

Previsão de séries temporais financeiras utilizando redes neurais artificiais: um comparativo na crise de 2008

Financial time series forecast using artificial neural networks: a comparative in the 2008 crisis

Debora Barbosa Aires¹ - Univ. Est. Paulista "Júlio de Mesquita Filho" - Fac. de Eng. de Bauru - Dep. de Eng. de Produção
Ronaldo César Dametto² - Univ. Est. Paulista "Júlio de Mesquita Filho" - Fac. de Eng. de Bauru - Dep. de Eng. de Produção
Antonio Fernando Crepaldi³ - Univ. Est. Paulista "Júlio de Mesquita Filho" - Fac. de Eng. de Bauru - Dep. de Eng. de Produção

RESUMO As redes neurais artificiais (RNAs) vem sendo utilizadas em diferentes segmentos da área financeira, como na previsão de preços de ações e índices de mercado. Este artigo busca mensurar o poder das RNAs na predição do Índice Bovespa e de preços de ações, averiguando o seu poder de previsão mesmo em períodos de crise. Para tanto, foram extraídas do *Yahoo! Finance* séries temporais de mais de uma década, contendo o período da crise do *subprime* e suas vizinhanças temporais. As RNAs foram executadas por meio do *software* Matlab 2016a, apresentando resultados satisfatórios, os quais foram avaliados pelos diagramas de dispersão dos erros e pelo método do erro percentual absoluto médio (MAPE).

Palavras-chave: Redes Neurais Artificiais. Ibovespa. ABEV3. ITUB4. Mercado de Ações. Previsão de Preços. Crise do *Subprime*.

ABSTRACT *Artificial Neural Networks (ANN) have been used in different segments inside the area of finance such as stock prices and market indices forecast. This article seeks to measure the power of ANN on the Bovespa Index and the prediction of stock prices, verifying their forecast power even in times of crisis. Therefore, time series of over a decade were extracted from Yahoo! Finance, including the period of the subprime crisis and its temporal neighborhoods. ANN were performed using Matlab 2016a software with satisfactory results, which were evaluated by scattergrams errors and Mean Absolute Percentage Error (MAPE) method.*

Keywords: *Artificial Neural Networks. Ibovespa. ABEV3. ITUB4. Stock Market. Prices Forecast. Subprime Crisis.*

1. Rua Maria Cecília de Oliveira Maciel, 1-175, Jardim Colonial, Bauru, SP, CEP: 17047-625, debbysinha@gmail.com; 2. rdametto@uol.com.br; 3. crepaldi@feb.unesp.br

AIRES, D. B.; DAMETTO, R. C.; CREPALDI, A. F. Previsão de séries temporais financeiras utilizando redes neurais artificiais: um comparativo na crise de 2008. **GEPROS. Gestão da Produção, Operações e Sistemas**, Bauru, Ano 13, nº 1, jan-mar/2018, p. 177-206.

DOI: 10.15675/gepros.v13i1.2016

1. INTRODUÇÃO

A compra e venda de ações são investimentos de longo prazo que podem ser realizadas por qualquer pessoa. Porém, este tipo de investimento envolve riscos e por isso o investidor deve ter conhecimento básico sobre o comportamento do mercado de ações (BM&FBOVESPA, 2017).

A previsão do comportamento das ações no mercado financeiro é uma análise de difícil tratamento devido ao comportamento não linear de sistemas como estes, gerando a “[...] necessidade de utilização de uma ferramenta capaz de tratar esse tipo de problema de forma automática e eficiente.” (SILVA; SAPATTI; FLAUZINO, 2010, p. 302). Dessa forma, o avanço tecnológico elevou o grau de sofisticação das operações oferecidas pelo mercado financeiro aos investidores, o que eleva as possibilidades de ganhos e reduz riscos nas atividades de investimento em ações (MARTINS; METTE; MACEDO, 2008). Existem diversos métodos para auxiliar na tarefa de modelar e estimar a volatilidade e a previsão de preços de ativos, um deles é a utilização de Redes Neurais Artificiais (RNAs) (MARTINS; METTE; MACEDO, 2008; ROCA; MÓL, 2015).

Vários trabalhos da literatura mostram que as RNA trazem resultados positivos e mais aderentes que outros métodos para a previsão do comportamento do índices financeiros e ações negociadas na bolsa de valores brasileira (MARTINS; METTE; MACEDO, 2008; OLIVEIRA, 2007; ROCA; MÓL, 2015). Porém, estes artigos avaliaram individualmente o Índice Bovespa ou alguma ação específica.

Desta forma, é preciso avaliar se estes mesmos resultados podem ser alcançados utilizando uma mesma estrutura de RNA para prever o comportamento de ambos. Nesta conjuntura, este trabalho enfoca as seguintes questões-problema: É possível que uma mesma configuração de Rede Neural Artificial possa ser aderente tanto para prever o comportamento do Ibovespa quanto o de ações que o compõe? Como a previsão feita por este tipo de Rede Neural Artificial se comporta em períodos tendenciosos como a crise do *subprime*? Assim, o presente artigo tem por objetivo estimar, inclusive em períodos de alta volatilidade como a crise do *subprime*, por meio da RNA, o comportamento do Índice Bovespa e de duas ações que são as de maior representatividade na composição do próprio índice: o ITUB4 PN, disponibilizado pela Itaú Unibanco S/A, e a ABEV3 ON, disponibilizado pela Ambev S/A. Para tanto, foi utilizando uma série de preços diários compreendida no período de 03 de janeiro de 2006 a 04 de julho de 2016. Os dados coletados formaram três séries temporais com mais de dez anos de dados históricos cada.

O trabalho está estruturado em quatro seções, além da introdução. A segunda seção é dedicada a uma revisão teórica sobre o mercado de ações, o Índice Bovespa, a crise do *subprime* e conceitos sobre o método de redes neurais artificiais; a terceira é dedicada ao detalhamento da metodologia usada; na quarta seção encontra-se a análise dos resultados obtidos a partir do treinamento, execução da RNA e comparação com dados reais (medida de erros), por fim, na quinta seção são feitas as conclusões.

2. REFERENCIAL TEÓRICO

2.1. Mercado de ações

O Brasil possui atualmente uma única bolsa de valores em operação, a B3 S.A., resultado da fusão da BM&FBOVESPA S.A. (Bolsa de Valores, Mercadorias e Futuros) e Cetip S.A. (Mercados Organizados) em março de 2017. A B3 está entre as maiores bolsas do mundo em valor de mercado e é líder na América Latina. Atualmente negocia os ativos de aproximadamente 450 empresas as quais integram os índices Ibovespa, IBrX-50, IBrX e Itag, entre outros (BM&FBOVESPA, 2017).

Ações são investimentos de renda variável, que envolvem riscos de flutuação no valor investido e seu potencial de boa rentabilidade se dá no longo prazo. A BM&FBovespa (2017) define o conceito de ações como: “Ações são pequenas partes de uma empresa. Quando uma companhia se torna aberta, o patrimônio dela é dividido em várias cotas, que são distribuídas para os investidores.”. Entre os diversos tipos de ações colocadas à venda no mercado financeiro pelas empresas destacam-se os tipos PN, o qual dá direito a recebimento de lucro da empresa, e ON, o qual dá direito ao voto nas assembleias da empresa em questão (SILVA; SAPATTI; FLAUZINO, 2010). O possuidor de ações pode compra-las ou vende-las a qualquer momento, poré, para lucrar neste tipo de mercado recomenda-se seguir algumas precauções, como conhecer a empresa que receberá o investimento, conhecer o mercado onde ela atua, certificar-se da credibilidade desta e avaliar a possibilidade de lucratividade no futuro. Uma das formas de obter lucro no mercado de ações é com a alta das ações adquiridas. O preço da ação é formado pelo fluxo de oferta e procura de cada papel. (BM&FBOVESPA, 2017).

Existem dois modelos diferentes que regem a compra e venda de ações no mercado financeiro: modelo fundamentalista e modelo técnico. O modelo fundamentalista analisa aspectos da empresa em questão e aspectos macroeconômicos. Já o modelo técnico se fundamenta em dados históricos a respeito da empresa, tentando, assim, inferir o futuro a partir de comportamentos passados. (SILVA; SAPATTI; FLAUZINO, 2010). O histórico de preços de uma determinada ação, portanto, produz uma série temporal não-linear, “[...] cuja previsão de comportamento é de fundamental importância para negociações futuras.” (SILVA; SAPATTI; FLAUZINO, 2010, p. 302).

2.2. Índice Bovespa

O Índice Bovespa (Ibovespa), criado em 1968, é o indicador do desempenho médio das cotações das ações de maior negociabilidade e representatividade do mercado brasileiro negociadas na B3, resultado de uma carteira teórica de ativos composto, atualmente por 59 ações de empresas (BM&FBOVESPA, 2017). Leite e Sanvicente (1994) afirmam que a negociabilidade é o principal fator para a utilização do Ibovespa como índice de mercado, devendo ser considerado para a análise da rentabilidade a variação percentual entre dois pontos históricos quaisquer.

Na data desta pesquisa (julho de 2016) as duas ações com maiores participações na composição do Ibovespa são ITUB4 do tipo PN, com mais de 10% de participação, e a ABEV3 do tipo ON, com mais de 8,7% de participação (BM&FBOVESPA, 2017). Tais papeis são disponibilizados pelas empresas Itaú Unibanco S/A e Ambev S/A, respectivamente. O Itaú Unibanco é uma companhia resultante da fusão das duas empresas em 2008 com atuação no Brasil e no exterior, na atividade bancária em todas as modalidades (ITAÚ, 2016). A Ambev S/A é uma companhia de bebidas resultante da fusão das empresas Cervejaria Brahma e Companhia Antarctica em 1999, com atuação em diversos países (AMBEV, 2016).

