APLICAÇÃO DE REDES NEURAIS PARA A PREDIÇÃO NO MERCADO DE AÇÕES NACIONAL

Renato Elias Santana
Pontifícia Universidade Católica de Goiás – PUC/GO
Av. Universitária, 1.440, Setor Universitário, Goiânia – GO – Brasil, 74605-010
renato-e-s@hotmail.com

Maria José Pereira Dantas
Programa de Pós-Graduação *Strictu Sensu* em Engenharia de Produção e Sistemas – PUC/GO
1ª Avenida com Av. Universitária, Qd. 88, nº 904 – Área III, Bloco D - 3º andar - Setor Universitário – Goiânia – GO – Brasil, 74605-010
mjpdantas@gmail.com

Rafael Gomes Loiola
Programa de Pós-Graduação *Strictu Sensu* em Engenharia de Produção e Sistemas – PUC/GO
1ª Avenida com Av. Universitária, Qd. 88, nº 904 – Área III, Bloco D - 3º andar - Setor Universitário – Goiânia – GO – Brasil, 74605-010
rafaelgo.eng@gmail.com

RESUMO

A previsão do mercado de ações sempre foi alvo de grande interesse por parte dos investidores. Isso porque, aqueles que conseguem prever preços futuros ou ao menos predizer tendências de comportamento do mercado possuem grandes vantagens em relação aos outros investidores. Assim, este estudo tem como objetivo a predição do índice da Bolsa de Valores de São Paulo (Ibovespa) através da utilização de Redes Neurais MLP. Para tanto, utilizou-se a série histórica diária de fechamento do índice compreendida entre o período de Janeiro de 2011 a Dezembro de 2015 totalizando 1253 pontos. O algoritmo de treinamento utilizado foi do tipo *Back-propagation*. Foram criadas diversas arquiteturas de rede e aquela que apresentou o melhor desempenho possuía 4 neurônios na camada de entrada, 4 neurônios na camada intermediária e 1 neurônio na camada de saída e os erros de previsão RMSE e MAPE encontrados foram respectivamente de 956,31 e 1,70%.

PALAVRAS CHAVE. Redes Neurais MLP, Ibovespa, *Back-propagation*.

Área Principal: GF - Gestão Financeira

ABSTRACT

Predicting the stock market has always been a great target interest from investors. This is because those who predict future prices or at least predict market behavior trends have major advantages over other investors. This study aims to predict the index of the São Paulo Stock Exchange (Ibovespa) by using Neural Networks MLP. For this, we used the daily time series of closing index between the period January 2011 to December 2015 a total of 1253 points. The training algorithm used was at the back-propagation type. Various network architectures have been created and the one that presented the best performance had 4 neurons in the input layer 4 neurons in the hidden layer and 1 neuron in the output layer and the RMSE and MAPE forecast errors found were respectively 956,31 and 1,70%.

KEYWORDS. Neural Network MLP, Ibovespa, Back-propagation.

Main Area: GF - Financial Management

1. Introdução

Numa economia existem os agentes econômicos superavitários (também conhecidos como poupadores) e os agentes econômicos deficitários. Os agentes superavitários são aqueles que não consomem toda a renda que possuem e dessa forma se dispõem a transformar o excedente em ativos financeiros. Em contrapartida, os agentes deficitários estão dispostos a tomar recursos no mercado para financiar seus investimentos.

Para viabilizar esse processo de oferta e demanda de recursos existe o Sistema Financeiro Nacional (SFN), que é composto por órgãos e instituições financeiras públicas e privadas que, dentre outras funções, fazem a intermediação entre os agentes econômicos supracitados formando, dessa forma, o mercado financeiro. Um importante segmento desse mercado é o mercado de capitais que tem como objetivo suprir as necessidades de investimentos dos agentes econômicos, por meio de diversas modalidades de financiamentos a médio e longo prazos para capital de giro e capital fixo [ASSAF NETO, 2011].

Herling *et al.* [2012, p. 167] afirmam que "ao longo dos anos, o mercado de ações vem atraindo cada vez mais investidores devido ao fato de apresentar rentabilidades muito atraentes em relação às outras possibilidades de investimento, como a caderneta de poupança e títulos de renda fixa".

Sendo assim, uma ferramenta que consiga predizer o futuro ou ao menos demonstrar tendências no mercado de ações é sempre valiosa, pois permite que o investidor antecipe decisões reduzindo possíveis perdas ou aumentando seus ganhos, através de uma simples e preciosa predição dos movimentos de subida e descida nos preços das ações.

É ai que surge a importância das Redes Neurais Artificiais (RNAs). As RNAs são consideradas como instrumentos de apoio nas decisões sobre investimentos devido à capacidade de mapear funções complexas e a possibilidade de prever preços de ações trazendo grandes benefícios para os investidores, principalmente devido às incertezas inerentes aos investimentos em renda variável, e.g., ações, onde o investidor está sujeito às oscilações do mercado financeiro.

Haykin [2001, p. 32] salienta que "uma rede neural é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse [...]". Segundo Silva *et al.* [2010, p. 25] o trabalho pioneiro, em redes neurais, "data de 1943, por meio do artigo elaborado por McCulloch & Pitts [...]". Segundo eles, os autores realizaram a primeira modelagem matemática inspirada no neurônio biológico, resultando-se assim na primeira concepção de neurônio artificial [SILVA *et al.,* 2010].

