

## **PREVISÃO DE SÉRIES TEMPORAIS: UMA APLICAÇÃO DAS REDES NEURAIS ARTIFICIAIS AO IBOVESPA**

**CESAR HENRIQUE BARRERA MARTINS**

CENTRO UNIVERSITÁRIO ÁLVARES PENTEADO (FECAP)

cesar\_psl@hotmail.com

**GABRIEL HOSSRI MATHEOS POLICASTRO**

CENTRO UNIVERSITÁRIO ÁLVARES PENTEADO (FECAP)

gabrielpolicastro@outlook.com

**JEFFERSON ALVICO**

CENTRO UNIVERSITÁRIO ÁLVARES PENTEADO (FECAP)

jeffersonalvico@hotmail.com

**MARCEL SOLÉO TARTAGLIONI**

CENTRO UNIVERSITÁRIO ÁLVARES PENTEADO (FECAP)

marcelsoleo@outlook.com

**MATHEUS PARIZI MARTINS DE MORAES**

CENTRO UNIVERSITÁRIO ÁLVARES PENTEADO (FECAP)

matheus.moraes@edu.fecap.br

## **Introdução**

O presente estudo se propõe a treinar uma rede neural artificial para prever uma série temporal, pleiteando assim responder à pergunta: uma rede neural artificial, que tenha como variáveis os agregados macroeconômicos, inflação, calculada pelo IPCA, a taxa câmbio que é refletida sobre a variação do dólar (PTAX), e a taxa básica de juros, a Selic meta, pode prever o comportamento do Ibovespa para um, seis e doze meses à frente?

## **Problema de Pesquisa e Objetivo**

A pesquisa busca identificar se os agregados macroeconômicos podem servir de parâmetros para realizar a previsão da série de retornos do Ibovespa e se uma rede neural artificial se mostra adequada para a previsão.

## **Fundamentação Teórica**

Foram usados como fundamentação teórica, artigos e livros sobre previsão de séries temporais, redes neurais artificiais, função de base radial, carteira de mercado e sobre os agregados macroeconômicos juros, taxa de câmbio e inflação.

## **Metodologia**

Tendo em vista o conteúdo e os objetivos propostos, a abordagem da pesquisa será eminentemente quantitativa, descritiva e ex-post facto. Os dados empregados no estudo correspondem às séries históricas mensais, anuais e semestrais dos seguintes indicadores:

- Ibovespa
- IPCA
- Cotação do Dólar Comercial Compra (PTAX)
- Taxa SELIC

## **Análise dos Resultados**

Após a modelagem da rede atingir os parâmetros de aprendizagem desejado, partiu-se para a extrapolação do intervalo de aprendizagem. Os dados reais das variáveis independentes do período  $t$  foram inseridas na rede para a realização da previsão do valor da série em  $t+1$ .

Esse processo se repetiu até completar o intervalo da série temporal destinado ao teste da modelagem.

O resultado obtido na saída da rede foi comparado ao resultado real do Ibovespa.

## **Conclusão**

A modelagem apresentou-se capaz de prever com razoável precisão a série histórica do Ibovespa na defasagem de um e seis meses, sendo insatisfatória na defasagem de doze meses.

## **Referências Bibliográficas**

- ASSAF, N. A. Mercado financeiro. 8. ed. São Paulo: Atlas, 2008.
- BISHOP, C. M. Neural networks for pattern recognition. New York: Oxford University Press, 2004.
- BM&FBOVESPA. Índice Brasil 100 (IBrX 100). Disponível em: . Acesso em: 30 de mar. 2016.
- GIL, A. C. Como elaborar projetos de pesquisa. São Paulo: atlas, 2002.
- GRÔPPO, S. G. Causalidade de variáveis macroeconômicas sobre o IBOVESPA. Dissertação de Mestrado – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2004.

## **PREVISÃO DE SÉRIES TEMPORAIS: UMA APLICAÇÃO DAS REDES NEURAI ARTIFICIAIS AO IBOVESPA**

**Resumo:** Investidores institucionais, pessoas e governos estão cada vez mais munidos de recursos e arcabouços teóricos para sustentar e guiar as suas decisões no ambiente econômico e financeiro. Contudo, com o surgimento da era da informática o volume de informações de que se dispõe oferecem tantas possibilidades quanto dificuldades na sua seleção, tratamento e aplicação para a tomada de decisão. Os estudos voltados para redes neurais artificiais, que inicialmente se propunham a criar uma inteligência artificial, culminaram em um poderoso recurso de tratamento de dados e identificação de padrões inspirados nos mecanismos de aprendizagem do cérebro humano. Assim, esse estudo procurou aplicar o treinamento de uma rede neural para realização de previsão da série temporal do Ibovespa, admitindo os agregados macroeconômicos Juros, Inflação e Câmbio como variáveis explicativas. A modelagem apresentou-se capaz de prever com razoável precisão a série histórica do Ibovespa na defasagem de um e seis meses, sendo insatisfatória na defasagem de doze meses.

**Palavras-chave:** Função de base radial, Carteira de Mercado, Agregados Macroeconômicos

## **PREDICTION OF TIME SERIES: AN APPLICATION OF ARTIFICIAL NEURAL NETWORKS TO IBOVESPA**

**Abstract:** *Institutional investors, people and governments are increasingly arming themselves with resources and theoretical frameworks to support and guide their decisions on an economic and financial environment. However, with the advent of the age of information technology, the great amount of information available offers as many possibilities as difficulties when it comes to selecting the best data for decision-making. The studies focused on artificial neural networks, which initially were intended to create an artificial intelligence, culminated in a powerful feature of processing and identifying patterns inspired by the learning mechanisms of the human brain. Thus, this study sought to apply the training of a neural network for time series prediction of the IBOVESPA, admitting the macroeconomics aggregates, inflation and foreign exchange interest as explanatory variables. The modeling appeared able to predict with reasonable accuracy the IBOVESPA's historic series in lag of one and six months, being unsatisfactory in 12-month-lag.*

**Keywords:** *Radial Basis Function, Market Portfolio, Macroeconomic Aggregates*

## 1 INTRODUÇÃO

Diversos estudos analisaram a influência dos agregados macroeconômicos para explicar as variações ocorridas no mercado acionário nacional e internacional, a exemplo de Grôppo (2004) e Pimenta Junior e Higuchi (2008), tais esforços se mostram necessários, pois a identificação dessas relações auxilia na tomada de decisões no âmbito empresarial e governamental. Contudo, muitas dessas pesquisas são caracterizadas pelo uso de métodos estatísticos e/ou econométricos como ARIMA (*autoregressive integrated moving average*), entre outros.

O presente estudo se propõe a treinar uma rede neural artificial para prever uma série temporal, pleiteando assim responder à pergunta: uma rede neural artificial, que tenha como variáveis os agregados macroeconômicos, inflação, calculada pelo IPCA, a taxa câmbio que é refletida sobre a variação do dólar (PTAX), e a taxa básica de juros, a Selic meta, pode prever o comportamento do Ibovespa para um, seis e doze meses à frente?