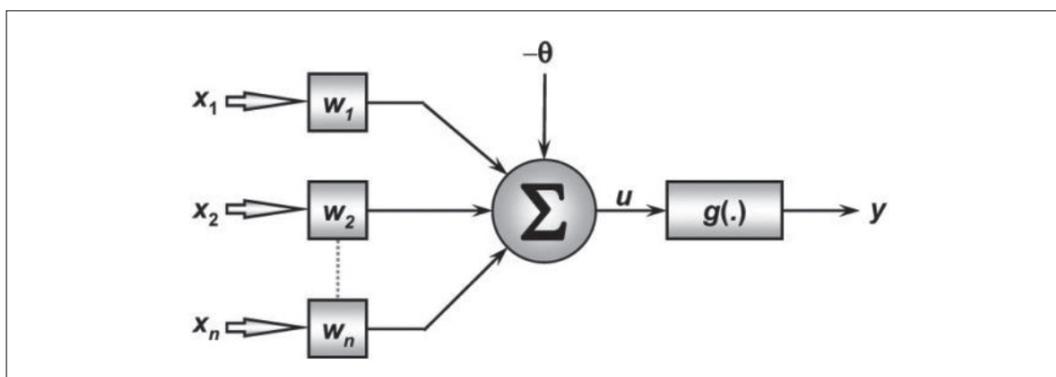
2.3. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) foram desenvolvidas na década de 1940, por Walter Pitts e McCulloch, o primeiro matemático e o segundo neurofisiologista, com o objetivo de desenvolver um modelo computacional análogo a neurônios biológicos e circuitos eletrônicos, capazes de simular conexões sinápticas pelo uso de resistores variáveis e amplificadores (LUDWIG; COSTA, 2007).

Os primeiros trabalhos acadêmicos sobre RNAs foram publicados na década de 1960, porém foi a partir da década de 1990 que as RNAs começaram a ser largamente estudadas e aplicadas em diversas áreas (MARTINS; METTE; MACEDO, 2008; SILVA; SAPATTI; FLAUZINO, 2010). Uma das áreas de aplicação são os sistemas de previsão que consistem em “[...] estimar valores futuros de um processo levando-se em consideração diversas medidas prévias observadas em seu domínio.” (SILVA; SAPATTI; FLAUZINO, 2010, p. 28). Uma das aplicações nesta área é a previsão de ações no mercado financeiro. Este tipo de problema requer o apoio de ferramentas capazes de tratar sistemas não lineares como estes, de forma automática e eficiente (SILVA; SAPATTI; FLAUZINO, 2010). Desta forma as RNAs vêm auxiliar em problemas que envolvem sistemas complexos como este, pois são capazes de extrair características relevantes de grandes conjuntos de dados baseando-se em conhecimentos prévios (OLIVEIRA, 2007).

As RNAs são formadas por neurônios interligados entre si e sinapses artificiais estruturados com base em modelos biológicos. Desta forma, as RNAs possuem características como capacidade de aprendizagem através de treinamento, habilidade de generalização e tolerância a falhas (MARTINS; METTE; MACEDO, 2008; SILVA; SAPATTI; FLAUZINO, 2010). Um neurônio pode ser visualizado conforme a Figura 1, com os x_i sinais de entrada externos e os w_i pesos sinápticos, que ponderam e variam de acordo com a relevância de cada x_i . Em seguida é realizada a soma ponderada dos sinais de entrada, realizada pelo combinador linear Σ , e subtrai-se a variável θ chamada de limiar de ativação. Desta forma, a saída de cada neurônio é denominada de potencial de ativação u . As saídas dos neurônios artificiais são enviadas para uma função de ativação, denominada por $g()$, a qual tem a função de limitar a saída do neurônio dentro de um intervalo determinado que possa ser assumido pela rede e gera o sinal de saída y (SILVA; SAPATTI; FLAUZINO, 2010).

Figura 1 – Neurônio Artificial.



Fonte: Silva, Sapatti e Flauzino (2010).

Uma RNA pode ser dividida em três camadas básicas: entrada, escondidas, e saída. A camada de entrada é responsável por receber os sinais x_i . As camadas escondidas ou intermediárias são compostas pelos neurônios artificiais responsáveis pelo processamento interno da rede. A camada de saída é composta pelos neurônios artificiais responsáveis por gerar o sinal y (SILVA; SAPATTI; FLAUZINO, 2010).

Os possíveis arranjos de neurônios são chamados de arquitetura da RNA. As diferentes formas de composição estrutural que uma arquitetura pode assumir é a topologia da rede (SILVA; SAPATTI; FLAUZINO, 2010). A forma como as interconexões de neurônios serão estruturadas pode variar de acordo com o número de camadas, o número de neurônios em cada camada, a função de ativação dos neurônios em uma camada e a forma como as camadas são conectadas, podendo ser de forma total ou parcial (ROCA; MÓL, 2015). O mecanismo de funcionamento das RNAs consiste em aprender a relação intrínseca existente nos dados através de um número de neurônios que se comunicam entre si, distribuídos em diferentes camadas (ADHIKARI; AGRAWAL, 2014).

Existem basicamente três tipos de arquiteturas: *feedforward* simples ou múltiplas camadas e recorrente. A *feedforward* de camada simples não possui camadas intermediárias, tendo apenas as uma camada de entrada e uma de saída. Já a arquitetura *feedforward* de camadas múltiplas possui uma ou mais camadas escondidas. As arquiteturas *feedforward* possuem um fluxo de dados em um único sentido, da camada de entrada para a camada de saída. Na arquitetura recorrente, porém, a rede é realimentada com os sinais de saída (ROCA; MÓL, 2015; SILVA; SAPATTI; FLAUZINO, 2010).

Os três principais tipos de treinamento ou algoritmos de aprendizagem são: Supervisionado, não supervisionado e com reforço. No treinamento supervisionado é disponibilizado as saídas desejadas para cada conjunto de dados de entrada, o que não acontece nos treinamentos não supervisionados, de modo que a rede deve se auto-organizar de acordo com as particularidades da amostra. Já o treinamento com reforço é uma variação do treinamento supervisionado, onde a defasagem entre os resultados gerados pela rede e os resultados desejados é avaliada constantemente (MARTINS; METTE; MACEDO, 2008; SILVA; SAPATTI; FLAUZINO, 2010).

Para construção das RNA é necessário dividir aleatoriamente a série temporal disponível em duas partes: uma parte maior (entre 60% e 90%) que será utilizada para treinar a rede e uma parte menor (entre 10% e 40%) que será utilizada para avaliações e testes. Na etapa de treinamento, a rede recebe uma amostra de valores de entradas e os respectivos resultados esperados, no caso do treinamento supervisionado. Os pesos das correlações e os limiares são estabelecidos nesta etapa. Tal processo visa balancear a RNA de forma que suas respostas estejam próximas aos valores desejados. Na etapa de teste e validação consiste em prever os próximos valores da série temporal. Dessa forma os valores históricos são comparados com os valores previstos pela RNA e pôde-se calcular o erro obtido pelas previsões da rede. (ROCA; MÓL, 2015; SILVA; SAPATTI; FLAUZINO, 2010).

Existem vários tipos de medidas do erro de previsão que podem mensurar os desvios entre os valores previstos e os observados. Para Lewis (1997), o erro percentual absoluto médio (MAPE) é considerado como uma das medidas de erro mais usadas para se avaliar os métodos de previsão. A partir do valor do MAPE é possível mensurar o erro em relação aos dados da série histórica. O MAPE é calculado conforme Equação 1, na qual P_t é o valor da série histórica e \hat{P}_t é a previsão e n é o número de períodos de previsão (WANKE, 2010). Na prática, um valor MAPE (do inglês *Mean Absolute Percentage Error*) menor que 10% seria considerado muito bom e com potencial para fornecer uma previsão de qualidade.

$$\text{MAPE} = \frac{\sum_{t=1}^n \frac{|P_t - \hat{P}_t|}{P_t}}{n} \quad (1)$$

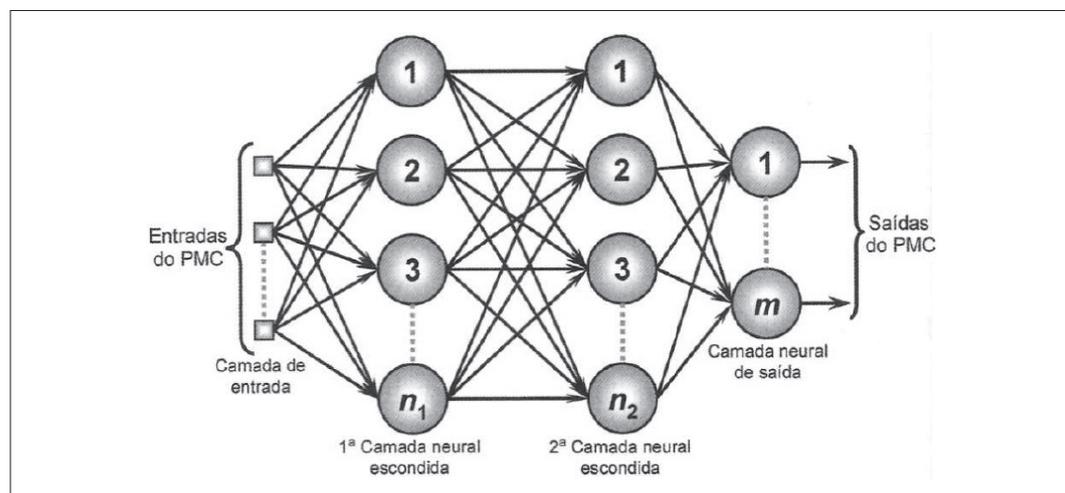
Na prática, um valor MAPE menor que 10% seria considerado muito bom e com potencial para fornecer uma previsão de qualidade (LEWIS, 1997).

