dos retornos das ações a partir do método de redes neurais em relação a técnicas tradicionais.

Sumarti e Wahyudi (2014) estudaram o processo de tomada de decisão na negociação de ações e opções com a utilização de redes neurais para uma carteira simulada. A partir de seus resultados, os autores concluíram que o método apresenta uma boa capacidade em prever o preço dos ativos, e que a carteira simulada obteve retornos consideráveis. Nessa mesma linha, a pesquisa de Dash, Dash e Bisoi (2015) utilizou redes neurais na previsão e modelagem precisa de dados financeiros. O modelo proposto pelos autores foi comparado com outras técnicas de previsão de séries temporais e os resultados indicaram que redes neurais oferecem melhorias significativas no desempenho da previsão de volatilidade.

3 METODOLOGIA

Nesta seção, dividida em quatro subseções, foram abordadas a classificação da pesquisa, a definição da amostra e dos dados, além da descrição das variáveis e do modelo de rede neural que foram adotados.

3.1. Definição da pesquisa

O presente estudo é classificado, quanto à forma e abordagem do problema, como quantitativo, visto que são empregadas técnicas matemáticas com o intuito de atingir alguma representatividade numérica.

No que tange ao universo da matriz teórica e dos objetivos, esta pesquisa se caracteriza como descritiva. Gil (2002) afirma que as pesquisas descritivas buscam essencialmente descrever as características de determinada população ou fenômeno, assim como estabelecer relações entre variáveis. Selltiz (1967) complementa, expondo que este tipo de pesquisa também estuda o relacionamento de algo em relação a alguma outra coisa, possibilitando verificar a frequência de acontecimentos, e possibilitando criar mecanismos de previsão.

No que se refere à amostra e aos dados, esta investigação utilizou dados secundários coletados no banco de dados Económica e nos sites da Associação Nacional dos Fabricantes

de Veículos Automotores (ANFAVEA), do Banco Central do Brasil (BACEN), da Bolsa de Valores, Mercadorias e Futuros de São Paulo (BM&FBovespa), e da Fundação Getúlio Vargas (FGV). O conjunto de amostras foi selecionado com base no trabalho de Oliveira, Nobre e Zárte (2013), que propôs o desenho de um modelo baseado em RNA que permitiu prever o comportamento dos preços das ações da Petrobrás. Segundo os autores, o modelo de rede neural criado por eles pode ser adaptado para tentar prever o comportamento de outras ações, fato esse que inspirou o presente estudo. Com isso, a amostra foi composta pelos preços das ações das demais empresas brasileiras que compõem o setor de Petróleo e Gás da BM&FBovespa, o que fez com que a amostra final se envolva cinco empresas, conforme o Quadro 1.

Quadro 1 – Empresas que compõe a amostra do estudo

Empresa	Código	Setor	Segmento
Companhia de Gás de São Paulo	CGAS5	Petróleo e Gás	Exploração, Refino e Distribuição
OGX Petróleo	OGXP3	Petróleo e Gás	Exploração, Refino e Distribuição
Refinaria de Petróleos Manguinhos	RPMG3	Petróleo e Gás	Exploração, Refino e Distribuição
PetroRio	PRIO3	Petróleo e Gás	Exploração, Refino e Distribuição
Queiroz Galvão Exploração e Produção	QGEP3	Petróleo e Gás	Exploração, Refino e Distribuição

Fonte: Elaborado pelos autores.

Os dados históricos consistem nas observações de variáveis no período de janeiro de 2010 a dezembro de 2015. O período escolhido se deve ao fato de que os anos de 2008 e 2009 poderiam ocasionar alta volatilidade nos ativos devido à crise do mercado financeiro internacional. A periodicidade das informações é mensal, visto que a maioria das variáveis selecionadas tiveram suas séries históricas disponibilizadas mensalmente, conforme apontam Oliveira, Nobre e Zárte (2013).

3.2 Definição das variáveis

As variáveis que compuseram o conjunto de dados necessários para construir o modelo de rede neural foram: o preço de abertura, o preço de fechamento, o preço mínimo, o preço máximo, a média móvel, as Bandas de *Bollinger*, o volume, o Índice *On Balance Volume* (OBV), o nível de emprego, o preço do Petróleo *Brent*, as vendas de automóveis do mercado interno, o Índice de Confiança do Consumidor, os estoques finais de petróleo dos Estados Unidos, a participação de investidores, a Taxa de juros do Certificado de Depósito Interbancário (CDI), a Taxa de Juros Selic, o Índice de Commodities energéticas do Brasil, o Índice The New York Stock Exchange (NYSE), o Moving Average Convergence Divergence (MACD), o indicador *Momentum*, a Faixa Percentual de *Williams*, o Oscilador Estocástico, o Índice de Força relativa e a variação percentual do dólar, conforme o estudo de Oliveira, Nobre e Zárate (2013), totalizando 24 variáveis. O quadro 2 apresenta o resumo dessas variáveis, bem como suas respectivas definições e fontes.