Assim, o objetivo desta pesquisa é apresentar o uso de redes neurais artificiais para predição no mercado de ações nacional, mais especificamente da série Ibovespa, que é o índice da Bolsa de Valores, Mercadorias e Futuros de São Paulo (BM&FBovespa S.A.). Para tanto, será utilizada uma rede neural artificial do tipo *Perceptron* de múltiplas camadas (*MultiLayer Perceptron* - MLP) com algoritmo de treinamento denominado *Back-propagation* ou algoritmo de retropropagação do erro, através do software Matlab.

O presente artigo está organizado em quatro seções estruturadas da seguinte forma: na seção dois é tratado o referencial teórico, focando o mercado de ações, as redes neurais artificiais, bem como os trabalhos que já aplicaram a técnica no mercado acionário. Na seção três é delineada a metodologia de estudo seguida da apresentação e análise dos resultados, na quarta seção. Por fim, na seção cinco, são apresentadas as conclusões do estudo.

2. Referencial teórico

2.1. Mercado de ações

O mercado de ações brasileiro sofreu algumas alterações nos últimos anos. Até maio de 2008 a bolsa oficial do Brasil era conhecida como Bolsa de Valores de São Paulo (Bovespa). A partir do dia 08 do mês supramencionado, houve a fusão entre a BM&F e a Bovespa culminando

na criação da Bolsa de Valores, Mercadorias e Futuros (BM&FBovespa S.A.), localizada em São Paulo.

Dentro da gama de produtos e serviços que são oferecidos à negociação pela bolsa de valores brasileira estão as ações. Ação é uma parte do capital de uma companhia, ao adquiri-las o acionista se torna coproprietário da sociedade anônima e dessa forma participará dos resultados (positivos ou negativos) gerados pela mesma. É um investimento adequado para quem deseja correr maior risco (volatilidade) no curto prazo em busca de maior rentabilidade no longo prazo [HALFELD, 2001].

Para avaliar o desempenho do mercado de ações brasileiro existe o Índice Bovespa – Ibovespa. O mesmo é resultado de uma carteira teórica de ativos e tem como objetivo refletir o desempenho médio dos negócios a vista ocorridos nos pregões da BM&FBovespa, além de ser o mais importante indicador de desempenho das cotações das ações negociadas no mercado brasileiro [ASSAF NETO, 2011] por isso sua escolha neste trabalho.

2.2. Redes neurais artificiais

Uma rede neural é um processador maciçamente paralelo e distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso [HAYKIN, 2001]. Sendo assim, as RNAs reproduzem o funcionamento do cérebro de maneira simplificada.

No conceito precedente apresentado por Haykin pode-se destacar a importante propriedade de uma rede neural de adaptar suas forças de conexão entre neurônios, conhecidas como pesos sinápticos (armazenadores de conhecimento), a modificações do meio ambiente. Além disso, é possível perceber que uma RNA é constituída por unidades de processamento simples, também conhecidas como neurônios artificiais.

Um neurônio artificial é formado por três elementos, sendo eles: os pesos sinápticos, a função de soma e a função de transferência, também chamada de função de ativação. Seu modelo pode ser visualizado através da Figura 1.

Figura 1 – Neurônio artificial

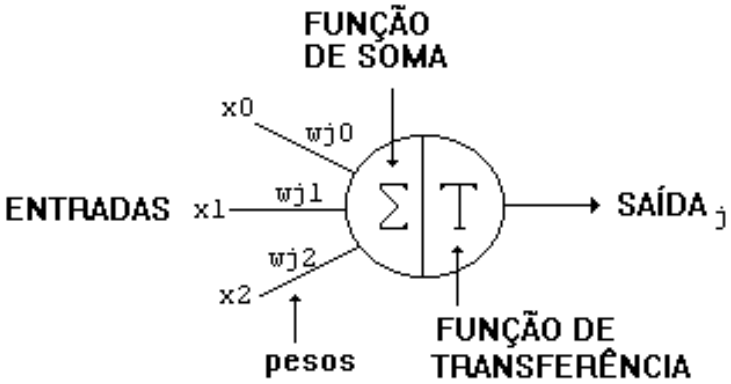

Fonte: Adaptado de Tafner *et al.* [1996]

Onde:

- *x0, x1* e *x2* são os sinais de entrada;
- *wj0, wj1* e *wj2* são os pesos sinápticos aplicados aos sinais de entrada;
- ∑ é a função responsável por realizar a soma ponderada do produto entre as entradas e os respectivos pesos;
- *T* é a função de transferência, também conhecida como função de ativação;

– j é a saída.

Fazendo analogia com o neurônio biológico percebe-se que os dendritos foram substituídos por entradas, as sinapses (ligações com o corpo celular) são representadas no neurônio artificial pelos pesos sinápticos, os estímulos são processados pela função de soma e o limiar de disparo foi substituído pela função de transferência, também conhecida como função de ativação.