2.4. Redes *Perceptron* Multicamadas

Em 1957 Frank Rosenblatt criou uma rede neural que foi batizada com o nome *Perceptron*, cujo objetivo era uma simulação computacional para a retina, demonstrou como o sistema nervoso visual reconhece padrões (SILVA; SAPATTI; FLAUZINO, 2010, LUDWIG; COSTA, 2007).

O *Perceptron* multicamadas (PMC) é um dos principais tipos de redes com arquitetura *feedforward*, aplicada em diversas áreas e reconhecidamente utilizada em problemas de previsão de séries temporais, cujo treinamento é feito de forma supervisionada. É caracterizado, basicamente, pela existência de ao menos uma camada escondida de neurônios entre as camadas de entrada e saída, sendo que a camada de saída pode conter mais de um neurônio, conforme pode ser visto na Figura 2 (ADHIKARI; AGRAWAL, 2014; SILVA; SAPATTI; FLAUZINO, 2010).

Figura 2 – Ilustração de rede *Perceptron* multicamadas.



Fonte: Silva, Sapatti e Flauzino (2010).

O algoritmo de aprendizagem aplicado a uma PMC é denominado back-propagation, ou algoritmo de retropropagação do erro. O método de Levenberg-Marquardt é uma variação do backpropagation com o objetivo de tornar o processo de convergência do resultado mais eficiente.

2.5. Crise do *Subprime*

A crise financeira internacional, evidenciada a partir da crise no mercado imobiliário norte-americano, conhecida apenas como a crise de 2008, é uma profunda crise de confiança decorrente de uma cadeia de empréstimos originalmente imobiliários baseados em devedores insolventes que, ao levar os agentes econômicos a preferirem a liquidez e assim liquidar seus créditos, está levando bancos e outras empresas financeiras à situação de quebra mesmo que elas próprias estejam solventes (BORÇA JUNIOR, TORRES FILHO, 2008).

Segundo Paul Krugman (2009), o que se sabe das crises financeiras é que elas são muito diversas em suas origens e nas suas consequências. O crédito fácil e a disseminação de um investimento sem rastro pelo mundo todo estão na raiz da crise financeira de 2008. Por volta de 1998, os bancos dos Estados Unidos começaram a emprestar dinheiro a muita gente que não tinha como pagar. Mesmo quem estava desempregado e não tinha renda nem patrimônio conseguia ser aprovado pelos bancos para receber um financiamento. E poderia dar a própria casa como garantia para vários empréstimos (IEDI, 2008). Segundo IEDI (2008), esse tipo de crédito era conhecido como *subprimes*. O problema é que os devedores não pagaram suas dívidas. Como essas dívidas estavam nas mãos de bancos e fundos de investimento do mundo todo, houve um efeito dominó no mercado. Um dos marcos da crise foi em 15 de setembro de 2008, quando um dos bancos de investimentos mais tradicionais dos Estados Unidos, o Lehman Brothers, foi a falência, e as Bolsas do mundo todo despencaram, o Ibovespa apresentou a maior desvalorização percentual diária desde 11 de setembro de 2001 (MATUCHESKI; CLEMENTE; SANDRINI, 2009).

3. PROCEDIMENTOS METODOLÓGICOS

3.1. Objeto de estudo

O presente artigo tem por objetivo estimar, inclusive em períodos de alta volatilidade, como a crise do *subprime*, por meio da RNA, o comportamento do Índice Bovespa (Ibovespa) e dos preços das duas ações mais representativas que compõe este índice no atual período desta pesquisa (julho de 2016): o ITUB4 PN, disponibilizado pela Unibanco S/A, e a ABEV3 ON, disponibilizado pela Ambev S/A. O Ibovespa foi escolhido por ser o principal indicador do desempenho médio das cotações de ativos do mercado de ações brasileiro, retratando, assim, o comportamento dos papéis de maior volume e valor negociado na B3 (BM&FBOVESPA, 2017). Como período da crise do *subprime* considerou-se os anos de 2008 a 2009.

3.2. Procedimentos de coleta de dados

Foram extraídas do *Yahoo! Finance* (YAHOO, 2016) as series temporais com periodicidade diária do Ibovespa e das ações ITUB4 PN e ABEV3 ON referentes ao período de 02 de janeiro de 2006 a 04 de julho de 2016. Ressalta-se, porém, que os valores são disponíveis somente nos dias úteis. Das informações disponibilizadas, foram utilizadas apenas os valores de fechamento. Os dados foram, então, formatados, ordenados cronologicamente e os valores de split e de eventuais dividendo e juros sobre capital próprio foram removidos.

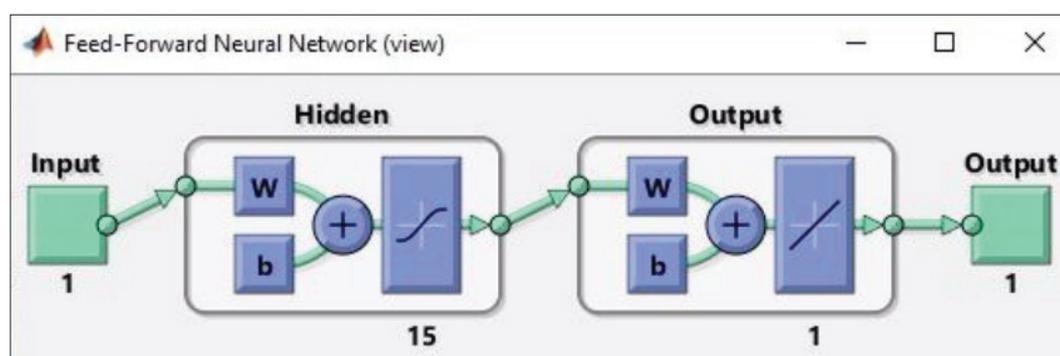
3.3. Procedimentos de análise de dados

Para modelagem da RNA foi utilizado o software MATLAB R2016a trial versão 9.0.0.341360. Foram criadas redes neurais para previsão dos próximos 5, 15 e 30 dias, sendo que estas redes seriam treinadas com três conjuntos de dados diferentes: dados completos (de 2006 a 2016), dados referente a crise do *subprime* (de 2008 a 2009) e dados referentes ao período pós-crise do *subprime* (de 2010 a 2011), totalizando assim nove redes neurais, sendo que todas foram alimentadas com cada uma das três séries temporais aqui estudadas (Ibovespa, ABEV3 e ITUB4). Dos dados obtidos, foram separados os 30 dias mais recentes de cada série, usados posteriormente como comparativo das previsões executadas pela rede.

Seguiu-se a metodologia de aplicação de redes neurais para séries temporais, descrita por Oliveira (2007), composta de três fases: pré-processamento, treinamento e teste de rede.

Na fase de pré-processamento iniciou-se um estudo sobre a melhor estrutura a ser utilizada nas redes. Após uma análise inicial optou-se por utilizar uma única estrutura de RNA com arquitetura PMC. A topologia destas redes foi formada por uma camada escondida, sendo que esta camada possui 15 neurônios artificiais e a função de ativação é do tipo tangente hiperbólica. Já a camada de saída possui um neurônio artificial e sua função de ativação é do tipo rampa simples. A configuração desta rede pode ser visualizada na Figura 3.

Figura 3 – Diagrama de configuração da RNA.



Fonte: Autores.

Segue abaixo os comandos básicos do MatLab para processar a RNA:

```
net = feedforwardnet(15);
net = configure(net,entradas,saidas);
net = train(net,entradas,saidas);
previsao = sim(net,dadosultimomes);
```

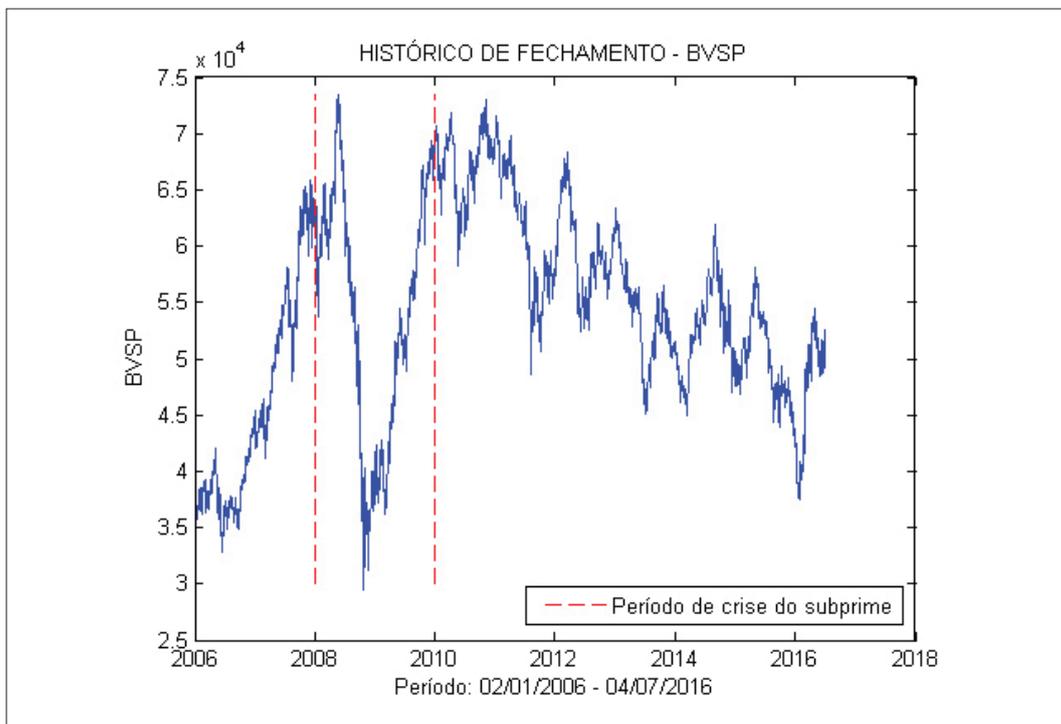
Na fase de treinamento foram selecionados aleatoriamente 70% dos dados de cada série financeiras analisada para serem usados no treinamento da rede. O algoritmo de aprendizagem utilizado foi o *Backpropagation Levenberg-Marquardt*. A fase de teste da rede foi sub-dividida em duas etapas: avaliação da previsão, que utilizou aleatoriamente 15% dos dados e o teste, propriamente dito, que utilizou os 15% restantes dos dados das séries financeiras. A análise dos erros de previsão utilizou-se do MAPE. Além de analisar o erro pelo MAPE é preciso verificar se o erro não é tendencioso, o que prejudicaria a qualidade da previsão (JOHNSON; WICHERN, 2002).