Quadro 2 - Resumo das variáveis do estudo

Nome	Definição	Fonte
Preço de abertura	Preço de abertura da ação no mês em questão.	Economática
Preço de fechamento	Preço de fechamento da ação no mês em questão.	Economática
Preço mínimo	Preço mínimo da ação no mês no mês em questão.	Economática
Preço máximo	Preço máximo da ação no mês em questão.	Economática
Média móvel	Média móvel dos preços da ação no mês em questão.	Economática
Bandas de <i>Bollinger</i>	Bandas de desvio padrões, de 10 pontos percentuais, acima e abaixo de uma média móvel, em relação aos preços de fechamento, auferindo-se o caminho do ciclo do comportamento do título.	Economática
Volume	Resultado da soma das cotações de fechamento no mês em questão, dividida pela quantidade de dias deste mês.	Economática
Índice <i>On Balance Volume</i> (OBV)	Relaciona o volume com as mudanças de preços. De modo que, quando o preço da ação fecha o período em baixa, o valor do volume do período é subtraído ao indicador; quando o preço da ação fecha o período em alta, o valor do	Economática

	volume do período é somado ao indicador e, quando o preço da ação é estável durante o período, o volume do período não é adicionado nem subtraído do indicador.	
Índice do Nível de Emprego Formal	Índice do Banco Central que mede a quantidade de vagas de empregos formais preenchidas.	BACEN
Preço do Petróleo <i>Brent</i>	Preço do petróleo extraído no Mar do Norte e comercializado na Bolsa de Valores de Londres.	Economática
Vendas de automóveis	Quantidade mensal de automóveis novos vendidos no Brasil. Considera apenas os veículos e comerciais leves.	ANFAVEA
Índice de Confiança do Consumidor	Mede a confiança do consumidor na sua capacidade de compra e na situação do país, abordando expectativas em relação à inflação, ao desemprego e a rendimentos futuros.	FGV
Estoques Finais Petróleo EUA	Quantidade de óleo e produto que está disponível em armazenamento nos Estados Unidos.	Economática
Participação de investidores	O percentual de participação do maior investidor nas distribuições públicas de ações da amostra.	Economática
Taxa de juros CDI	Calculada com base nas operações de emissão de depósitos entre bancos pré-fixados, e representa as condições de liquidez do mercado.	BACEN
Taxa de juros Selic	Taxa do Sistema Especial de Liquidação e Custódia (SELIC) que é tida como referência para as operações financeiras de crédito no mercado.	BACEN
Índice de Commodities energéticas do Brasil	Verifica as variações de preços de produtos básicos com cotação internacional (commodities), para avaliar os efeitos na inflação do Brasil.	BACEN
Índice <i>The New York Stock Exchange (NYSE)</i>	Índice que reflete o valor de mercado das ações comercializadas na Bolsa de Valores de Nova York	Economática
<i>Moving Average Convergence Divergence (MACD)</i>	É um oscilador de média móvel, que utiliza a relação entre 2 médias móveis exponenciais de 12 e 26 períodos. O sinal de compra é gerado quando a média móvel de 12 (rápida) períodos cruza de baixo para cima a média de 26 (lenta)	Economática

	períodos, estando abaixo da linha de gatilho (média de 9 períodos da diferença entre as medias 12/26). O sinal de venda, por sua vez, é disparado, quando a média móvel mais rápida (12) cruza para baixo da média mais lenta de (26), estando acima da linha de gatilho.	
Indicador <i>Momentum</i>	Mede o quanto o preço de uma ação mudou durante certo período de tempo, a partir da diferença entre o preço de fechamento atual e o preço de fechamento de n dias atrás.	Economática
Faixa Percentual de <i>Williams</i>	Determina as zonas de compra ou venda de um ativo, através de possíveis pontos de mudança.	Economática
Oscilador Estocástico	Técnica de mensuramento da velocidade dos preços, baseada na teoria de que, à medida que os preços sobem, os fechamentos têm a tendência de posicionarem-se mais próximos das altas do período. Similarmente, se os preços descem, os fechamentos tendem a se aproximar das baixas. Este indicador varia entre 0 e 100. A região de sobrecompra fica próxima a 100 e a região de sobrevenda próxima a 0.	Economática
Índice de Força Relativa	Mede a evolução da relação de forças entre compradores e vendedores ao longo do tempo. Sua utilização possibilita observar o enfraquecimento de uma tendência, rompimentos, suporte e resistência antes de se tornarem aparentes no gráfico de barras. O estudo é desenhado em uma faixa paralela, com o formato de uma curva simples e seu domínio está entre 0 e 100.	Economática
Variação Percentual Dólar	Cotação da moeda norte-americano (US\$) com paridade na moeda brasileira (R\$), utilizado como parâmetro de pagamento nas transações com exportações e importações de produtos do e para o Brasil.	BACEN

Fonte: Elaborado pelos autores.