A junção de diversos neurônios artificiais forma uma RNA:

Figura 2 – Representação gráfica de uma Rede Neural MLP

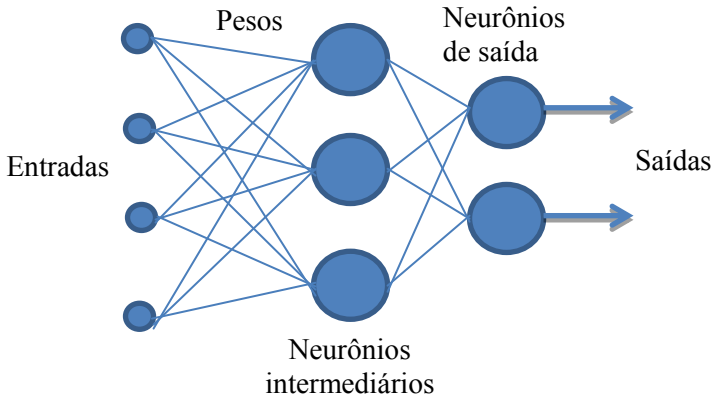

Fonte: Adaptado de Tafner *et al.* [1996]

2.3. Aplicações de redes neurais artificiais no mercado de ações

Diversos pesquisadores em diferentes lugares do mundo se propuseram a utilizar as RNAs no mercado de ações. Quah e Srinivasan [1999] enfatizaram que a seleção de boas ações é de extrema importância para garantir um bom retorno. Nesse contexto, uma ferramenta confiável no processo de seleção pode ser de grande ajuda para os investidores tendo em vista que dará para eles uma grande vantagem competitiva em relação aos outros. Assim, como ferramenta de seleção, tem-se a RNA que com a sua capacidade de generalização comprovada, é capaz de inferir a partir de padrões históricos as características de desempenho das ações.

Cao *et al.* [2005] utilizaram as RNAs para prever o movimento dos preços das ações negociadas no mercado acionário chinês, mais especificamente da bolsa Shenzhen Stock Exchange (SZSE). Em sua pesquisa constataram que a ferramenta é útil para os mercados emergentes, como a China, por exemplo, tendo em vista que os retornos destes mercados são geralmente mais previsíveis do que os retornos dos mercados desenvolvidos.

Faria *et al.* [2008] estudaram a técnica na previsão da série temporal do Ibovespa. Para tanto utilizaram a rede *MultiLayer Perceptrons* com algoritmo *Back-propagation* para fazer previsões do índice. Os dados utilizados foram referentes às cotações diárias do fechamento do Ibovespa no período de Setembro de 1998 a Agosto de 2007. Com os resultados obtidos constataram que apenas uma camada escondida foi suficiente para a previsão do indicador estudado. Além disso, atestaram que os erros médios encontrados ficaram na faixa de 2% nas previsões do indicador e ressaltaram que estudos envolvendo redes neurais artificiais envolvem muito tempo na busca de parâmetros, dado que estes são obtidos através da experimentação conforme um modelo de tentativa e erro.

Wuerges e Borba [2010] constataram que, de um total de 258 artigos analisados, 193 deles (o que corresponde a 74,81% do total), sendo 129 em finanças e 64 em contabilidade, utilizaram o método de RNA. Além disso, 56,96% dos artigos sobre bolsas de valores privilegiam as redes neurais artificiais, tendo como explicação o fato dos artigos normalmente

desenvolverem modelos para detectar e explorar padrões em séries temporais, algo que as RNAs fazem muito bem.

A técnica também foi utilizada para prever preços de duas das principais ações transacionadas no mercado de valores colombiano. Neste trabalho, Villada *et al.* [2012] aplicaram o modelo no estudo das ações das empresas Ecopetrol e Preferencial Bancolombia que são negociadas nas bolsas de valores da Colômbia e Nova York. Foram utilizadas duas estruturas sendo que na primeira as entradas se deram pela série de preços diários e na segunda, além da série de preços, foi utilizado também o índice do dólar estadunidense DXY. O algoritmo de aprendizado utilizado foi do tipo Levenberg-Marquardt que, segundo os autores, tem uma convergência mais rápida, de modo que requer menor quantidade de iterações para chegar ao nível de erro especificado. Os resultados mostraram um bom comportamento das redes neurais, com baixos erros de desempenho tanto na aprendizagem, quanto na predição.

Laboissiere *et al.* [2015] analisaram a resposta da RNA na previsão de máximo e mínimo do preço das ações de empresas brasileiras de distribuição de energia. O horizonte de tempo dos dados históricos utilizados pelos autores foi de Janeiro de 2008 a Setembro de 2013 sendo que, 75% do total de dados foram utilizados para treinar a rede e o restante (25%) foram utilizados para validar. Os resultados obtidos da previsão, considerando o Erro Percentual Absoluto Médio (MAPE), foram inferiores a 0,9% para os preços máximos de ações e inferiores a 2,1% para os preços mínimos. Segundo os autores, esses resultados só foram possíveis de serem alcançados devido ao uso combinado de seleção de atributos com base em análise de correlação e redes neurais MLP.

3. Metodologia de pesquisa

3.1. Arquitetura da rede neural

A forma como os diversos neurônios estão dispostos, uns em relação aos outros, define a arquitetura de uma rede neural artificial [SILVA *et al.*, 2010]. Nesse contexto, as principais arquiteturas de redes neurais artificiais podem ser divididas em: redes *feedforward* (alimentação à frente) de camada simples, redes *feedforward* de camadas múltiplas, redes recorrentes e redes reticuladas [SILVA *et al.*, 2010].