Assim, reconhecendo a relevância e a notoriedade que vêm ganhando os estudos direcionados às redes neurais artificiais e a sua capacidade em modelar e aproximar funções complexas para identificar padrões em dados, como demonstrado por Zhang, Patuwo e Hu (1998), propõe-se identificar se os agregados macroeconômicos podem servir de parâmetros para realizar a previsão da série de retornos do índice anteriormente citado e se uma rede neural artificial se mostra adequada para a previsão, além de identificar a defasagem com que a rede melhora sua capacidade de previsão.

Este trabalho é justificado por aplicar um método não utilizado até a data de submissão desse artigo, em estudos nacionais, para previsão de uma série de retornos do Ibovespa, pretendendo-se com isso testar uma modelagem capaz de predizer o comportamento deste índice.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Previsão de Séries Temporais

Existem pelo menos cinco abordagens à previsão econômica de séries temporais (GUJARATI, 2006):

- Métodos de suavizamento exponencial;
- Modelos de regressão com uma única equação;
- Modelos de regressão com equações simultâneas;
- Modelos auto-regressivos integrados de médias móveis (ARIMA) e
- Auto-regressões vetoriais (VAR).

De maneira geral, esses modelos se sustentam na hipótese de que as séries temporais são estacionárias, ou que podem ser transformadas a fim de se tornarem estacionárias. (GUJARATI, 2006)

Os modelos de previsão Box-Jenkins (modelos ARIMA) apresentam uma potencial limitação na aplicação em muitos fenômenos econômicos, pois “na prática, a maior parte das séries econômicas é não-estacionária” (GUJARATI, 2006, p. 665).

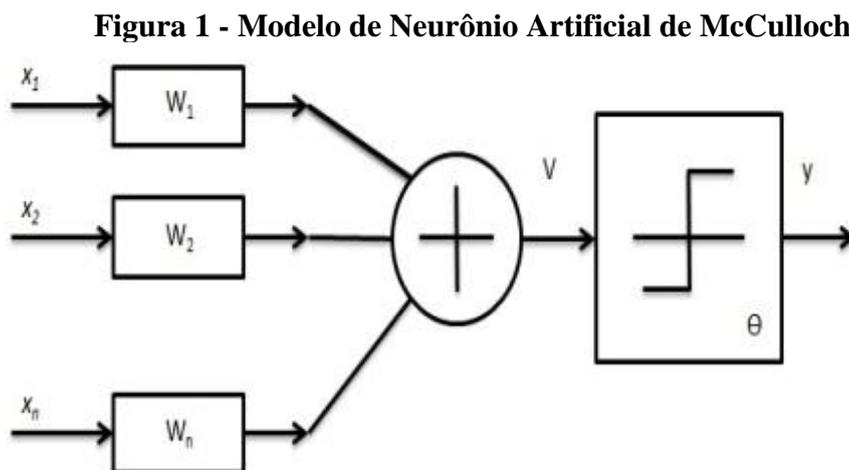
Hair et al (2005, p. 325) destacam que: “A natureza flexível [das redes neurais] as tornam adaptáveis a uma vasta amplitude de problemas, variando de previsão e classificação até mesmo a análise de séries temporais”.

Zhang, Patuwo e Hu (1998) estudaram a aplicação dos modelos ARIMA e das Redes Neurais e os resultados obtidos apontam para a limitação dos primeiros em ambientes de não-linearidade, indicando que a capacidade de generalização e aprendizagem de padrões de um conjunto de observações passadas é mais assertiva com as RNAs (Redes Neurais Artificiais).

## 2.2 Redes Neurais Artificiais

Uma rede neural artificial é um algoritmo que simula o comportamento do cérebro humano em um computador digital. A rede é modelada pela interligação de células computacionais, os “neurônios”, que são acionados através de ajustes nos pesos associados às variáveis de entrada, os chamados pesos sinápticos. A rede, então, é submetida a um processo de aprendizagem que visa modificar esses pesos, gerando as sinapses que aperfeiçoam o algoritmo e melhoram sua capacidade de detectar padrões nos dados. (HAYKIN, 2001).

O artigo de McCulloch, pioneiro no assunto, propôs a representação de um neurônio simples, capaz de lidar com operadores booleanos não complexos. O modelo, conforme o representado na figura 1, era um dispositivo binário que ponderava arbitrariamente suas entradas para obter uma saída do tipo pulso ou não-pulso, semelhante ao neurônio biológico apresentado na figura 2. (KOVÁCS, 2002).

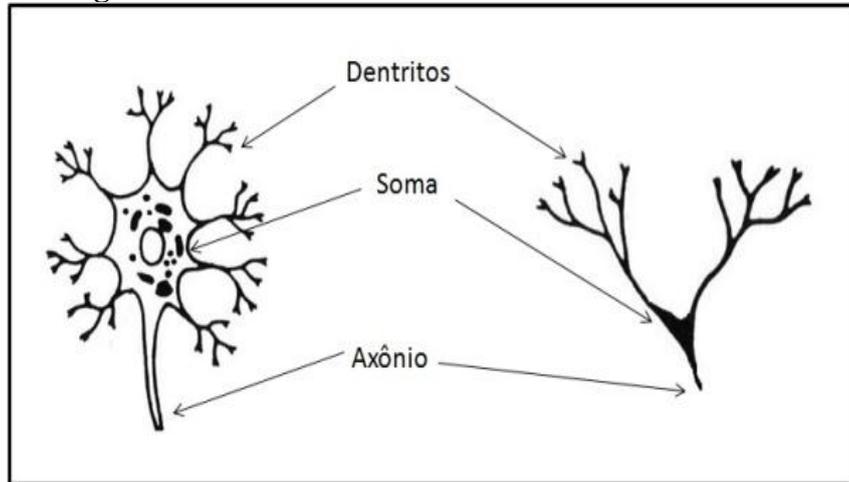


Fonte: KOVÁCS (2002, p. 30)

Nota: Representação do neurônio artificial proposta por McCulloch.

No esquema, cada variável do modelo ( $x_i$ ) é multiplicada por um peso arbitrário ( $w_i$ ), os pesos sinápticos, e então somados. O somatório torna-se a variável ( $V$ ) da função de ativação ( $\Theta$ ), que retornará o resultado final ( $y$ ).