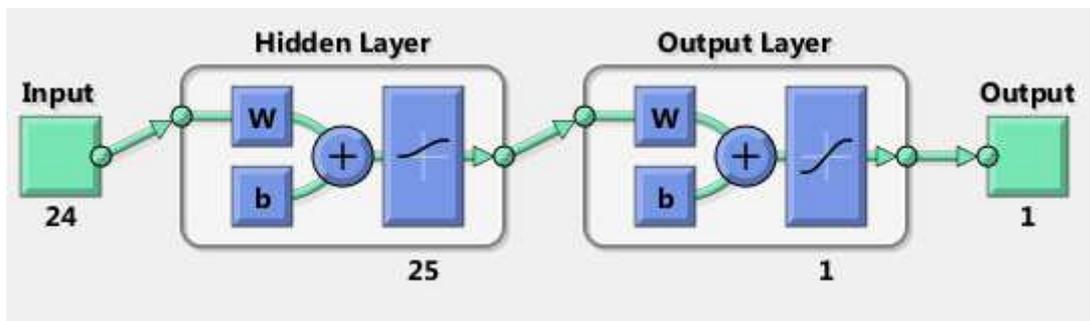
Tendo em mente a amostra e a formatação da pesquisa, faz-se necessária uma descrição mais detalhada da ferramenta utilizada, que são as redes neurais artificiais.

3.3 Modelo de rede neural

Para realizar a previsão do preço de fechamento das ações das empresas selecionadas na amostra, foi utilizado o modelo de rede neural *feedforward* Multicamadas, conforme proposto por Oliveira, Nobre e Zárte (2013), que afirmam que esse tipo de rede possui eficiência no processo de previsão de séries temporais, e capacidade inerente de aprender e reconhecer a partir de dados não lineares. Dessa maneira, foi construído um modelo de rede neural para prever as ações de cada uma das empresas que compuseram a amostra do presente estudo.

Para treinamento e teste da rede neural, foram utilizados os preços das ações que compõem a amostra. Com isso, 75% dos dados da rede foram utilizados para treinamento, 10% para validação e 15% para teste. A estrutura da rede é composta por três camadas, incluindo uma camada de entrada, uma camada oculta e uma camada de saída, conforme a figura 1.

Figura 1 – Estrutura da rede neural



Fonte: Elaborado pelos autores.

O número de Neurônios na camada de entrada é igual à quantidade de variáveis que compuseram o conjunto de dados necessários para construir o modelo de rede, ou seja, 24 camadas, visto que foram utilizadas 24 variáveis. Já o número de neurônios na camada de saída é de apenas um, visto que foi o valor das ações de cada empresa previsto pela rede neural. Por fim, tem-se o número de neurônios da camada oculta, que foi determinado conforme a equação abaixo:

$$2\sqrt{(m + 2)N}$$

Em que m e N representam o número de neurônios da camada de saída e da camada de entrada, respectivamente. Esta equação foi proposta por Huang (2003) e foi utilizada pois, segundo Oliveira, Nobre e Zárte (2013), seu uso melhora o processo de aprendizagem em rede. Com isso, o modelo de rede neural foi composto por 17 camadas ocultas. O algoritmo escolhido para o treinamento da rede foi o *Backpropagation* que, na concepção dos autores, procura eliminar a influência negativa de derivativos parciais no ajuste dos pesos.

Para avaliar o desempenho do modelo neural, as quatro medidas utilizadas na pesquisa de Oliveira, Nobre e Zárte (2013) também foram selecionadas, sendo elas o Erro Médio Percentual Absoluto (MAPE), que é a média dos erros percentuais absolutos das previsões e se mostra bastante didático, pois fornece os erros médios em percentuais, calculado através da equação abaixo:

$$MAPE = \frac{100}{N} \sum_{t=1}^N \left| \frac{target_t - output_t}{output_t} \right|$$