Desta forma, de acordo com a classificação de pesquisas acadêmicas apresentadas por Gil (2007) esta pesquisa é aplicada, quantitativa, descritiva e experimental.

4. RESULTADOS

Os dados selecionados para o valor de fechamento do Ibovespa possuem as seguintes características: total de dados na amostra: 2.593; média: 54.022,87; desvio padrão: 9.563,66; coeficiente de variação: 17,7%. A evolução dos valores do Ibovespa pode ser visualizada na Figura 4.

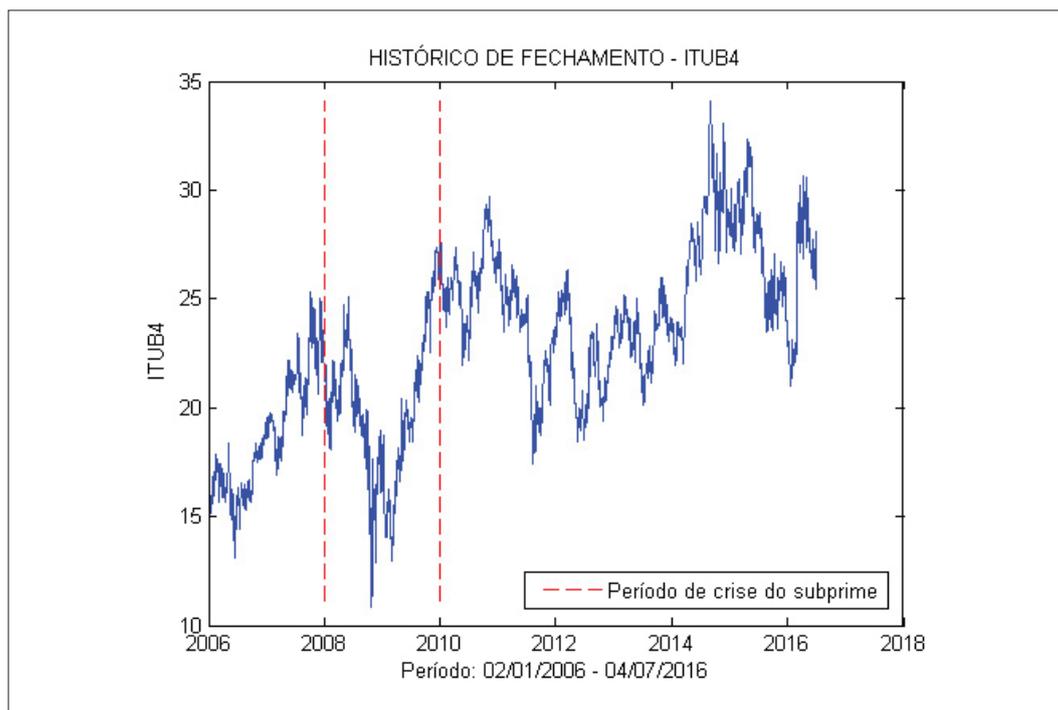
Figura 4 – Evolução do Índice Bovespa.



Fonte: Autores.

Já os dados selecionados para o preço de fechamento da ação ITUB4 possui as seguintes características: total de dados na amostra: 2.562; média: 22,84; desvio padrão: 4,18; coeficiente de variação: 18,31%. A evolução dos preços desta ação pode ser visualizada na Figura 5.

Figura 5 – Evolução dos Preços da ação ITUB4.



Fonte: Autores.

Por fim, os dados selecionados para a ação ABEV3 possui as seguintes características: total de dados na amostra: 2.588; média: 10,04; desvio padrão: 5,89; coeficiente de variação: 58,67%. A evolução dos preços desta ação pode ser visualizada na Figura 6.

Figura 6 - Evolução dos Preços da ação ABEV3.



Fonte: Autores.

Ao comparar as previsão dos retornos das três séries temporais com os dados reais, pode-se perceber a quão difícil é prever este tipo de série temporal. Desta forma faz-se necessário uma análise dos erros obtidos, o qual pode ser considerando em uma margem de segurança aceitável. A Tabela 1 compara os MAPEs resultantes de cada previsão realiza, sendo que os resultados das colunas “Todo” são referentes às RNs treinadas com o total dos dados (de 2006 a 2016), as colunas “Crise” são referentes as RNs treinadas com os dados no período da crise do *subprime* (de 2008 a 2009) e as colunas “Pós-Crise” são referentes as RNs treinadas com os dados posterior à crise do *subprime* (de 2010 a 2011). Observa-se que nenhum valor MAPE superou o lincear de 10%, dessa forma os erros puderam ser considerados como aceitáveis e com potencial para fornecer uma previsão de qualidade (LEWIS, 1997).

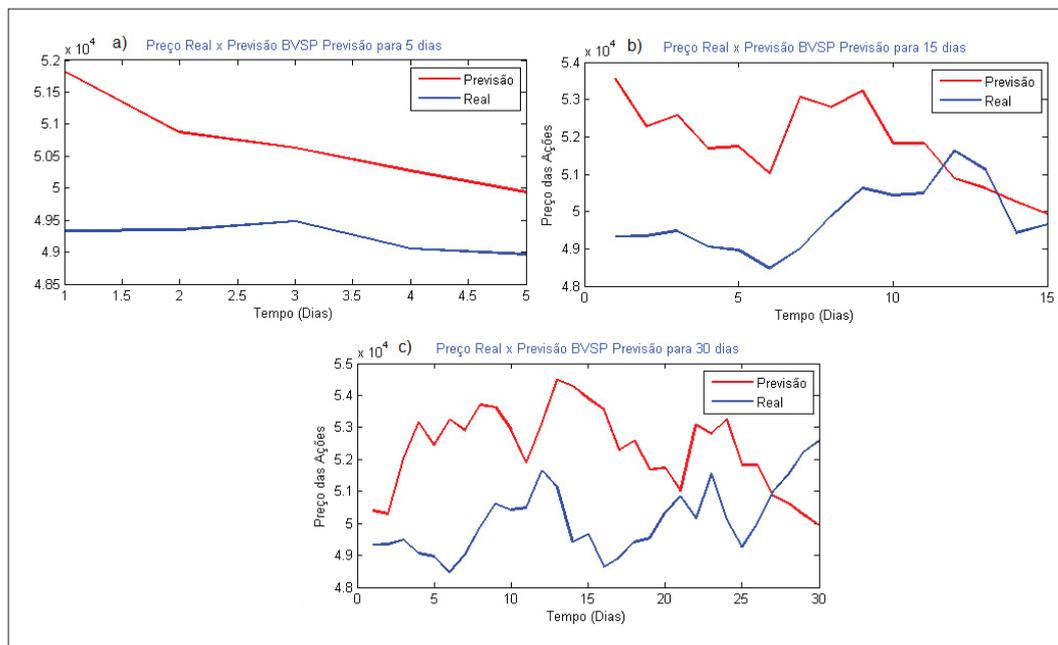
Tabela 1 - MAPE Comparativo entre Períodos Previstos.

MAPE das Previsões									
Dias Previstos	BVSP			ITUB4			ABEV3		
	Todo	Crise	Pós-Crise	Todo	Crise	Pós-Crise	Todo	Crise	Pós-Crise
5	2,99%	2,22%	3,98%	1,94%	2,37%	4,06%	2,03%	3,13%	3,22%
15	4,43%	5,09%	3,03%	4,35%	6,29%	5,89%	2,78%	4,09%	4,64%
30	5,22%	5,51%	3,48%	7,78%	6,89%	5,75%	2,31%	4,60%	9,23%

Fonte: Autores.