Optou-se por utilizar neste trabalho as redes *feedforward* de camadas múltiplas, mais especificamente a *Perceptron* multicamadas (também conhecida como *MultiLayer Perceptron* – MLP) em razão do sucesso obtido pela mesma em resolver diversos problemas difíceis, através do seu treinamento de forma supervisionada com o algoritmo de retropropagação de erro (*Error Back-propagation*) [HAYKIN, 2001]. Para Braga *et al.* [2000, p. 51] "redes MLP apresentam um poder computacional muito maior do que aquele apresentado pelas redes sem camadas intermediárias". Além disso, é uma arquitetura que já foi aplicada em outros projetos referentes à previsão de séries temporais no mercado de ações apresentando desempenhos satisfatórios como em Faria *et al.* [2008], Oliveira *et al.* [2013] e Laboissiere *et al.* [2015].

Figura 3 – Grafo arquitetural de uma rede *MultiLayer Perceptron* com duas camadas ocultas

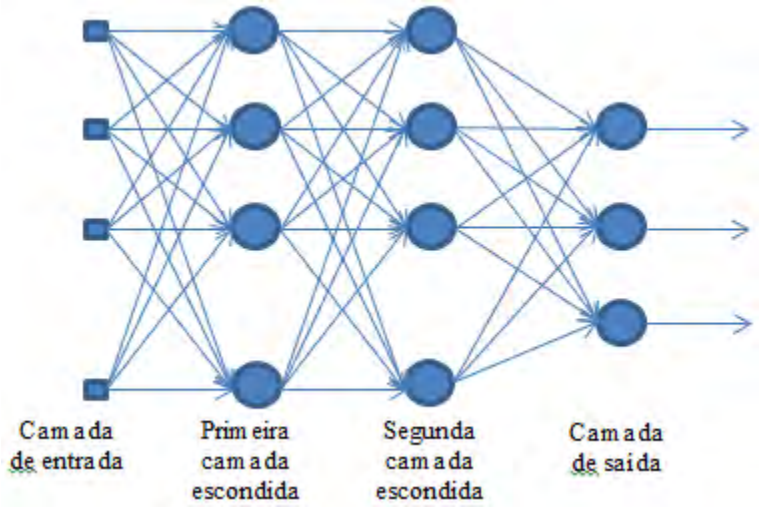

Fonte: Adaptado de Haykin [2001]

3.2. Treinamento

Haykin [2001, p. 75] salienta que "a propriedade que é de importância primordial para uma rede neural é a sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem". Assim, para que a rede possa aprender através do ambiente externo é necessário que ela passe por um processo de treinamento.

O processo de aprendizado (treinamento) se dá por dois métodos, sendo eles: supervisionado e não-supervisionado [BRAGA *et al.*, 2000]. No aprendizado supervisionado há a presença de um "professor", que irá fornecer para a rede a resposta desejada (valor alvo) que será comparada com a resposta real, tendo na diferença entre ambas a formação de um sinal de erro. Em contrapartida, no aprendizado não-supervisionado não há a presença de um "professor" indicando a saída desejada, de modo que a própria rede deverá extrair internamente as características dos dados de entrada.

O algoritmo *Back-propagation* utilizado neste trabalho é do tipo supervisionado sendo baseado na regra de aprendizagem por correção de erro. Haykin [2001, p. 183] corrobora que "a aprendizagem por retropropagação de erro consiste de dois passos através das diferentes camadas da rede: um passo para frente, a propagação, e um passo para trás, a retropropagação". Na propagação os pesos sinápticos são todos fixos, ou seja, não sofrem alterações. Já na retropropagação, o sinal de erro citado anteriormente, é propagado para trás contra a direção das conexões sinápticas, ajustando-se assim os pesos com o objetivo de diminuir a distância entre a resposta real e a resposta desejada.

3.3. Erros de previsão

Na literatura existem diversas medidas de erro que podem ser utilizadas para avaliar a precisão de um método tais como: comparação gráfica, média absoluta percentual dos erros (MAPE), raiz do erro quadrático médio (RMSE), diagramas de dispersão, média do quadrado dos erros (MSE), entre outros [FARIA *et al.*, 2008]. O erro de previsão normalmente é encontrado através da diferença entre o valor real e o valor previsto. Neste trabalho, foram utilizadas a Média Absoluta Percentual dos Erros (MAPE) e a Raiz do Erro Quadrático Médio (RMSE) bem como a comparação gráfica para melhor visualização dos resultados das previsões. A primeira é representada pela Equação 1:

$$MAPE: \frac{1}{n}\sum_{t=1}^{n}\left|\frac{e_t}{y_t}\ x\ 100\right| \qquad (1)$$

Onde:

- e_t é o erro absoluto de previsão para o período t;
- y_t é o valor real para o período t; e
- n é o número de períodos de avaliação.

Já o RMSE é expresso através da Equação 2:

$$RMSE: \sqrt{\frac{\sum_{K=1}^{N}(a_k - y_k)^2}{N}} \quad (2)$$

Segundo Faria *et al.* [2008, p. 16] "N é o número de padrões, a_k representa o valor real no instante t, e y_k representa o valor previsto no instante t".