**Figura 2 - Neurônio do Sistema Nervoso dos Vertebrados**

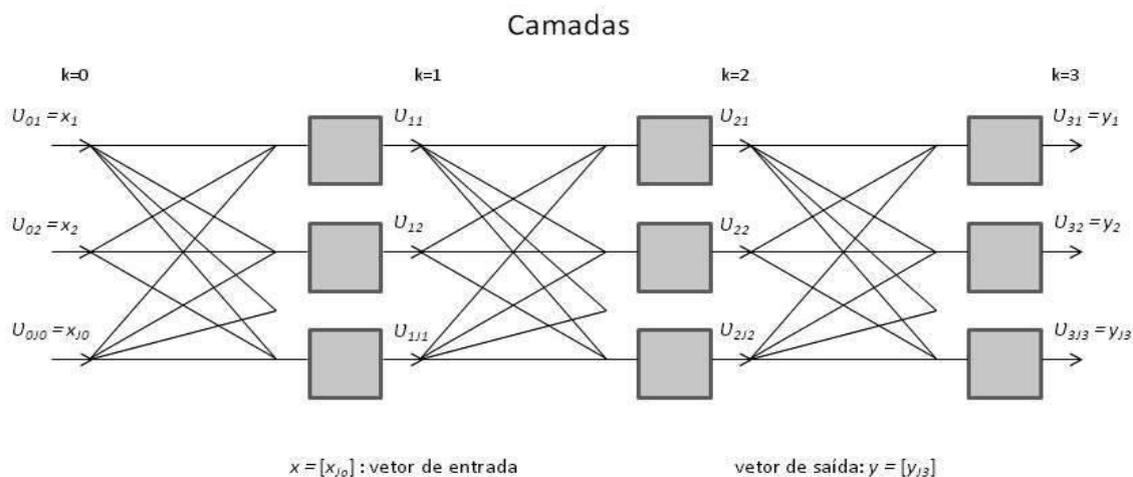


Fonte: KOVÁCS (2002, p. 14)

Nota: Representação do neurônio biológico. É possível perceber a semelhança com o modelo proposto por McCulloch

Rosenblatt (apud KOVÁCS, 2002), tendo como base os estudos de McCulloch, desenvolveu, em meados de 1950, uma rede de múltiplos neurônios. Essa rede, que chamou de *Perceptron* (Figura 3), é constituída de um certo número de neurônios, dispostos em camadas, sendo a camada inicial a camada de entrada dos dados, e camada final a camada de saída. A camada de entrada processa os dados e envia para segunda camada e assim sucessivamente, até a camada final. As camadas de neurônios posicionadas entre a camada inicial e final são conhecidas como camadas ocultas (BISHOP, 2004; KOVÁCS, 2002).

**Figura 3 – Perceptron Multicamadas**



Fonte: KOVÁCS (2002, p. 40)

Nota: O Perceptron Multicamadas é constituído de uma rede de neurônios artificiais. O vetor de entrada ( $x$  ou  $U$ ) contém as variáveis do modelo, sendo processado pelas camadas de neurônios ( $k$ ). O resultado produzido em uma camada é enviado à seguinte e assim sucessivamente até a camada final.

A utilização de multicamadas para construção de uma RNA apresentou um avanço para os estudos, pois possibilitou que as RNAs se tornassem aptas a lidar com relações mais complexas nos dados. Era de se esperar que o desenvolvimento de um método de aprendizagem fosse formulado para proporcionar a “aprendizagem” da rede a partir de um conjunto de dados de treinamento, a exemplo do que ocorre com os processos de aprendizagem humana (KOVÁCS, 2002).

A resposta para o problema do treinamento de uma RNA foi inicialmente formulada por Widrow em 1962 com o princípio da *Regra Delta*, que posteriormente foi generalizada por Rummelhart, Hinton e Willians para a formulação do principal algoritmo de aprendizagem de rede desenvolvido até o momento, o algoritmo de retro propagação do erro, ou *error backpropagation* (KOVÁCS, 2002).

O processo de treinamento de uma rede neural pelo algoritmo de retro propagação do erro envolve um procedimento iterativo para minimização de uma função de erro. O algoritmo realiza ajustes passo a passo para aproximar o valor de saída de rede para o valor desejado. As interações ocorrem até que a rede atinja o nível de erro que se deseja aceitar. (HAYKIN, 2001).

### 2.3 Função de Base Radial

Uma rede neural que possui, em sua camada oculta, funções de ativação sintonizadas em torno de uma região são chamadas Redes de Função de Base Radial ou *Radial Basis Function (RBF)*, em inglês (KOVÁCS, 2002).

Essa classe de rede neural tem a particular característica de admitir como parâmetro de ativação a distância entre o vetor de dados de entrada e um vetor arbitrário (BISHOP, 2004).

Formalizando, dado um conjunto de  $\mathbf{K}$  vetores  $n$ -dimensionais e suas respectivas observações  $t$ , pretende-se encontrar uma função  $f(x)$  tal que:

$$f(x_k) = t_k, \quad k = 1, 2 \dots, K$$

A saída da rede é dada como a combinação linear das funções base:

$$f(x_k) = \sum_n w_n \varphi(\|x_k - p_n\|) + b \quad (1)$$

Em que:

$\|x_k - p_n\|$  = distância euclidiana entre o  $k$ -ésimo vetor de entrada e o  $n$ -ésimo neurônio base

$w$  = peso atribuído ao neurônio base

$b$  = coeficiente de ajuste

$\varphi(r)$  = função de ativação

A função de ativação mais empregada em modelagens de Redes Neurais FBR é a Gaussiana:

$$\varphi(r) = e^{-\sigma r^2} \quad (2)$$

O parâmetro  $\sigma$  determina o grau de ponderação produzido pelo neurônio. Um sigma maior significa uma base radial mais larga e, portanto, mais suscetível à captação da sinapse produzido pelo vetor de entrada (KOVÁCS, 2002).

O treinamento de uma Rede Neural de Base Radial não é o mesmo daquele aplicado às redes multicamadas como o *Perceptron*. A utilização do algoritmo de retropropagação do erro exigiria um elevado número de cálculos, o que tornaria a tarefa de aprendizagem da rede potencialmente interminável para situações em que se pleiteia utilizar um número extenso de variáveis (KOVÁCS, 2002).

### **3 METODOLOGIA**

#### **3.1 Classificação da pesquisa**

Tendo em vista o conteúdo e os objetivos propostos, a abordagem da pesquisa será eminentemente quantitativa, descritiva e *ex-post facto*.