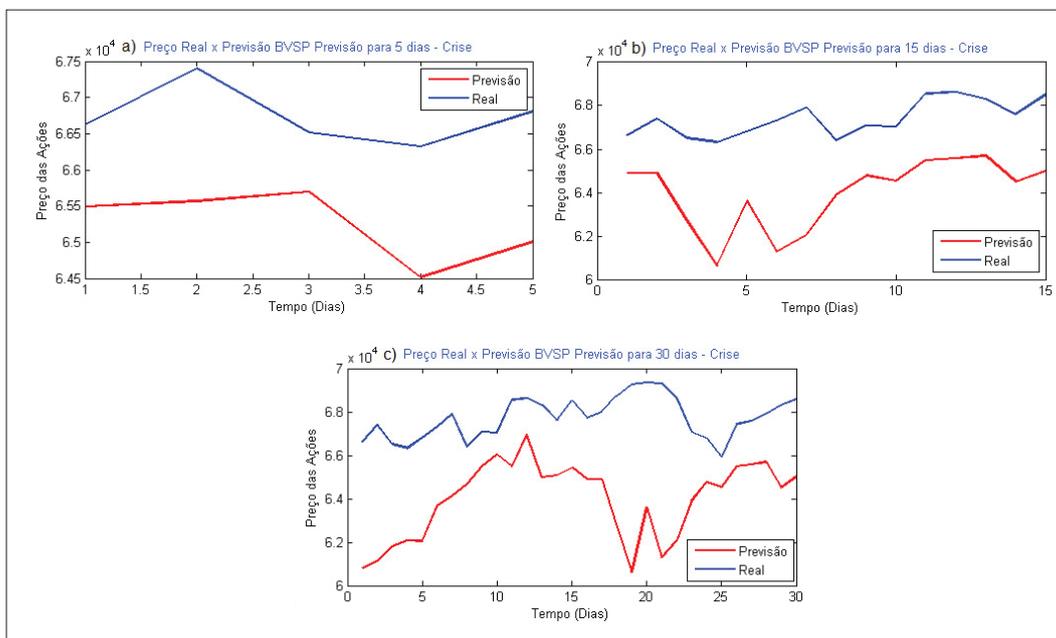
Os resultados das previsões para o fechamento diário do Ibovespa comparado aos desempenhos reais são apresentados nas Figuras 7, 8 e 9, onde é possível visualizar a previsão para 5, 15 e 30 dias (figuras a, b e c respectivamente) para treinamentos realizados com os dados totais da série histórica, dados da crise do *subprime* e dados pós-crise respectivamente.

Figura 7 - Redes treinadas com dados BVSP de 2006 a 2016: (a) Retorno Real x Previsão: 5 dias; (b) Retorno Real x Previsão: 15 dias; (c) Retorno Real x Previsão: 30 dias.



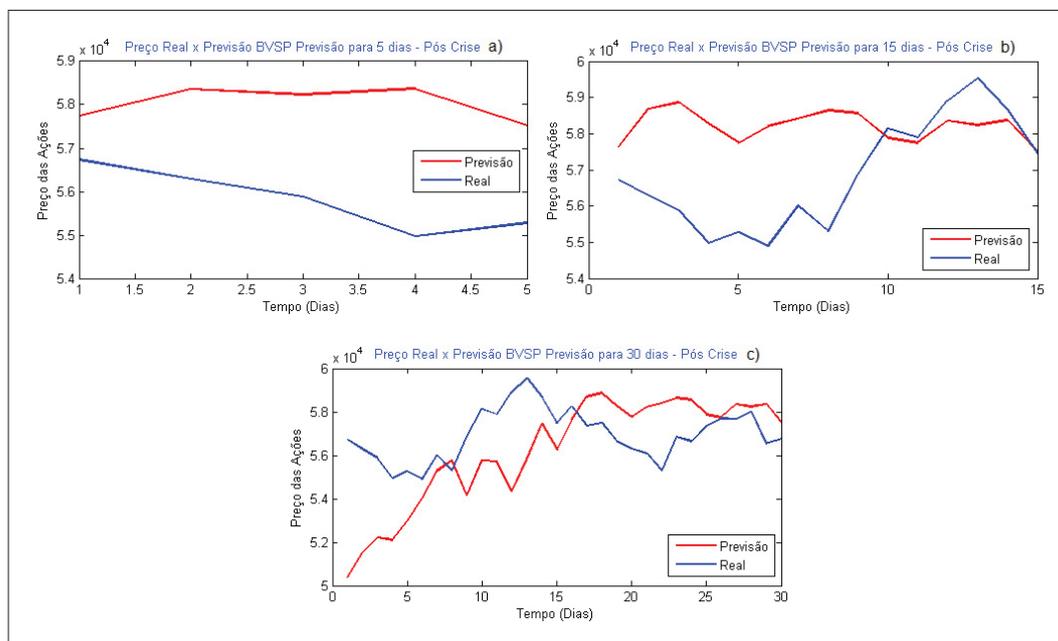
Fonte: Autores.

Figura 8 - Redes treinadas com dados BVSP de 2008 a 2009: (a) Retorno Real x Previsão: 5 dias; (b) Retorno Real x Previsão: 15 dias; (c) Retorno Real x Previsão: 30 dias.



Fonte: Autores.

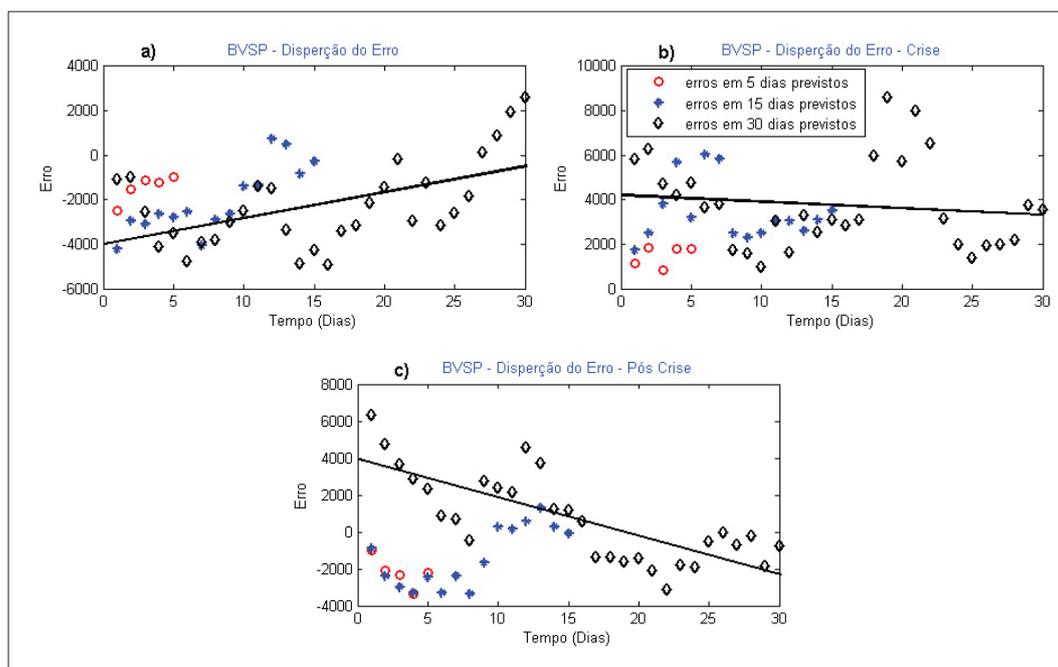
Figura 9 - Redes treinadas com dados BVSP de 2010 a 2011: (a) Retorno Real x Previsão: 5 dias; (b) Retorno Real x Previsão: 15 dias; (c) Retorno Real x Previsão: 30 dias.



Fonte: Autores.

A Figura 10 apresenta os diagramas de dispersões dos erros para previsão de 5, 15 e 30 dias referente ao comportamento do Ibovespa para RNAs treinadas com os dados totais, dados da crise do *subprime* e dados pós-crise (figura a, b e c respectivamente). Foram traçadas retas de tendências para as previsões de 30 dias. Percebe-se que o erro absoluto referente aos dados totais tende a diminuir ao passar do tempo, oscilando entre -6000 e 2000 aproximadamente, tendo uma tendência ascendente. O erro absoluto referente ao período pós-crise tem um comportamento semelhante, tendendo a diminuir ao passar do tempo, oscilando entre 6000 e -3000 aproximadamente, tendo uma tendência descendente. Já o erro referente ao período da crise tem uma alta volatilidade, porém tende a oscilar em torno de 4000.

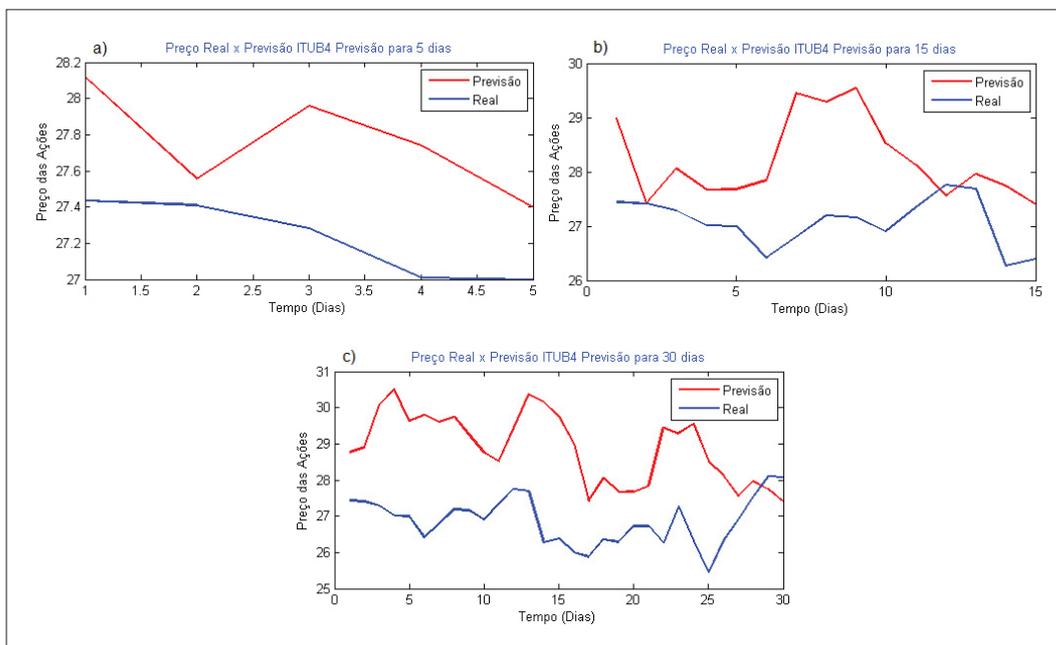
Figura 10 – Diagrama de dispersão do erro de previsão BVSP para 5, 15 e 30 dias: (a) Referente aos total de dados; (b) Referente aos dados da crise do *subprime*; (c) Referente aos dados pós-crise.