3.4. Programa utilizado

Para execução do trabalho proposto utilizou-se o programa Matlab R2013a desenvolvido pela *MathWorks*. Matsunaga [2012] corrobora que o Matlab "é um sistema interativo e uma linguagem de programação baseados numa matriz, onde as soluções e problemas são expressos em linguagem matemática". A aplicação de redes neurais pode ser feita tanto pela linha de comando (utilizada para programação) quanto pela interface gráfica *Neural Network Toolbox* (NNTool). Neste projeto, optou-se por utilizar a linha de comando, tendo em vista a maior flexibilidade na execução dos parâmetros.

3.5. Parâmetros da rede

Para que uma rede neural possa ser implementada, deve-se definir alguns parâmetros que serão utilizados em sua configuração. Neste trabalho, foram realizados diferentes testes empíricos com o objetivo de se encontrar um modelo de rede com o resultado mais satisfatório. Durante a execução do trabalho os parâmetros utilizados foram os seguintes:

- **Número de camadas (*layers*):** segundo Cybenko [1989] e Hertz *et al.* [1991] [*apud* BRAGA *et al.,* 2000, p. 55] "uma camada intermediária é suficiente para aproximar qualquer função contínua". Dessa forma, durante todo o desenvolvimento do projeto optou-se por utilizar uma arquitetura com uma camada de entrada, uma camada intermediária (oculta) e uma camada de saída;
- **Número de neurônios por camada:** os neurônios por camada variaram ao longo dos testes tendo como objetivo encontrar o menor erro RMSE. Na camada de entrada foram realizados testes com 4, 5, 7, 10, 12 e 15 neurônios. Na camada intermediária foram criadas redes com 4, 5, 6, 7, 8, 10 e 12 neurônios. Como corrobora Braga *et al.* [2000, p. 55] "com relação ao número de nodos nas camadas intermediárias, este é em geral definido empiricamente";
- **Função de ativação:** conforme Haykin [2001] um *Perceptron* de múltiplas camadas possui função de ativação não-linear sendo que, normalmente, é utilizada a não-linearidade sigmóide definida pela função logística apresentada na Equação 3:

  $$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (3)$$

  Sendo a o parâmetro de inclinação da função sigmóide.
- **Taxa de aprendizado:** com o objetivo de não tornar o aprendizado muito lento com uma taxa de aprendizagem muito baixa optou-se por variá-la entre 0,6 e 0,7. Vale ressaltar

que, taxas muito elevadas podem provocar oscilações no treinamento impedindo a convergência do algoritmo de treinamento;

– **Critério de parada:** optou-se por utilizar o número de épocas como critério de parada, ou seja, definiu-se inicialmente um número de vezes (iterações) que o conjunto de treinamento seria apresentado à rede e ao atingi-lo o treinamento era finalizado.

4. Resultados

Os dados necessários para a realização deste trabalho são reais e foram obtidos através do sítio do *Yahoo!* Finanças. Ressalta-se que os mesmos são fornecidos em formato *csv* e dessa forma foi preciso organizá-los no Microsoft Excel 2010®. O período selecionado foi de Janeiro de 2011 a Dezembro de 2015 (totalizando 1253 pontos) sendo utilizada a série histórica diária do fechamento do Ibovespa conforme Gráfico 1. Na Tabela 1 é possível verificar algumas medidas estatísticas dos dados citados.

Gráfico 1 – Série histórica diária do fechamento do Ibovespa – Janeiro/2011 a Dezembro/2015

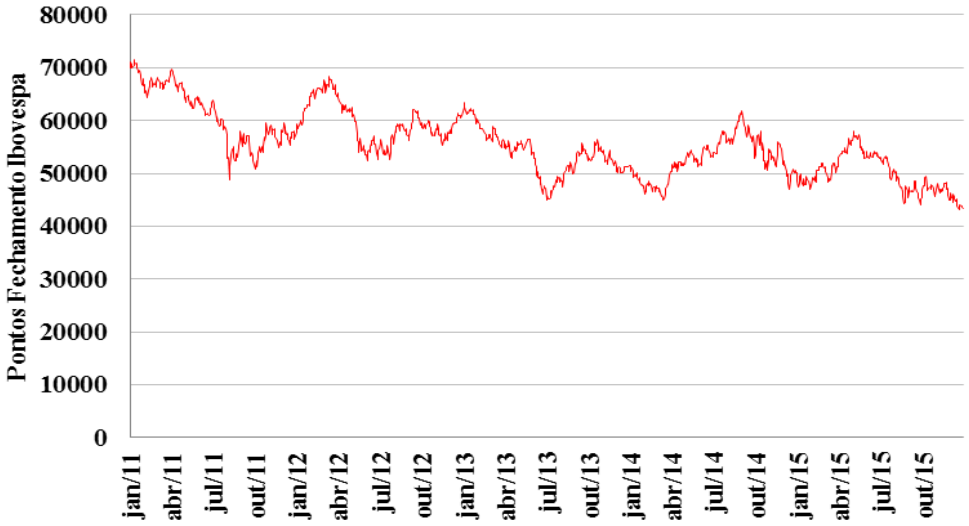

Fonte: Elaborado pelos autores

Tabela 1 – Medidas estatísticas do conjunto de dados

Mínimo	1º Quartil	Média	Mediana	3º Quartil	Máximo	Desvio Padrão da Média	Desvio Padrão
43200	51158	55369	54786	58972	71633	170,46	6034,02