#### **3.2 Universo da pesquisa e coleta dos dados**

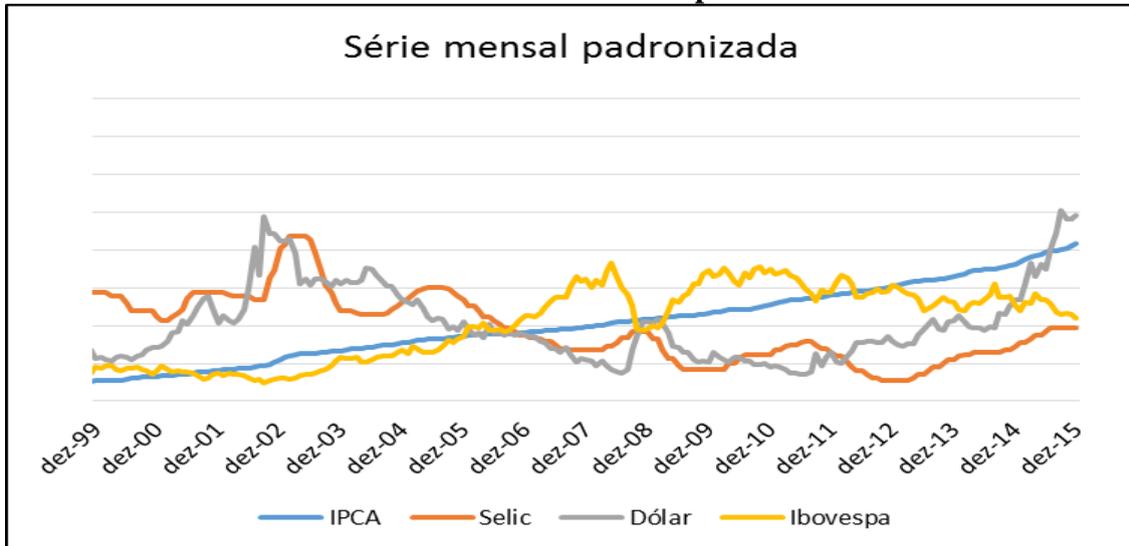
Os dados empregados no estudo correspondem às séries históricas mensais, anuais e semestrais dos seguintes indicadores:

- Ibovespa, o índice de mercado da Bolsa Valores de São Paulo (BM&FBovespa), selecionado como variável dependente;
- IPCA, índice de preços oficial do Brasil, medido pelo IBGE, admitido como variável independente;
- Cotação do Dólar Comercial Compra (PTAX), medido e divulgado pelo Banco Central do Brasil, admitido como variável independente;
- Taxa do SELIC, a taxa básica de juros da economia, admitido como variável independente.

A série histórica das variáveis foram selecionadas no intervalo de 1º de janeiro de 2000 à 31 de dezembro de 2015.

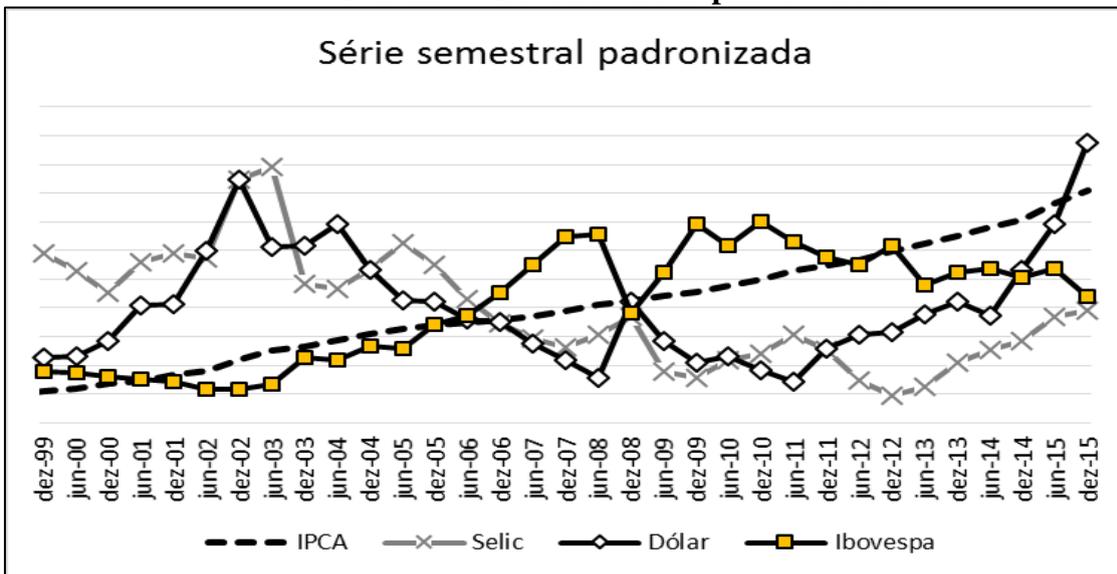
A modelagem da rede neural foi realizada com o auxílio da planilha eletrônica Microsoft Excel, pois trata-se de um software de fácil manuseio e é financeiramente mais acessível em comparação com outros *softwares* de modelagem de redes neurais disponíveis.

**Gráfico 1 – Série mensal padronizada**



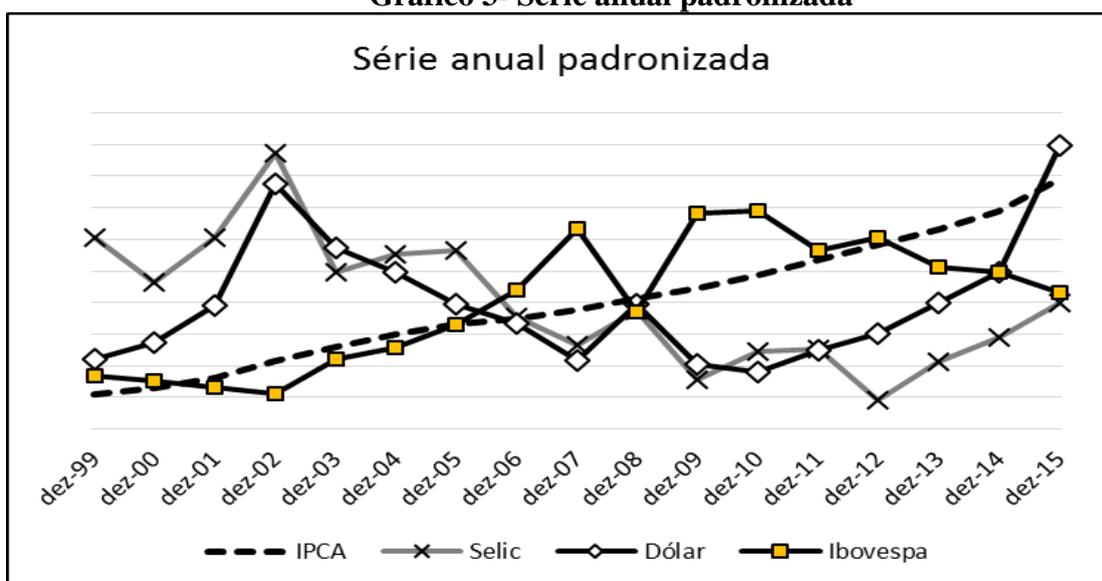
Fonte: Dos autores

**Gráfico 2 – Série semestral padronizada**



Fonte: Dos autores

Gráfico 3- Série anual padronizada



Fonte: Dos autores

Por meio da demonstração gráfica das séries é possível fazer interpretações sobre a relação entre as variáveis macroeconômicas e o Ibovespa.