Fonte: Autores.

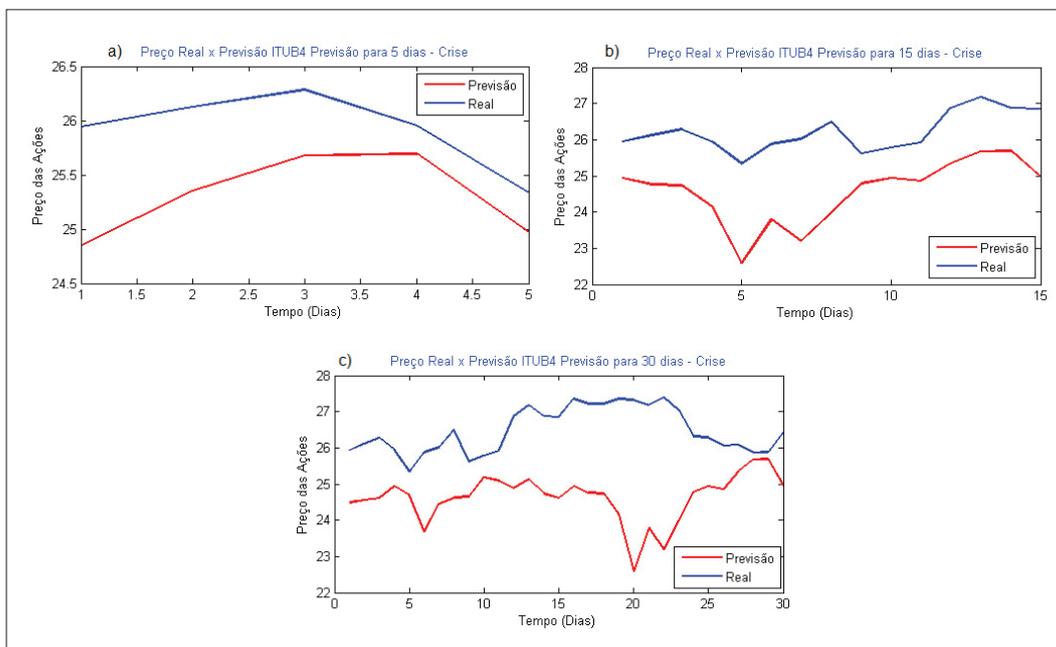
As Figuras 11, 12 e 13 apresentam os resultados das previsões para o retorno da ação ITUB4 comparado aos desempenhos reais, onde é possível visualizar a previsão para 5, 15 e 30 dias (figuras a, b e c respectivamente) para treinamentos realizados com os dados totais da série histórica, dados da crise do *subprime* e dados pós-crise respectivamente. Com relação ao período pós-crise, a previsão para 30 dias conseguiu antecipar uma tendência de alta significativa.

Figura 11 - Redes treinadas com dados ITUB4 de 2006 a 2016: (a) Preço Real x Previsão: 5 dias; (b) Preço Real x Previsão: 15 dias; (c) Preço Real x Previsão: 30 dias.



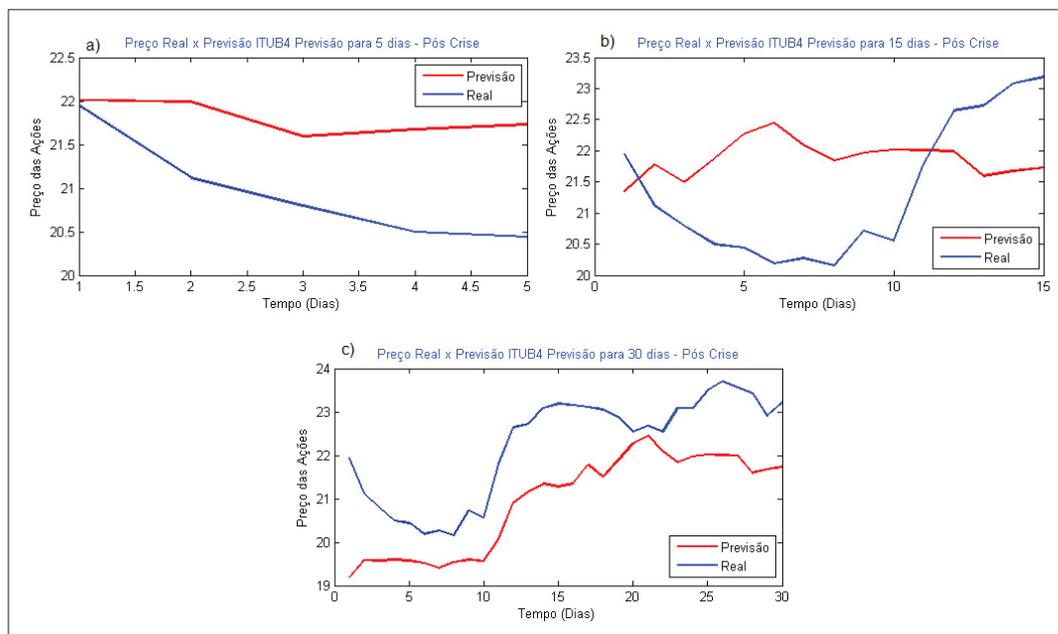
Fonte: Autores.

Figura 12 - Redes treinadas com dados ITUB4 de 2008 a 2009: (a) Preço Real x Previsão: 5 dias; (b) Preço Real x Previsão: 15 dias; (c) Preço Real x Previsão: 30 dias.



Fonte: Autores.

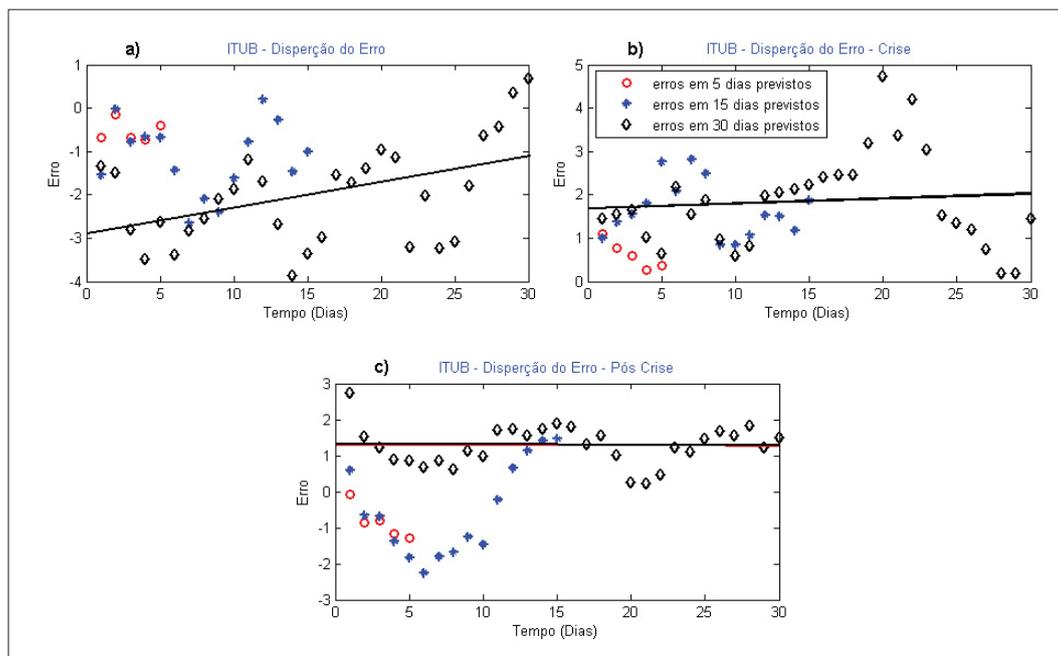
Figura 13 - Redes treinadas com dados ITUB4 de 2010 a 2011: (a) Preço Real x Previsão: 5 dias; (b) Preço Real x Previsão: 15 dias; (c) Preço Real x Previsão: 30 dias.



Fonte: Autores.

A Figura 14 apresenta os diagramas de dispersões dos erros para previsão de 5, 15 e 30 dias referente ao retorno da ação ITUB4 para RNAs treinadas com os dados totais, dados da crise do *subprime* e dados pós-crise (figura a, b e c respectivamente). Foram traçadas retas de tendências para as previsões de 30 dias. Percebe-se que o erro absoluto referente aos dados totais tende a diminuir ao passar do tempo, oscila entre -4 e 1 aproximadamente, tendendo a diminuir ao longo do tempo. Já as retas de tendência de erro nos períodos de crise e pós-crise têm coeficientes angulares praticamente desprezíveis, variando em torno de 2 e 1 respectivamente, e são positivamente viesadas.