Fonte: Elaborado pelos autores

De posse dos dados realizou-se a separação do conjunto em três partes: treinamento, teste e previsão. Assim, determinou-se que 70% (o que corresponde a 877 pontos) seriam utilizados para treinamento, 20% para teste (250 pontos) e os 10% restantes para previsão. A etapa seguinte consistiu em normalizar os dados, conforme Gráfico 2, para uma mesma faixa de valores com o objetivo de aprimorar o desempenho da rede, evitando-se assim anomalias e também a estagnação do aprendizado. Esse processo foi realizado através do método de normalização sigmoidal conforme Equação 4:

$$y = \frac{1}{1 + e^{-\frac{x-\bar{x}}{\sigma_x}}} \tag{4}$$

Gráfico 2 – Fechamento do índice Ibovespa normalizado

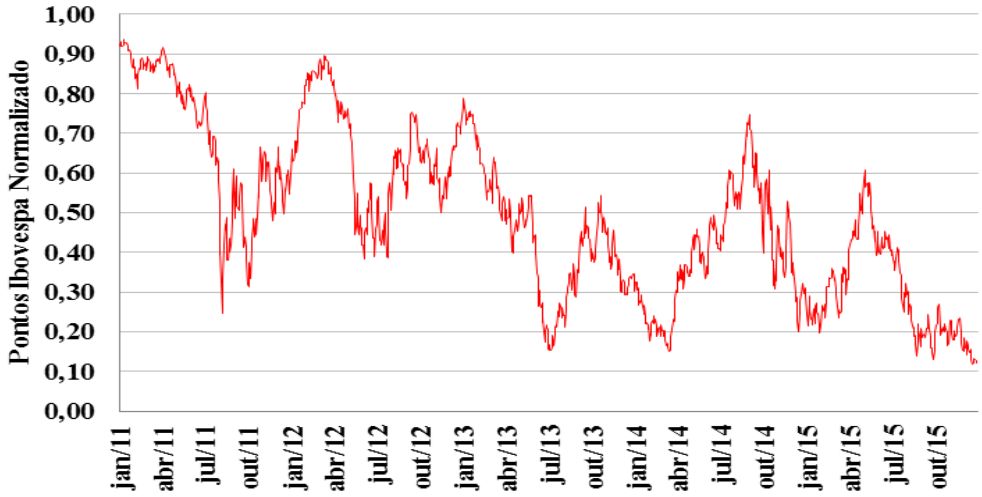

Fonte: Elaborado pelos autores.

Através dos testes realizados em diferentes arquiteturas, conforme Tabela 2, buscou-se encontrar a rede neural artificial que apresentasse o menor valor correspondente a Raiz do Erro Quadrático Médio (RMSE). Assim, percebe-se que a melhor arquitetura encontrada foi a da rede configurada com os seguintes parâmetros: 4 neurônios na camada de entrada, 4 neurônios na camada intermediária e 1 neurônio na camada de saída. Além disso, foi utilizada taxa de aprendizado de 0,7 bem como foram realizadas 100000 iterações.

Tabela 2 – Parâmetros testados rede MLP

Arquitetura			RMSE Normalizado	Iterações	Coeficiente de Aprendizado
Entrada	Oculta	Saída			
4	4	1	0.0388	5000	0.6
4	4	1	0.0391	10000	0.6
4	4	1	0.0393	5000	0.7
4	4	1	0.0388	10000	0.7
4	4	1	0.0387	20000	0.7
4	4	1	0.0385	50000	0.7
4	**4**	**1**	**0.0384**	**100000**	**0.7**
4	6	1	0.0389	5000	0.7
4	7	1	0.0388	5000	0.7
4	8	1	0.0389	5000	0.7
4	10	1	0.0388	5000	0.7
4	12	1	0.0389	5000	0.7
5	4	1	0.0392	5000	0.7
5	5	1	0.0389	3000	0.7
5	5	1	0.0388	10000	0.7
5	5	1	0.0389	20000	0.7
7	4	1	0.0393	5000	0.7
10	4	1	0.0387	5000	0.7
12	6	1	0.0385	5000	0.7
15	4	1	0.0389	5000	0.7

Fonte: Elaborada pelos autores

Os três gráficos a seguir permitem a comparação gráfica nas fases de treinamento, teste e previsão entre a série real e a série prevista (desnormalizadas) da rede que apresentou o melhor resultado:

Gráfico 3 – Comparação entre a série real e a série prevista na fase de treinamento