Durante o período de janeiro de 2000 e junho de 2008 (gráfico 1), ano da crise financeira mundial, o Ibovespa manteve-se em constante crescimento, sendo que as variáveis Taxa de Juros e Câmbio mantinham tendência de queda no mesmo período.

Essa relação negativa entre câmbio, taxa de juros e o Ibovespa que se observou no período está em linha com Kennedy (2004), ao afirmar que uma taxa de câmbio depreciada estimula a atividade econômica devido ao aumento na demanda externa.

Em junho de 2008 eclode a crise financeira mundial nos países desenvolvidos, fenômeno que afetou economias do mundo todo, principalmente por conta da retração do crédito global. Nesse período, os agregados macroeconômicos de Câmbio e Taxa de Juros são abruptamente interrompidos na sua tendência de queda e sofrem uma elevação intensa. O Ibovespa então apresenta uma queda violenta, reforçando o pressuposto de relação dessas variáveis.

Nos dois anos seguintes (2009 e 2010), como demonstrado no gráfico 1, essas variáveis novamente se alteram e retomam o ritmo observado no período anterior à crise, ocorrendo novamente a relação inversa entre Câmbio, Juros e o Ibovespa.

O período segue, a partir de 2010, com a tendência de alta do Câmbio e dos Juros e queda no Índice Bovespa, indicando retração da atividade econômica. Também se observa que o nível de preços apresenta uma ligeira elevação nos últimos meses da série.

Com essa breve descrição dos dados, procurou-se evidenciar que, empiricamente, é possível identificar as relações entre os agregados macroeconômicos e o Ibovespa, indicando que essas variáveis podem ser empregadas em um modelo de previsão de séries temporais, como proposto pelo presente trabalho.

## 4 ANÁLISE DOS RESULTADOS

O conjunto de dados das séries foi dividido em dois grupos:

- O primeiro grupo é o grupo de treinamento da rede. Refere-se à série histórica compreendida entre 1º de janeiro de 2000 a 31 de dezembro de 2010;
- Os dados restantes constituem o grupo empregado na avaliação da capacidade de previsão e generalização do modelo. Refere-se à série histórica compreendida entre 1º de janeiro de 2011 a 31 de dezembro de 2015.

Visando proporcionar uniformidade nos dados e diminuir a exigência computacional da modelagem, os dados de treinamento foram padronizados conforme o seguinte procedimento:

$$k_t = \frac{x_t - X}{\sigma} \quad (3)$$

Onde:

$k_t$  – Valor padronizado da variável no instante  $t$

$X$  – Média aritmética

$X_t$  – Valor da série no instante  $t$

$\sigma$  – Desvio padrão da série

A rede neural foi ajustada com técnicas de treinamento supervisionado. Assim, a cada interação entre as variáveis, a saída da rede era comparada com a saída esperada. O procedimento é repetido até que a diferença entre o conjunto de dados de saída da rede e o conjunto de treinamento fosse mínima.

A diferença entre o conjunto de dados de saída da rede e o conjunto de treinamento é medido pelo erro absoluto médio ( $\varepsilon$ ), dado por:

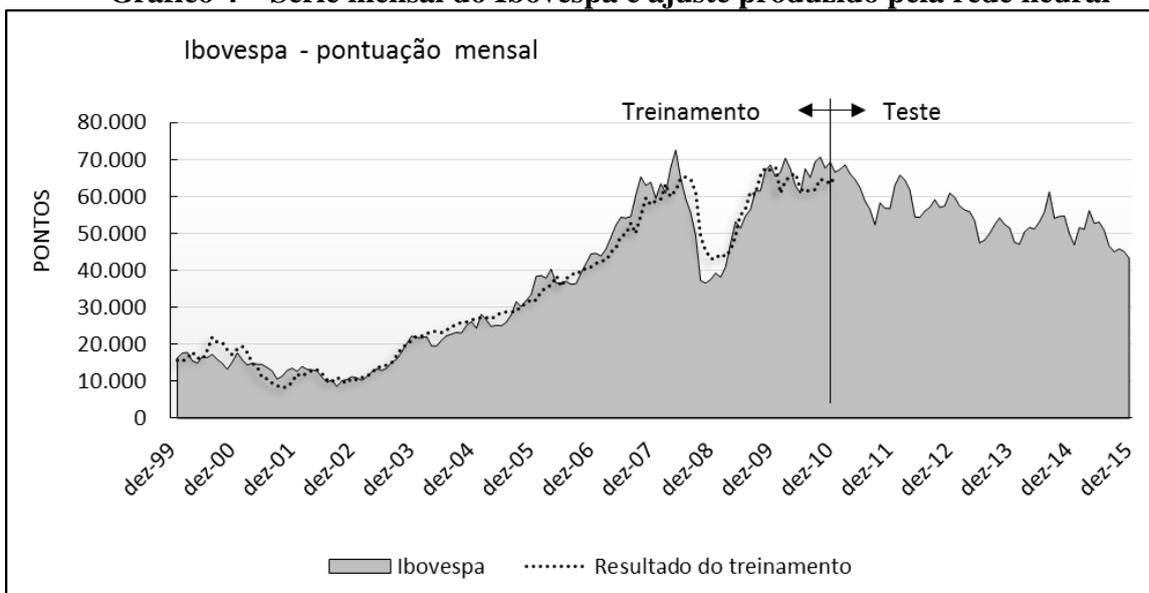
$$\varepsilon = \frac{|r_i - R_i|}{n} \quad (4)$$

Em que  $n$  é o número de observações,  $r_i$  é a saída da rede no conjunto de treinamento  $i$  e  $R_i$  é o parâmetro de treinamento da observação  $i$  (o resultado real observado da variável Ibovespa).

O processo de treinamento da rede foi realizado até que o erro absoluto médio fosse o menor possível. Nesse ponto, espera-se que os valores produzidos pela rede neural sejam o mais próximo do valor real observado pela série do Ibovespa.

Procede-se à demonstração do ajuste produzido pela rede neural após o treinamento.

**Gráfico 4 – Série mensal do Ibovespa e ajuste produzido pela rede neural**



Fonte: Dos Autores

O período da série compreendido entre 2000 a 2010 (gráfico 4) foi utilizado para treinamento da rede neural. A linha tracejada, que representa os valores produzidos pela modelagem, ajustou-se aos movimentos da série do Ibovespa embora não tenha atingido os valores com 100% de precisão.