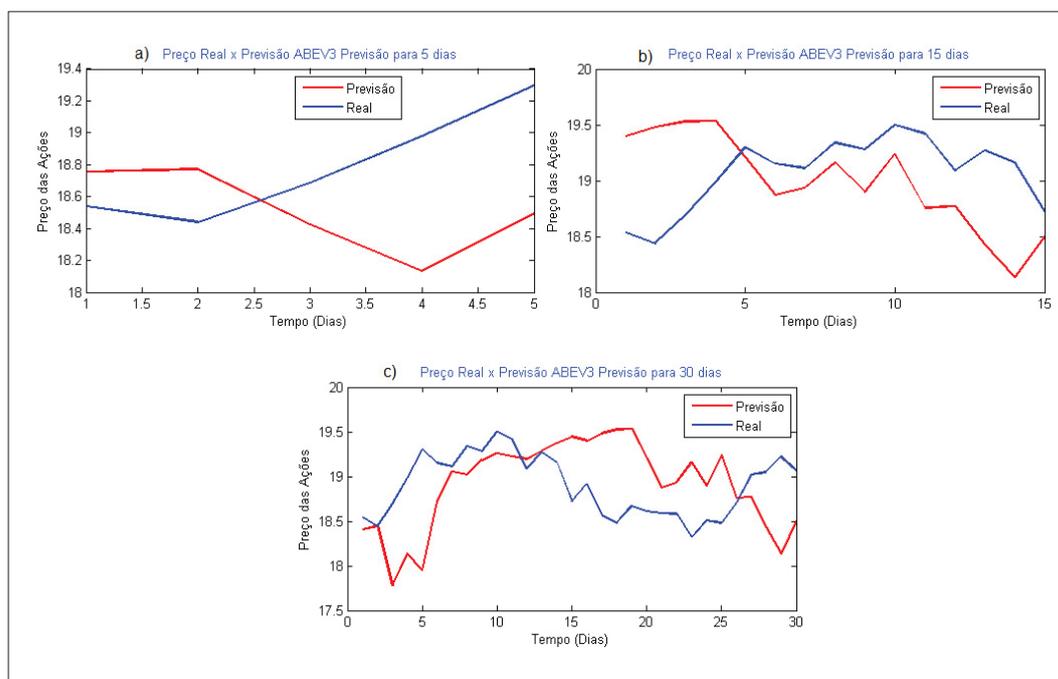
Figura 14 – Diagrama de dispersão do erro de previsão ITUB4 para 5, 15 e 30 dias: (a) Referente aos total de dados. (b) Referente aos dados da crise do *subprime*. (c) Referente aos dados pós-crise.



Fonte: Autores.

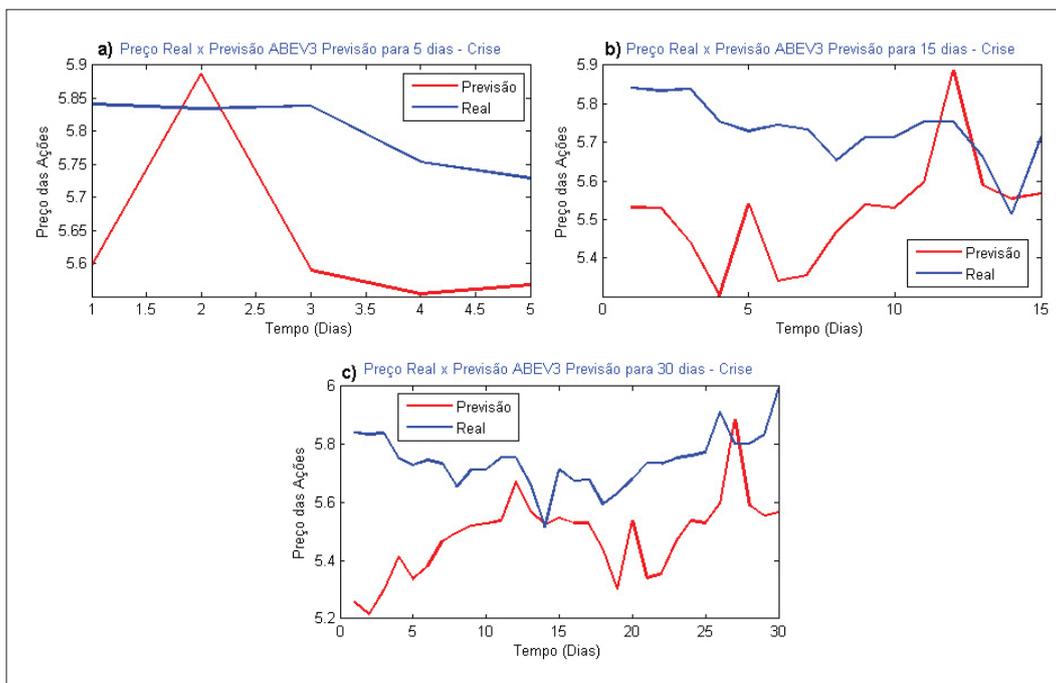
Por fim, as Figuras 15, 16 e 17 apresentam os resultados das previsões para o retorno da ação ABEV3 comparado aos desempenhos reais, onde é possível visualizar a previsão para 5, 15 e 30 dias (figuras a, b e c respectivamente) para treinamentos realizados com os dados totais da série histórica, dados da crise do *subprime* e dados pós-crise respectivamente. Para as previsões desta série temporal, percebe-se a formação de dentes de serra que invertem a tendência da previsão fornecida pela RNA numa tentativa de ser assertiva, não encontrando, porém, estabilidade. Para o período pós-crise, percebe-se ainda uma tendência de aumento da divergência entre os valores reais e os previstos. Essa divergência pode ser explicada pela consolidação de uma tendência de alta nos dados reais, em contrapartida a RNA não capta esta tendência e nos últimos dias do período de previsão, na tentativa da assertividade, tende a flutuar.

Figura 15 - Redes treinadas com dados ABEV3 de 2006 a 2016: (a) Preço Real x Previsão: 5 dias; (b) Preço Real x Previsão: 15 dias; (c) Preço Real x Previsão: 30 dias.



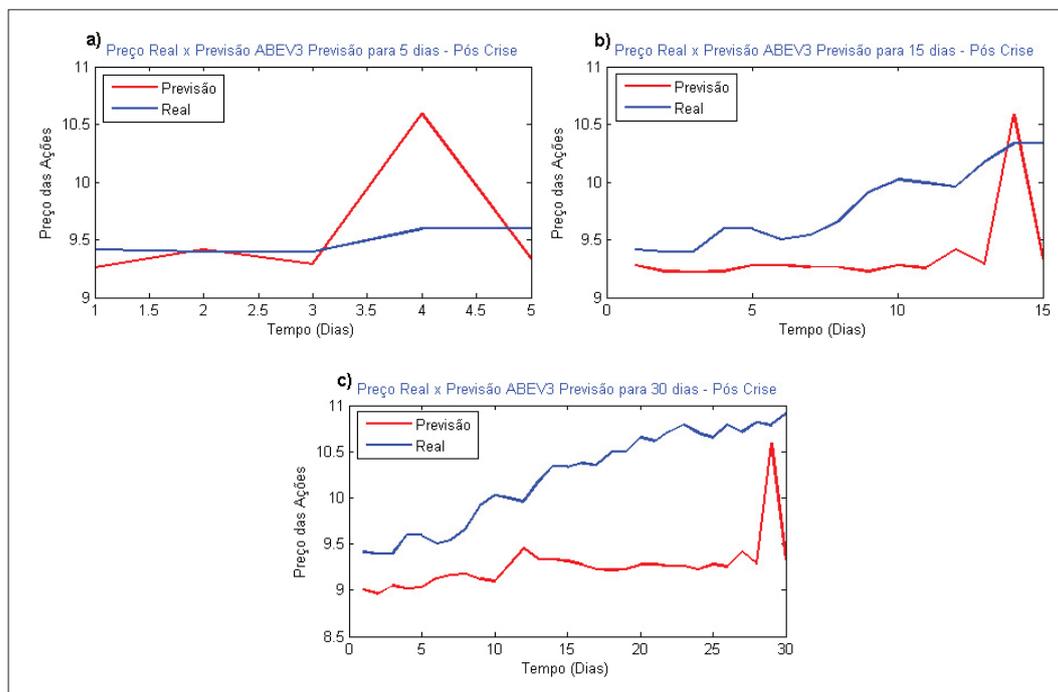
Fonte: Autores.

Figura 16 - Redes treinadas com dados ABEV3 de 2008 a 2009: (a) Preço Real x Previsão: 5 dias; (b) Preço Real x Previsão: 15 dias; (c) Preço Real x Previsão: 30 dias.



Fonte: Autores.