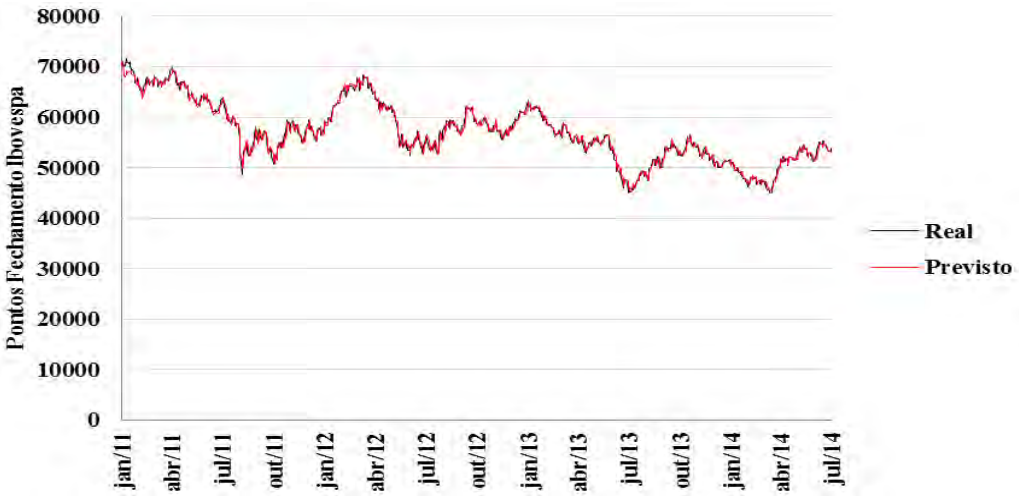

Fonte: Elaborado pelos autores

Gráfico 4 – Comparação entre a série real e a série prevista na fase de teste

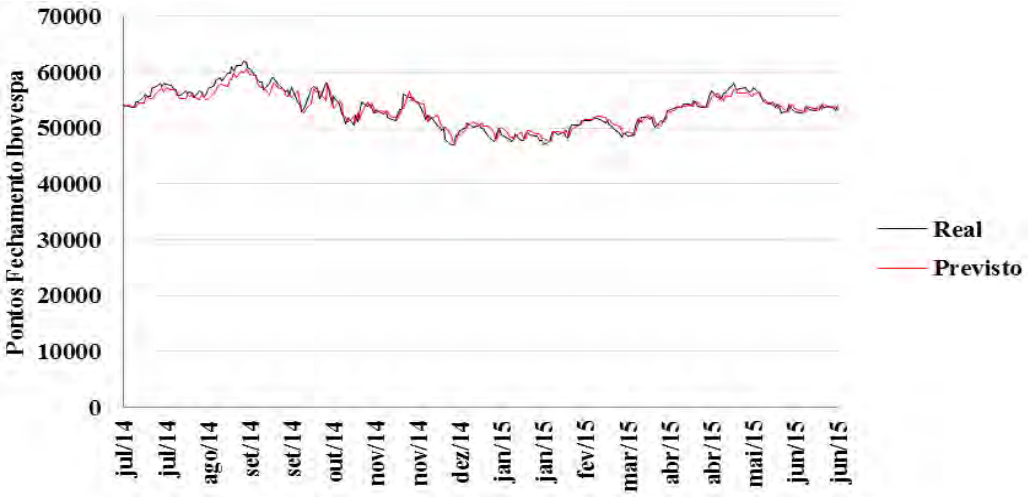

Fonte: Elaborado pelos autores

Gráfico 5 – Comparação entre a série real e a série prevista na fase de previsão

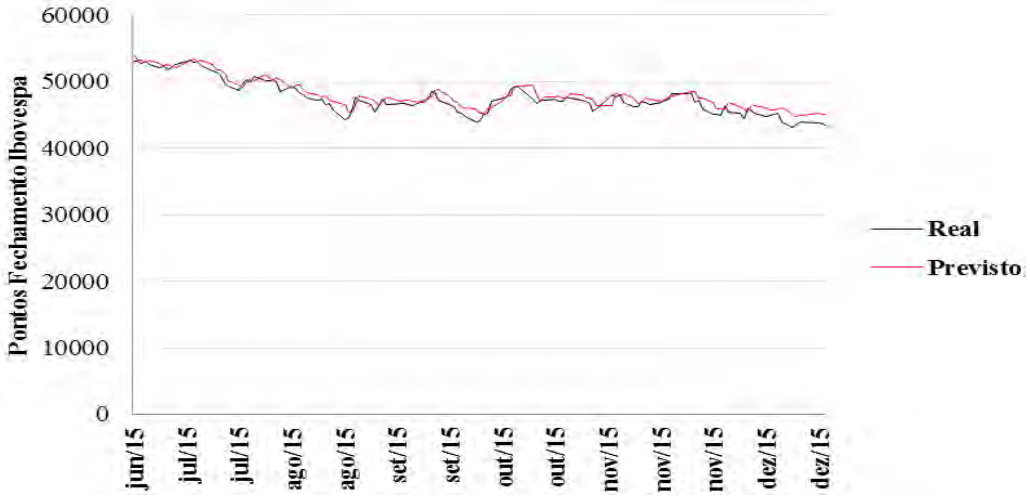

Fonte: Elaborado pelos autores

Através dos gráficos é possível perceber que na fase de previsão há certa defasagem entre o real e o previsto, entretanto, ainda assim, a rede conseguiu prever a tendência dos pontos de fechamento. Os erros (RMSE e MAPE) encontrados nessa fase na série sem normalização foram respectivamente de 956,31 e 1,70%. O MAPE foi próximo dos 5,45% encontrados por Oliveira *et al.* [2013] utilizando Redes MLP para previsão de preços das ações da Petrobras (PETR4) e de Laboissiere *et al.* [2015] utilizando o mesmo tipo de rede para previsão de preços máximos (MAPE inferior a 0,9%) e mínimos (MAPE menor que 2,1%) de ações de algumas empresas brasileiras de distribuição de energia.