A rede neural produziu um ajuste muito próximo da série do Ibovespa, sendo capaz de se modelar também ao período de recessão gerado pela crise de 2008. A precisão dos valores produzidos pela modelagem foi calculada como a diferença percentual entre os valores reais e os valores apresentados pela rede (equação 5):

$$p_i = \frac{r_i - V_i}{V_i} * 100 \quad (5)$$

Em que:

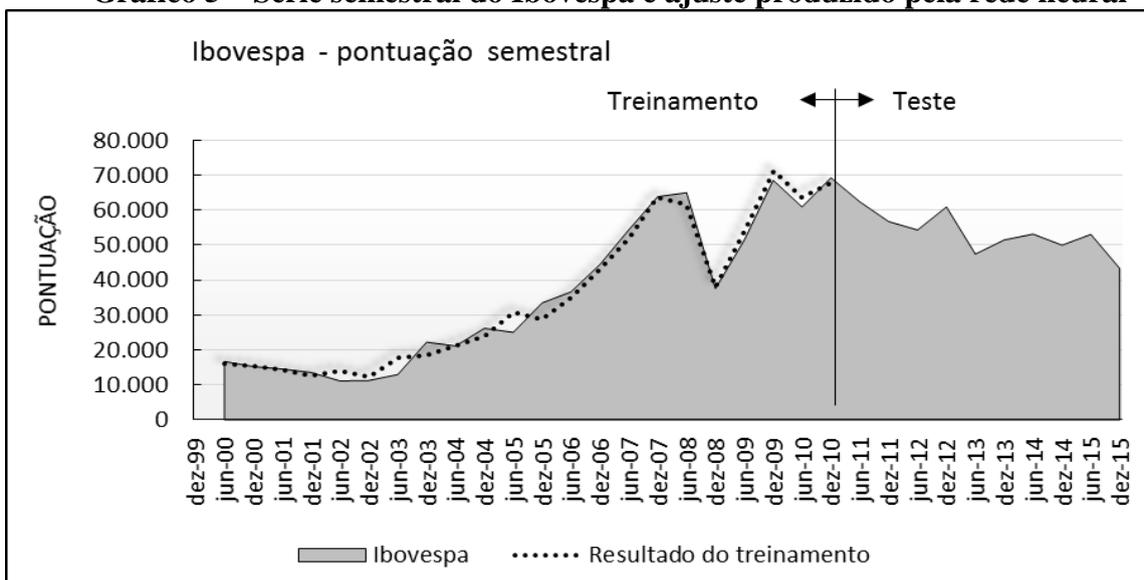
$p_i$  – precisão da modelagem para o valor  $i$

$r_i$  – valor produzido pela rede neural em  $i$

$V_i$  – valor real da série do Ibovespa

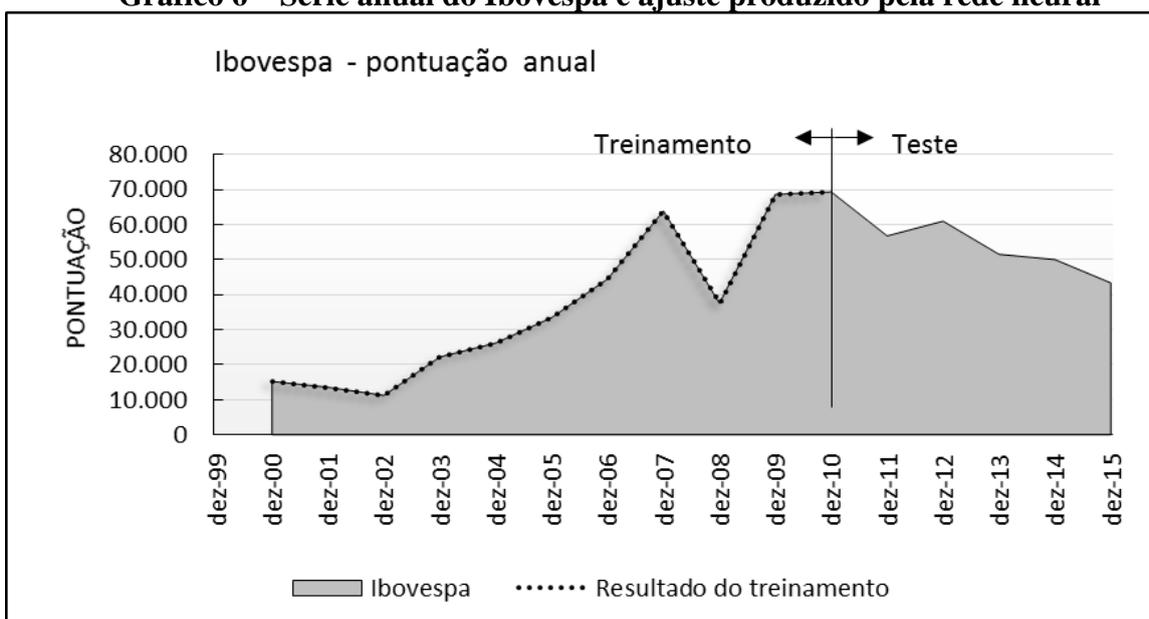
A distribuição do erro de precisão da rede neural na defasagem mensal apresentou uma média de 0,5% acima do valor real, com mediana de -1%.

**Gráfico 5 – Série semestral do Ibovespa e ajuste produzido pela rede neural**



Fonte: Dos Autores

**Gráfico 6 – Série anual do Ibovespa e ajuste produzido pela rede neural**



Fonte: Dos Autores

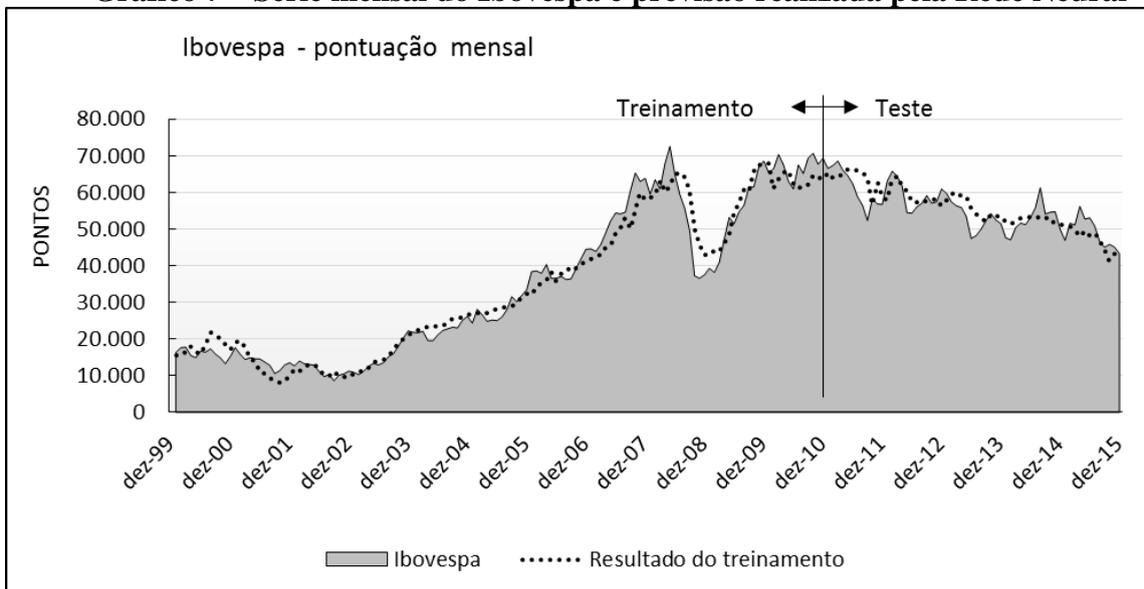
Na defasagem semestral, o ajuste produziu valores com erro de precisão médio de 1,6%, com mediana de -0,6%, já na defasagem anual, a precisão da rede foi exata.