O Erro Quadrático Médio (MSE) é a média do somatório dos quadrados dos erros obtidos pela rede neural. Para um dado conjunto de treinamento, esse erro representa uma função de custo, isto é, uma medida de desempenho da rede neural que é empregado como um indicador para o poder preditivo do modelo, de modo que, quanto mais próximo o resultado for de zero, melhor será esse poder de previsão, sendo calculado através da equação abaixo:

$$MSE = \frac{1}{N} \sum_{t=1}^N (target_t - output_t)^2$$

O Coeficiente U de THEIL serve para medir o quanto os resultados são mais eficazes do que uma previsão ingênua ou trivial. Se o coeficiente de THEIL for igual a um, o modelo testado tem o mesmo desempenho de uma escolha aleatória; caso o resultado for maior do que um, o modelo tem um desempenho inferior a uma escolha aleatória e, se o coeficiente for menor do que um, o modelo de previsão é superior a uma escolha aleatória. Quanto mais próximo o valor obtido for de zero, melhor será o resultado do modelo de previsão. O coeficiente de THEIL é calculado através da equação abaixo:

$$THEIL = \frac{\sum_{t=1}^N (target_t - output_t)^2}{\sum_{t=1}^N (output_t - output_{t-1})^2}$$

E por fim a Porcentagem de Correta Previsão Direcional (POCID), que mede o percentual de acerto quanto à tendência da série, com o intuito de se prever as alterações da direção, ou seja, se o valor futuro irá subir ou cair em relação ao valor atual, de maneira que, quanto mais próximos estiverem os valores de 100, melhor será o Modelo de previsão, conforme equação abaixo:

$$POCID = 100 \frac{\sum_{t=1}^N D_t}{N}$$

Em que $D = 1$, se $(target_t - target_{t-1}) (output_t - output_{t-1}) > 0$ e $D = 0$, se $(target_t - target_{t-1}) (output_t - output_{t-1}) < 0$. A seguir, tem-se a discussão e análise dos resultados da pesquisa.

4 RESULTADOS E DISCUSSÕES

A análise e discussão dos resultados tem início com o detalhamento das funções de ativação adotadas no processo de aprendizagem. Foram utilizadas a função sigmoideal, que faz com que a saída do neurônio seja normalizada entre 0 e 1, com o objetivo de gerar estabilidade no sistema, evitando que os pesos variem muito depois que o valor da saída já se encontra próximo a um dos extremos, e a tangente hiperbólica, que preserva a forma sigmoideal da função logística, mas assume valores positivos e negativos, -1 e 1 (RUMELHART; HINTON; WILLIAMS, 1986).

Com isso, foi obtido um total de 150 observações para as cinco empresas estudadas no período de janeiro de 2011 a dezembro de 2015. A quantidade de observações de dados obtida para cada empresa, como também os resultados alcançados pelas quatro medidas de erro utilizadas na pesquisa para avaliar o desempenho do modelo neural são expostos na tabela 1.

Tabela 1 – Comparação dos resultados obtidos pelo modelo de rede neural

	MAPE	MSE	THEIL	POCID	Quantidade de observações
Companhia de Gás de São Paulo OGX Petróleo	0,1576	0,0106	0,0926	41,6667	25
Refinaria de Petróleos Manguinhos PetroRio Queiroz Galvão	1,5442	0,0899	0,1729	21,4286	28
Exploração e Produção	7,1357	0,2975	0,4392	61,5385	13
	1,9865	0,1067	0,2165	38,2979	47
	0,2456	0,0067	0,1496	60	15

Fonte: Resultados da pesquisa.

Percebe-se, através dos resultados expostos na tabela 1, que as empresas obtiveram um baixo nível de Erro Médio Percentual Absoluto (MAPE), visto que o maior nível de erro alcançado foi na previsão da ação da Refinaria de Petróleos Manguinhos (RPMG3), que resultou em um MAPE de 7,14%. Esse resultado demonstra que o modelo de rede neural proposto foi capaz de prever 92,86% do comportamento desse papel e foi semelhante ao obtido por Oliveira, Nobre e Zárte (2013), que revelou um MAPE de 5,45%, alcançando um poder de previsão de 94,55% na ação da Petrobrás (PETR4).

As demais ações analisadas obtiveram um MAPE ainda mais baixo sendo, respectivamente, 1,99% para a ação da PetroRio (PRIO3), 1,54% para a OGX Petróleo (OGXP3), 0,25% para a Queiroz Galvão Exploração e Produção (QGEP3) e 0,16% para a Companhia de Gás de São Paulo (CGAS5). Tais resultados demonstram um poder de previsão do modelo de 98,01%, 98,46%, 99,75% e 98,84% respectivamente.

Analisando o Erro Quadrático Médio (MSE), percebe-se que o modelo de rede neural obteve maior poder de previsão para as ações QGEP3 e CGAS5, alcançando os seguintes resultados, respectivamente: 0,0067 e 0,0106. Apesar de um pouco maior, a pesquisa de

Oliveira, Nobre e Zárate (2013) obteve valor de MSE semelhante na previsão da PETR4, sendo de, aproximadamente, 0,04037.