5. Conclusão

O investimento em ações é considerado de maior risco a julgar pela incerteza que os investidores estarão sujeitos. Essas incertezas levam os mesmos a buscarem técnicas que possam auxiliá-los no processo de tomada de decisões. Uma dessas técnicas é a de Redes Neurais Artificiais, que levou diversos pesquisadores ao longo dos últimos anos a analisarem sua aplicabilidade em diferentes mercados, como já citado ao longo deste trabalho. Este estudo teve como objetivo a predição do maior indicador de desempenho médio do mercado de ações brasileiro que é o Ibovespa utilizando RNAs. Para tal, foi utilizada uma Rede MLP que possui algoritmo de treinamento do tipo *Back-propagation.*

Os resultados encontrados foram satisfatórios tendo em vista a aproximação entre os dados reais e os dados previstos, demonstrando a capacidade que a rede neural tem de reconhecer padrões, aprendendo as características dos dados apresentados no treinamento. Como limitações do estudo pode-se apontar o uso de apenas uma variável (fechamento) para todo o trabalho e a ausência de um maior tratamento estatístico dos dados com técnicas como análise de correlação, por exemplo, para melhor definição dos parâmetros da rede. Não obstante, o MAPE deste trabalho se aproximou daquele encontrado por outros pesquisadores utilizando o mesmo tipo de rede para predição no mercado acionário brasileiro.

Agradecimentos

Ao CNPq e a FAPEG pelo apoio financeiro e incentivo à pesquisa.

Referências

Assaf Neto, A. (2011). Mercado Financeiro. 10. ed. Atlas, São Paulo.

Braga, A. P., Carvalho, A. C. P. L. F. e Ludermir, T. B. (2000). Redes Neurais Artificiais: teoria e aplicações. 1. ed. Livros Técnicos e Científicos, Rio de Janeiro.

Cao, Q., Leggio, K. B. e Schniederjans, M. J. (2005). A comparison between Fama and French's model and artificial neural networks in predicting the Chinese stock market. Computers and Operations Research, v. 32, n. 10, p. 2499-2512.

Faria, E. L., Albuquerque, M. P., Alfonso, J. L. G.; Albuquerque, M. P. e Cavalcante, J. T. P. (2008). Previsão do Mercado de Ações Brasileiro utilizando Redes Neurais Artificiais. CBPF-NT/2008. Rio de Janeiro: CBPF. Disponível em: <cbpfindex.cbpf.br/publication_pdfs/NT00208.2011_01_04_11_01_14.pdf>. Acesso em: 27 fev. 2016.

_____; _____; _____; _____; _____. (2008). Previsão de Séries Temporais utilizando Métodos Estatísticos. CBPF-NT-003/2008. Rio de Janeiro: CBPF. Disponível em: <http://cbpfindex.cbpf.br/publication_pdfs/nt00308.2009_01_16_13_12_34.pdf> Acesso em: 10 mar. 2016.

Halfeld, M. (2001). Investimentos: Como administrar melhor seu dinheiro. 1. ed. Fundamento Educacional, São Paulo.

Haykin, S. (2001). Redes Neurais: Princípios e prática. 2. ed. Bookman, Porto Alegre.

Herling, L. H. D., Lima, M. V. A. de, Moritz, G. O. e Marangoni, P. H. (2012). Testando a Hipótese de Eficiência de Mercado por Meio de Redes Neurais Artificiais: Um Estudo de Caso com as Dez Principais Ações do Ibovespa do Primeiro Quadrimestre de 2011. Future Studies Research Journal. São Paulo, v. 4, n. 2, p. 164-186.

Laboissiere, L. A., Fernandes, R. A. S. e Lage, G. G. (2015). Maximum and Minimum Stock Price Forecasting of Brazilian Power Distribution Companies Based on Artificial Neural Networks. Applied Soft Computing, v. 35, p. 66-74.

Matsunaga, V. Y. (2012). Curso de Redes Neurais utilizando o Matlab. Pará.

Oliveira, F. A. de, Nobre, C. N e Zarate, L. E. (2013). 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, n. 18, p. 7596-7606.

Quah, T.-S. e Srinivasan, B. (1999). Improving returns on stock investment through neural network selection. Expert Systems With Applications, v. 17, n. 4, p. 295-301.

Silva, I. N. da, Spatti, D. H. e Flauzino, R. A. (2010). Redes neurais artificiais: para engenharia e ciências aplicadas. Artliber, São Paulo.

Tafner, M. A., Xerez, M. e Rodrigues Filho, I. W. (1996). Redes Neurais Artificiais: introdução e princípios de neurocomputação. EKO, Blumenau.

Villada, F., Muñoz, N. e García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. Información Tecnológica, v. 23, n. 4, p. 11-20.

Wuerges, A. F. E., Borba, J. A. (2010). Redes Neurais, Lógica Nebulosa e Algoritmos Genéticos: Aplicações e Possibilidades em Finanças e Contabilidade. Revista de Gestão de Tecnologia e Sistemas de Informações. v. 7, n. 1, p. 163-182.

Yahoo! Finanças. Disponível em: <https://br.financas.yahoo.com/> Acesso em: 01 mar. 2016.