Percebe-se que o ajuste da rede neural à série de dados produz menos erros quanto menor é o conjunto de dados. Essa constatação se dá, principalmente, devido ao baixo volume de dados utilizado na modelagem, o que exige menos esforço computacional.

Após a modelagem da rede atingir os parâmetros de aprendizagem desejado, partiu-se para a extrapolação do intervalo de aprendizagem. Os dados reais das variáveis independentes do período  $t$  foram inseridas na rede para a realização da previsão do valor da série em  $t+1$ .

Esse processo se repetiu até completar o intervalo da série temporal destinado ao teste da modelagem. O período de teste é o período da série compreendido entre janeiro de 2011 e dezembro de 2015. Segue-se os resultados obtidos.

**Gráfico 7 – Série mensal do Ibovespa e previsão realizada pela Rede Neural**

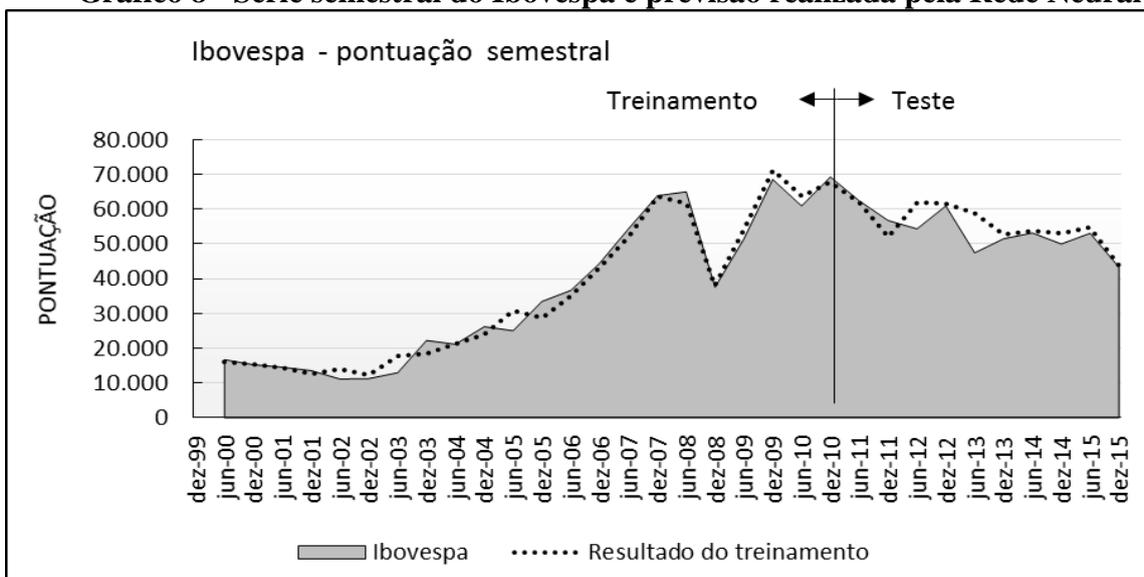


Fonte: Dos Autores

O intervalo da série mensal do Ibovespa utilizado para testar a capacidade de previsão da modelagem foi acompanhado pela rede neural, isto é, a rede neural foi capaz de prever a tendência da série mensal do Ibovespa. O erro de precisão tem média de 1,3% acima do valor real observado, com mediada de 0,3%.

Em se tratando da defasagem semestral, a capacidade de previsão da rede foi significativamente satisfatória.

**Gráfico 8 - Série semestral do Ibovespa e previsão realizada pela Rede Neural**

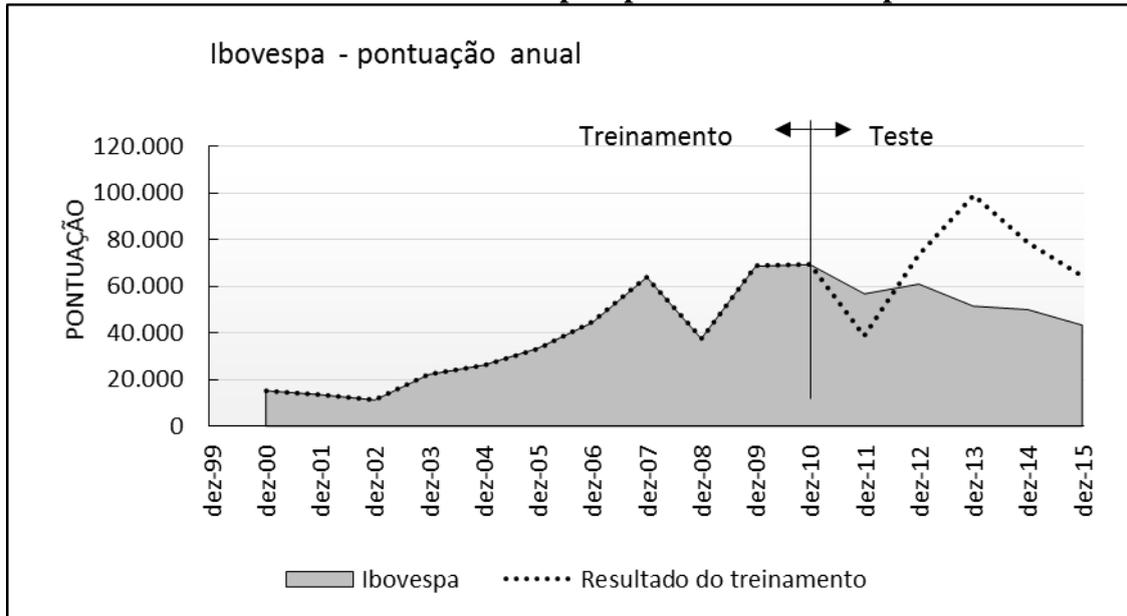


Fonte: Dos Autores

Na defasagem semestral, o erro de precisão da modelagem teve média de 4,4% e mediana de 1,7%. Nota-se também que a previsão é mais assertiva nos primeiros semestres da extrapolação, seguindo por um período de erros maiores e, então, novamente atingindo valores muito próximos ao real.

O último período de defasagem, o anual, apresentou resultados insatisfatórios na previsão.

**Gráfico 9 - Série anual do Ibovespa e previsão realizada pela Rede Neural**



Fonte: Dos Autores

A defasagem anual, que apresentou uma interpolação exata no período de treinamento, não foi capaz de prever o comportamento real da série do Ibovespa, resultando erros de precisão em média 37,3% acima do observado, com mediana de 48,4%.