As demais empresas estudadas obtiveram valores de MSE um pouco mais elevados, sendo 0,0899 para a OGXP30, 0,2975 para RPMG3 e 0,1067 para a PRIO3. Percebe-se uma perda de poder de predição do modelo proposto nesses três papéis, principalmente quando comparados com os obtidos no trabalho de Franco e Steiner (2014), por exemplo, que encontrou um MSE de aproximadamente 0,0645. Visto que os valores de MSE alcançados foram próximos de zero, sugere-se um bom poder de previsão para o modelo proposto.

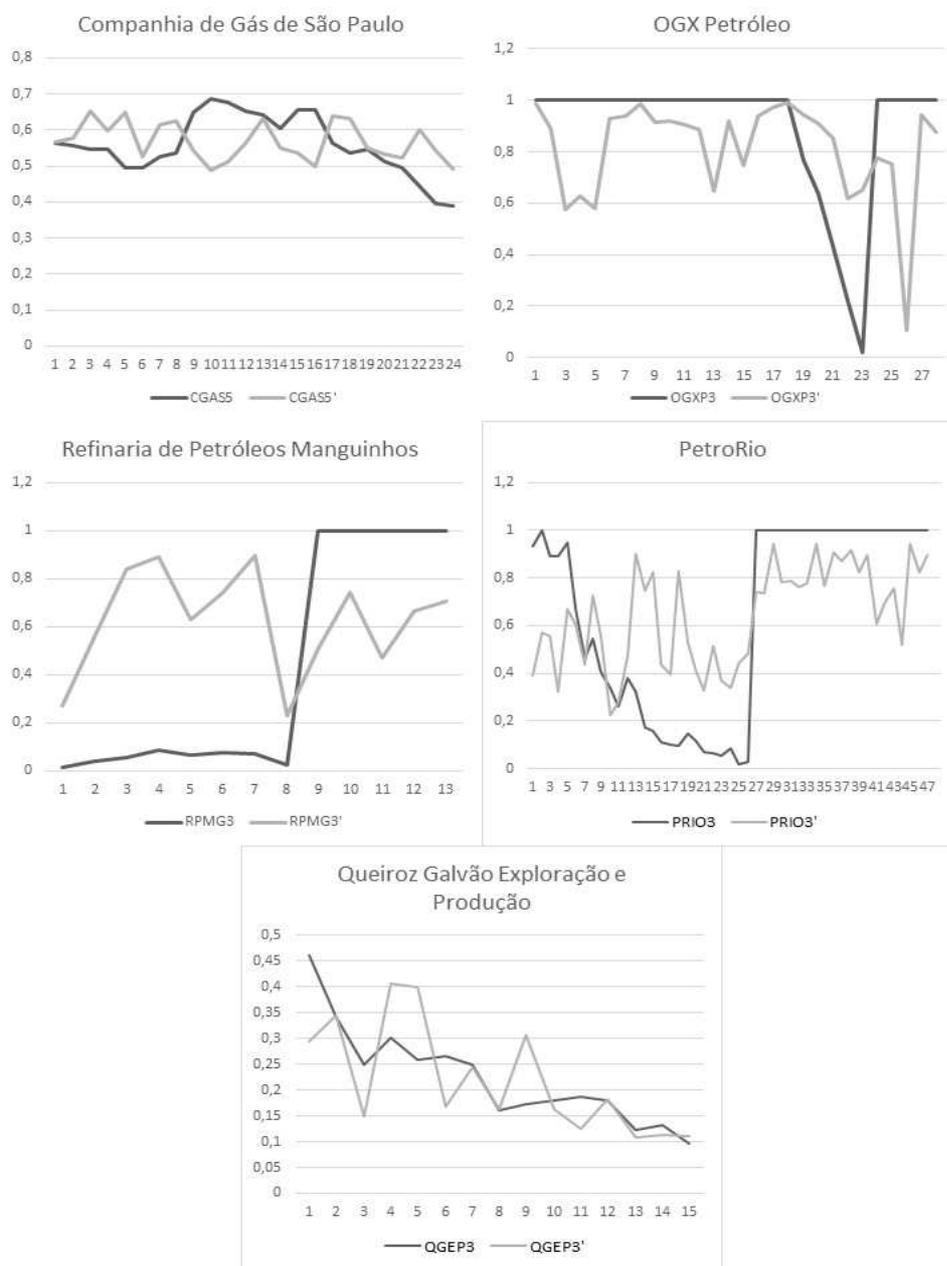
O estudo segue com a análise do Coeficiente U de Theil que, conforme comentado na metodologia, mede o quanto os resultados são mais eficazes do que uma previsão ingênua ou trivial. Todos os resultados alcançados a partir desta métrica foram menores que 1 (CGAS5 = 0,0926; OGXP3 = 0,1729; RPMG3 = 0,4392; PRIO3 = 0,2165; QGEP3 = 0,1496). Sugere-se, com isso, que o modelo de rede neural utilizado no presente estudo é mais eficaz para previsão das ações das empresas estudadas do que uma escolha feita de maneira aleatória. Vale ressaltar que os resultados foram inferiores, quando comparados aos alcançados no estudo de Oliveira, Nobre e Zárate (2013), que obteve um Coeficiente U de THEIL mais próximo de zero na previsão da ação da Petrobrás, sendo de, aproximadamente, 0,0261.