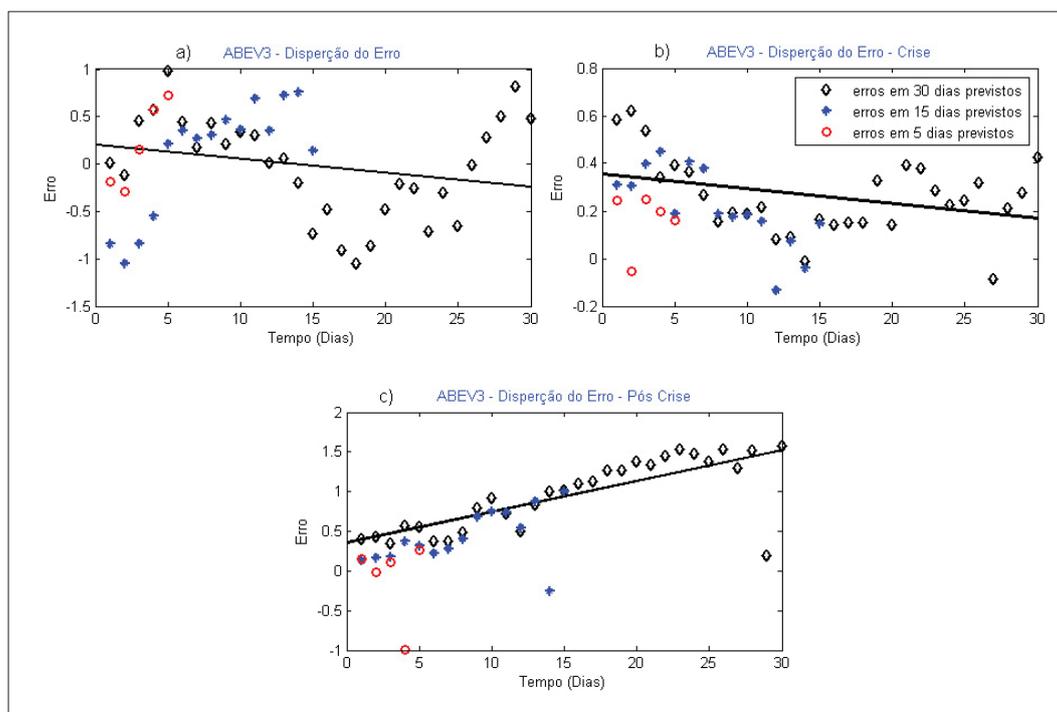
Figura 17 - Redes treinadas com dados ABEV3 de 2010 a 2011: (a) Preço Real x Previsão: 5 dias; (b) Preço Real x Previsão: 15 dias; (c) Preço Real x Previsão: 30 dias.



Fonte: Autores.

A Figura 18 apresenta os diagramas de dispersões dos erros para previsão de 5, 15 e 30 dias referente ao retorno da ação ABEV3 para RNAs treinadas com os dados totais, dados da crise do *subprime* e dados pós-crise (figura a, b e c respectivamente). Foram traçadas retas de tendências para as previsões de 30 dias. Percebe-se que o erro referente aos dados totais tem uma oscilação em torno de 0, variando entre 1,5 e -1 aproximadamente, tendo uma tendência descendente. O erro referente ao período da crise tende a diminuir com o passar do tempo, porém é positivamente viesado, oscilando em torno de 0,3 e tendo uma tendência descendente. Já o erro referente ao período pós-crise cresce ao passar do tempo, seguindo uma forte tendência ascendente, variando entre 0 e 1,5 aproximadamente, sendo positivamente viesado.

Figura 18 – Diagrama de dispersão do erro de previsão ABEV3 para 5, 15 e 30 dias: (a) Referente aos total de dados; (b) Referente aos dados da crise do *subprime*; (c) Referente aos dados pós-crise.



Fonte: Autores.

5. DISCUSSÕES

Percebeu-se que em períodos de alta volatilidade, como o período da crise do *subprime*, a RNA tende a ter dificuldades em realizar previsões de qualidade. Com isso foi observado que as previsões realizadas no período da crise do *subprime* para as três séries temporais geraram erros positivamente viesados não aleatórios, variando em torno de um valor constante. Para o período total considerado, o qual inclui o período da crise do *subprime*, em geral o erro flutuou próximo de 0, tendendo a diminuir ao longo do tempo. Tal resultado satisfatório pode ser explicado pelo tamanho da série temporal utilizada para treinar a rede, tendo cerca de uma década de informações.

Porém era esperado que as previsões pós-crise tivessem um desempenho melhor que os observados em relação a distribuição dos erros ao longo do tempo. Isto pode estar relacionado com a curta série temporal utilizada para treinar a RNA, referente ao período de 2 anos pós-crise do *subprime*. Sobre a previsão tendenciosa referente ao período pós-crise da ação ABEV3, o qual apresentou aumento na divergência entre preços reais e previstos ao passar do tempo, pode estar relacionada a natureza dos dados desta ação, que possuem uma grande volatilidade, tendo um coeficiente de variação de 58,67%, o que pode ter dificultado a previsão feita pela RNA.

Em geral é possível perceber, observando a Tabela 1, que quanto maior o período de previsão o MAPE tende a ser maior. Além disso, todos os valores de MAPE obtidos foram inferiores a 10%, o que segundo Lewis (1997), é considerado muito bom e com potencial para fornecer uma previsão de qualidade.

Desta forma, este trabalho tem semelhança e reforça os resultados já encontrados na literatura ao utilizar RNAs na previsão do comportamento de ações e índices financeiros negociados na B3 (MARTINS; METTE; MACEDO, 2008; OLIVEIRA, 2007; ROCA; MÓL, 2015). Porém, tais artigos avaliaram individualmente o Ibovespa ou alguma ação negociável na bolsa brasileira, sendo o diferencial do atual trabalho utilizar uma mesma configuração de RNA para previsão tanto de ações quanto de índice financeiro, além do enfoque na previsão do período da crise do *subprime* no contexto brasileiro entre 2008 e 2009 e suas vizinhanças temporais.

6. CONCLUSÕES

Em relação à previsão do comportamento das ações e do Ibovespa, considerando que nenhum valor MAPE ultrapassou o limiar de 10% e sendo que na maioria dos erros foram encontradas tendências ou vieses, podemos concluir que a rede *Feedforward*, com as configurações já mencionadas, apresentou resultados satisfatórios. Para estudos futuros sugere-se fazer uma comparação entre diferentes modelos, prever o comportamento de diferentes ações ou índices ou validação de uma arquitetura diferente para a RNA.

REFERÊNCIAS

- ADHIKARI, R.; AGRAWAL, R. K. A combination of artificial neural network and random walk models for financial time series forecasting. **Neural Computing and Applications**, v. 24, n. 6, p. 1441–1449, 2014.
- AMBEV. **Ambev**. Disponível em: <<http://www.ambev.com.br/>>. Acesso em: 3 jul. 2016.
- B3, Brasil Bolsa Balcão. **Relações com Investidores**. 2017. Disponível em: <<http://ri.bmfbovespa.com.br/>>. Acesso em: 10 out. 2017.
- BM&FBOVESPA. **BM&F Bovespa**. 2016. Disponível em: <<http://www.bmfbovespa.com.br>>. Acesso em: 10 out. 2017.
- BORÇA JUNIOR, G. R. B.; TORRES FILHO, E. T. Analisando a crise do subprime. **Revista do BNDES**, v. 15 n. 30, p. 129-159. Rio de Janeiro, 2008.
- GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2007.
- IEDI – INSTITUTO DE ESTUDOS PARA O DESENVOLVIMENTO INDUSTRIAL. Entendendo a crise do subprime e suas repercussões na economia mundial. **Carta IEDI**, n. 300, fev. 2008.
- ITAÚ. **O Itaú Unibanco**. Disponível em: <<https://www.itau.com.br/relacoes-com-investidores/o-itau-unibanco>>. Acesso em: 3 jul. 2016.
- JOHNSON, R. A.; WICHERN, D. W. **Applied Multivariate Statistical Analysis**. 5. ed. New Jersey: Prentice Hall, 2002.
- KRUGMAN, P. **A crise de 2008 e a economia da depressão**. Rio de Janeiro: Editora Campus, 2009.
- LAHMIRI, S. A variational mode decomposition approach for analysis and forecasting of economic and financial time series. **Expert Systems with Applications**, v. 55, p. 268–273, 2016.
- LEITE, H. P.; SANVICENTE, A. Z. **Índice Ibovespa: um padrão para os investimentos brasileiros**. São Paulo: Atlas, 1994.

LEWIS, C. D. **Demand forecasting and inventory control**: A computer aided learning approach. Cambridge: Woodhead Publishing Ltd, 1997.

LUDWIG JR, O.; COSTA, E. M. M. **Redes neurais**: fundamentos e aplicações com programas em c. Rio de Janeiro: Ciência Moderna, 2007.

MARTINS, M. A. S.; METTE, F.; MACEDO, G. R. A Utilização de Redes Neurais Artificiais para a Estimção dos Preços da Petrobrás PN na Bovespa. **Contexto**, v. 8, n. 14, p. 1–16, 2008.

MATUCHESKI, S.; CLEMENTE A.; SANDRINI, J. C. Governança corporativa e volatilidade das ações negociadas na Bovespa na crise financeira de 2008. **Revista Brasileira de Estratégia**. v. 2, n. 2, p. 171-183. 2009

MO, H.; WANG, J.; NIU, H. Exponent back propagation neural network forecasting for financial cross-correlation relationship. **Expert Systems with Applications**, v. 53, n. 2016, p. 106–116, 2016.

OLIVEIRA, M. A. **Aplicação de Redes Neurais Artificiais na Análise de Séries Temporais Econômico-Financeiras**. 2007. 316f. Tese (Doutorado em Administração) - Universidade de São Paulo, Faculdade de Economia, Administração e Contabilidade, São Paulo, 2007.

ROCA, R. L. R. S.; MÓL, A. L. R. Previsão do Índice Bovespa por Meio de Redes Neurais Artificiais. **Business and Management Review**, v. 4, n. 10, p. 377–390, 2015.

SILVA, I. N.; SAPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais**: Para Engenharia e Ciências Aplicadas. São Paulo: Artliber, 2010.

WANKE, P. F. **Gerência de operações**: uma abordagem logística. São Paulo: Atlas, 2010.

YAHOO. **Yahoo Finanças**. Disponível em: <<https://br.financas.yahoo.com>>. Acesso em: 3 out. 2017.