Em seguida, têm-se os resultados alcançados pela métrica da Porcentagem de Correta Previsão Direcional (POCID). Tais resultados não foram satisfatórios para três das ações estudadas, sendo elas a CGAS5, a OGXP3 e a PRIO3 que obtiveram percentuais de POCID de aproximadamente, 41,67%, 21,43% e 38,3%, respectivamente. Já os resultados alcançados na previsão das ações da RPMG3 e da QGEP3 foram satisfatórios, sendo de, aproximadamente, 61,54% e 60%, respectivamente. Entretanto, vale ressaltar que, apesar de satisfatórios, esses últimos resultados foram inferiores ao encontrado na pesquisa de Oliveira,

Nobre e Zárate (2013), que obteve um percentual de POCID no valor de 93.62% na previsão da ação PETR4.

Por fim, tem-se a exposição da figura 1, que expõe uma comparação entre os dados reais dos preços das ações das empresas estudadas e os valores alcançados pelo modelo de rede neural proposto pelo estudo, a partir da métrica MSE.

Figura 01 - Comparação dos dados reais com os previstos



Fonte: elaborado pelos autores.

A partir da figura 1, percebe-se que os dados obtidos pelo modelo de previsão e os dados reais seguem a mesma tendência em três das ações estudadas, sendo elas a RPMG3, a OGXP3 e a CGAS5. Na primeira, porém, existe um ponto de divergência, em que o modelo de previsão acusou um ponto de alta, mas que, na verdade, a ação manteve-se baixa. Apesar dessa diferença, pode-se concluir através da análise dos gráficos que os resultados alcançados pelo modelo de rede neural foram satisfatórios na previsão do preço dessas ações.

Entretanto, o mesmo não se pode dizer das ações PRIO3 e QGEP3 que, conforme os gráficos da figura 1, percebe-se a existência de diversos pontos de divergência entre os preços reais dessas ações e os valores obtidos pelo modelo de rede neural na previsão das mesmas.

5. CONSIDERAÇÕES FINAIS

O presente estudo teve como objetivo desenvolver um modelo de redes neurais artificiais baseado no modelo de Oliveira, Nobre e Zárte (2013) para previsão de preços das ações das empresas brasileiras do setor de petróleo e gás da BM&FBovespa.

Para alcançar este objetivo, e conforme orientação dos citados autores, a amostra do estudo foi composta pelos preços das ações das empresas brasileiras que compõem o setor de Petróleo e Gás da BM&FBovespa (exceto a Petrobrás), sendo elas a Companhia de Gás de São Paulo (CGAS5), a OGX Petróleo (OGXP3), a Refinaria de Petróleos Manguinhos (RPMG3), a PetroRio (PRIO3) e a Queiroz Galvão Exploração e Produção (QGEP3). As variáveis que compuseram o conjunto de dados foram as 24 utilizadas na pesquisa de Oliveira, Nobre e Zárte (2013), e os dados históricos referiram-se a observações de variáveis no período de janeiro de 2010 a dezembro de 2015.

Os primeiros resultados encontrados demonstraram que as empresas obtiveram um baixo nível de Erro Médio Percentual Absoluto (MAPE), (RPMG3 = 7,14%; PRIO3 = 1,99%; OGXP3 = 1,54%, QGEP3 = 0,25%; CGAS5 = 0,16%). Tais resultados sugerem que o modelo de rede neural proposto no estudo foi capaz de prever 92,86%, 98,01%, 98,46%, 99,75% e 98,84%, respectivamente, do comportamento dessas ações e foi semelhante ao obtido na pesquisa dos autores base, que obtiveram um MAPE de 5,45%, alcançando um poder de previsão de 94,55% na previsão da ação da Petrobrás (PETR4).

Analisando os resultados obtidos a partir do Erro Quadrático Médio (MSE), percebeu-se que o modelo de rede neural obteve maior poder de previsão para as ações QGEP3 e CGAS5, alcançando os seguintes resultados respectivamente: 0,0067 e 0,0106. Apesar de um pouco maior, a pesquisa de Oliveira, Nobre e Zárte (2013) obteve valor de MSE semelhante na previsão da PETR4, aproximadamente 0.04037.

As demais empresas estudadas obtiveram valores de MSE um pouco mais elevados, sendo 0,0899 para a OGXP30, 0,2975 para RPMG3 e 0,1067 para a PRIO3. Percebe-se uma perda de poder de predição do modelo proposto nesses três papéis, principalmente quando comparados com os obtidos no trabalho de Franco e Steiner (2014), por exemplo, que encontrou um MSE de, aproximadamente, 0,0645. Visto que os valores de MSE alcançados

foram próximos de zero, atribui-se um bom poder de previsão para o modelo proposto.

Em seguida foi feita a análise do Coeficiente U de Theil, em que todos os resultados alcançados foram menores que 1 (CGAS5 = 0,0926; OGXP3 = 0,1729; RPMG3 = 0,4392; PRIO3 = 0,2165; QGEP3 = 0,1496), achados esses que sugerem que o modelo de rede neural utilizado no presente estudo é mais eficaz para previsão das ações das empresas estudadas do que uma escolha feita de maneira aleatória. Vale ressaltar que os resultados foram inferiores quando comparados ao alcançados no estudo de Oliveira, Nobre e Zárte (2013), que obteve um Coeficiente U de THEIL mais próximo de zero na previsão da ação da Petrobrás, sendo de cerca de 0,0261.

Adicionalmente têm-se os resultados alcançados pela métrica da Porcentagem de Correta Previsão Direcional (POCID). Tais resultados não foram satisfatórios para três das ações estudadas, sendo elas a CGAS5, a OGXP3 e a PRIO3 que obtiveram percentuais de POCID de, aproximadamente, 41,67%, 21,43% e 38,3% respectivamente. Já os resultados alcançados na previsão das ações da RPMG3 e da QGEP3 foram satisfatórios, sendo de cerca de 61,54% e 60% respectivamente. Entretanto, vale ressaltar que, apesar de satisfatórios, esses últimos resultados foram inferiores ao encontrado na pesquisa dos autores base, que obtiveram um percentual de POCID no valor de 93,62% na previsão da ação PETR4.

Por fim, foi exposta uma comparação entre os dados reais dos preços das ações das empresas estudadas e os valores alcançados pelo modelo de rede neural proposto pelo estudo a partir da métrica MSE. Observou-se que os dados obtidos pelo modelo de previsão e os dados reais seguiram a mesma tendência em três das ações estudadas, sendo elas a RPMG3, a OGXP3 e a CGAS5. Entretanto, o mesmo não se pôde dizer das ações PRIO3 e QGEP3 que, apontaram diversos itens de divergência entre os preços reais dessas ações e os valores obtidos pelo modelo de rede neural na previsão das mesmas.

A partir dos resultados alcançados neste estudo, concluiu-se que o modelo de rede neural para previsão dos preços das ações selecionadas obteve resultados satisfatórios. Com isso, sugere-se que as redes neurais artificiais são uma ferramenta eficaz na previsão do comportamento do mercado de ações brasileiro para os dados, amostra e período investigado.

Ressalta-se, por oportuno, vale ressaltar que o modelo de rede construído com base no estudo de Oliveira, Nobre e Zárte (2013) pode ser adaptado para estudar outras ações, e não somente as que fazem parte do setor escolhido no presente estudo. Sugere-se então que, em pesquisas futuras, este modelo seja testado com alterações na escolha das variáveis setoriais, bem como sejam feitas adaptações no modelo de rede, com utilização de diferentes quantidades de neurônios na camada oculta, para que se possa alcançar resultados cada vez

mais satisfatórios na previsão do comportamento das ações dos diversos mercados e bolsas de valores existentes.

REFERÊNCIAS

ARNERIĆ, J.; POKLEPOVIĆ, T.; ALJINOVIĆ, Z. GARCH based artificial neural networks in forecasting conditional variance of stock returns. **Croatian Operational Research Review**, v. 5, n. 2, p. 329–343, 2014.

BEKAERT, G.; GARCIA, M. G. P.; HARVEY, O. R. **The role of capital markets in economic growth**. Rio de Janeiro: PUC, 1995. (Texto para discussão n. 342).

BODYANSKIY, Y.; POPOV, S. Neural network approach to forecasting of quasiperiodic financial time series. **European Journal of Operational Research**, v. 175, p. 1357-1366, 2005.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2011.

CAVALHEIRO, E. A.; CERETTA, P. S.; TAVARES, C. E. M.; TRINDADE, L. L. Previsibilidade de mercados: um estudo comparativo entre Bovespa e s&p500. **Sociais e Humanas**, v. 23, n. 1, p. 61-74, 2010.

CHURCHLAND, P. S.; SEJNOWSKI, T. J. **The computational brain**. Cambridge: MIT Press, 1992.

DASH, R.; DASH, P. K.; BISOI, R. A differential harmony search based hybrid interval type2 fuzzy EGARCH model for stock market volatility prediction. **International Journal of Approximate Reasoning**, v. 59, p. 81–104, 2015.

FAMA, E.F. Efficient capital markets: a review of theory and empirical work. **The Journal of Finance**, v. 25, p. 383-417, 1970.

FERREIRA, T. A. E.; VASCONCELOS, G. C.; ADEODATO, P. J. L. A new evolutionary method for time series forecasting. In: Genetic evolutionary computation conference, x.; 2005, Washington. **Anais...** Washington: GECCO, 2005.

FERSON, W. E.; SARKISSIAN, S.; SIMIN, T. Asset pricing models with conditional betas and alphas: The effects of data mining and spurious regression. **Journal of Financial and Quantitative Analysis**, v. 43, n. 2, p. 331-353, 2008.

FRANCO, D. G. B.; STEINER, M. T. A. Estudo comparativo de redes neurais artificiais para previsão de séries temporais financeiras. In: Simpósio de pesquisa operacional e logística da marinha, xvii.; 2014, São Paulo. **Anais...** São Paulo: SPOLM, 2014.

GIL, A. C. **Como Elaborar Projetos de Pesquisa**. São Paulo: Atlas, 2002.

GURESEN, E.; KAYAKUTLU, G.; DAIM, T. U. Using artificial neural network models in

stock market index prediction. **Expert Systems with Applications**, v. 38, n. 8, p. 10389-10397, 2011.

HAIR, J. F.; BABIN, B.; MONEY, A. H.; SAMOUEL, P. **Fundamentos de Métodos de Pesquisa em Administração**. Porto Alegre: Bookman, 2005.

HAYKIN, S. **Redes Neurais Princípios e Prática**. Porto Alegre: Bookman, 2001.

HUANG, G. B. Learning capability and storage capacity of two-hidden-layer feedforward networks. **IEEE Transactions on Neural Networks**, v. 14, n 2, p. 274-281, 2003.

KOLARIK, T.; RUDORFER, G. Time series forecasting using neural networks. **ACM Sigapl Apl Quote Quad**, v. 25, n. 1, p. 86-94, 1994.

MALIK, F.; NASEREDDIN, M. Forecasting output using oil prices: A cascaded artificial neural network approach. **Journal of Economics and Business**, v. 58, n. 2, p. 168-180, 2006.

NUNES, M.; COSTA JR, N.; MEURER, R. A relação entre o mercado de ações e as variáveis macroeconômicas: uma análise econométrica para o Brasil. **Revista Brasileira de Economia**, v. 59, n. 4, p. 585-607, 2005.

OLIVEIRA, F. A.; NOBRE, C. N.; ZÁRATE, L. E. Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index – Case study of PETR4, Petrobras, Brazil. **Expert Systems with Applications**, v. 40, p. 7596-7606.

PALIWAL, M.; KUMAR, U. A. Neural networks and statistical techniques: A review of applications. **Expert Systems with Applications**, v.36, n.1 p. 2-17, 2009.

PAO, H. T. A comparison of neural network and multiple regression analysis in modeling capital structure. **Expert Systems with Applications**, v. 35, n. 3, p. 720-727, 2008.

PENDHARKAR, P. C. A threshold-varying artificial neural network approach for classification and its application to bankruptcy prediction problem. **Computers and Operations Research**, v.32, p. 2561-2582, 2005.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning Internal Representations by Error Propagation**. Cambridge: The MIT Press, 1986.

SELLTIZ, C., JAHODA, M., DEUTSCH, M., COOK, S.M. **Métodos de Pesquisa nas Relações Sociais**. São Paulo: Editora Herder, 1967.

SKABAR, A.; CLOETE, I. Neural networks, financial trading and the efficient markets hypothesis. In: Australasian conference on computer science, xxv.; 2002, Darlinghurst. **Anais...** Darlinghurst: ACSC, 2002.

SUMARTI, N.; WAHYUDI, N. Stock and option portfolio using fuzzy logic approach. In: **International Journal of Approximate Reasoning**, IV.; 2012, Bandung. **Anais...** Bandung: ICMNS, 2014.

WHITE, H. Economic prediction using neural networks: The case of IBM daily stock returns.

International on Neural Networks, v. 2, p. 451-458.

Como Referenciar este Artigo, conforme ABNT:

MUNTASER, J. G. S; SILVA, V. P; PENEDO, A. S. T. Aplicação de Redes Neurais na Previsão das Ações do Setor de Petróleo e Gás da Bm & FBovespa. **Rev. FSA**, Teresina, v.14, n.6, art.3, p. 49-71, nov./dez. 2017.

Contribuição dos Autores	J. G. S. Muntaser	V. P. Silva	A. S. T. Penedo
1) concepção e planejamento.	X	X	X
2) análise e interpretação dos dados.	X	X	X
3) elaboração do rascunho ou na revisão crítica do conteúdo.	X	X	X
4) participação na aprovação da versão final do manuscrito.	X	X	X