## 5 CONCLUSÃO

As Redes Neurais Artificiais representam uma importante ferramenta para a gestão de empresarial e pública. Neste trabalho, a rede foi modelada com o uso de uma ferramenta de fácil utilização e amplamente acessível para o público em geral, indicando que a técnica não está condicionada à aquisição de *softwares* de alto custo.

Contudo, aplicações mais robustas da técnica, como nos casos em que se deseja estudar um número maior de variáveis ou que se disponha de um conjunto extenso de dados, exigiriam a utilização de um ferramental mais apropriado. Evidentemente, o investimento necessário para aquisição de tal ferramenta deve ser justificado pelo benefício que se pretende obter.

A metodologia aplicada neste trabalho poderia oferecer uma potencial melhoria na capacidade de previsão da rede se os valores reais do período de teste fossem reinseridos na modelagem,

a fim de fornecer mais intervalos de aprendizagem para a rede. Também aqui a exigência computacional tornou inviável a realização dessa abordagem na ferramenta utilizada. Testar a aplicação dessa melhoria na abordagem é uma sugestão dos autores para outros estudos que visem complementar o trabalho atual.

O objetivo específico de identificar a melhor defasagem de tempo na qual a rede neural produz resultados mais precisos na previsão concluiu que a rede foi capaz de prever a tendência de queda do Ibovespa durante o período de teste (janeiro de 2011 a dezembro de 2015) na defasagem mensal (gráfico 7), e na defasagem semestral (gráfico 8), não sendo capaz de prever a série do Ibovespa na defasagem anual (gráfico 9).

O baixo volume de dados disponíveis para aprendizagem pode ser uma explicação para que a rede não tenha conseguido prever o Ibovespa na defasagem anual. Isso ocorre porque a capacidade de se identificar padrões nos dados é menor, pois há menos históricos para a o treinamento.

A maior disponibilidade de dados, entretanto, representa maior exigência computacional para a realização do treinamento, o que pode dificultar a aprendizagem da rede. Tal fato foi percebido na previsão da série com defasagem mensal: embora a rede tenha acompanhado a tendência de queda do Ibovespa, a modelagem não foi capaz de prever com precisão as oscilações observadas pelo Ibovespa no período de teste.

Uma outra observação que se faz importante destacar é que a rede neural modelada se mostrou mais assertiva nos períodos mais próximos à extrapolação, o que indica que essa seria uma abordagem mais adequada para a previsão de séries temporais utilizando redes neurais.

Destaca-se também que a precisão da previsão é um critério eminentemente subjetivo, podendo variar de acordo com a necessidade de agentes econômicos e das circunstâncias em que se realiza a previsão.

Este estudo conclui que a técnica das Redes Neurais Artificiais pode ser empregada para a realização de previsão do comportamento do mercado brasileiro. Embora as aplicações das RNAs vão muito além da apresentada nesse trabalho, é possível afirmar que a previsão de séries temporais com RNAs represente um grande potencial para a gestão empresarial e pública, sendo válido os esforços no sentido de encontrar aplicações em outros campos e com outras abordagens metodológicas.

Por fim, sugere-se investigar em trabalhos posteriores se a inclusão de outras variáveis melhoraria a precisão da rede e quais variáveis poderiam ser adicionadas ao modelo.

## REFERÊNCIAS BIBLIOGRÁFICAS

ASSAF, N. A. **Mercado financeiro**. 8. ed. São Paulo: Atlas, 2008.

BISHOP, C. M. **Neural networks for pattern recognition**. New York: Oxford University Press, 2004.

BM&FBOVESPA. **Índice Brasil 100 (IBrX 100)**. Disponível em: <[http://www.bmfbovespa.com.br/pt\\_br/produtos/indices/indices-amplos/indice-brasil-100-ibrx-100-1.htm](http://www.bmfbovespa.com.br/pt_br/produtos/indices/indices-amplos/indice-brasil-100-ibrx-100-1.htm)>. Acesso em: 30 de mar. 2016.

GIL, A. C. **Como elaborar projetos de pesquisa**. São Paulo: atlas, 2002.

GRÔPPO, S. G. **Causalidade de variáveis macroeconômicas sobre o IBOVESPA**. Dissertação de Mestrado – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2004.

GUJARATI, D. N. **Econometria básica**. Rio de Janeiro: Elsevier, 2006.

GUOQIANG, Z. B.; EDDY, P. M. Y. H. **Forecasting with artificial neural networks: The state of the art**. Graduate School of Management, Kent State University, Kent, Ohio 44242-0001, USA Accepted 31 July 1997.

HAIR, Joseph F. et al. **Análise multivariada de dados**. 5. ed. Porto Alegre: Bookman, 2005.

HAYKIN, S. **Redes Neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

HODNETT, K.; HSIEH, H. H.; RENSBURG, V. P. **Nonlinearities In Stock Return Prediction: Evidence From South Africa**. The Journal of Applied Business Research – November/December 2012 Volume 28, Number 6.

JUNIOR, P. T.; HIGUCHI, H. R. **Variáveis macroeconômicas e o IBOVESPA: Um estudo da relação de causalidade**. Read – Edição 60, Vol. 14, N° 2 mai-ago, 2008.

KENNEDY, P. **Economia em contexto**. São Paulo: Saraiva, 2004.

KRUGMAN, P. R.; WELLS, R. **Introdução à economia**. Rio de Janeiro: Elsevier, 2012.

KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações, um texto básico**. São Paulo: Livraria da física, 2002.

LEVINE, D. M. et al. **Estatística: Teoria e aplicações**. 5.ed. Rio de Janeiro: LTC, 2008.

MANKIW, N. G. **Princípios de macroeconomia**. São Paulo: Thomson, 2005.

PINHEIRO, L. J. **Mercado de capitais: Novo texto reestruturado e atualizado com questões para consolidação e testes de verificação**. 6 ed. São Paulo: Atlas, 2012.

SAMUELSON, PAUL ANTHONY; NORDHAUS, WILLIAM D. **Economia**. 17. ed. Rio de Janeiro: McGraw-Hill, 2004.

TERRA, A. A. L.; PASSADOR, L. J. **Redes neurais artificiais na previsão da inflação: aplicação como ferramenta de apoio à análise de decisões financeiras em organizações de pequeno porte**. RAM, REV. ADM. MACKENZIE, V. 13, N. 1 • SÃO PAULO, SP • JAN/FEV. 2012 • ISSN 1518-6776 (impresso) • ISSN 1678-6971 (on-line). Submissão: 29 set. 2009. Aceitação: 26 ago. 2010. Sistema de avaliação: às cegas dupla (double blind review). UNIVERSIDADE PRESBITERIANA MACKENZIE. Walter Bataglia (Ed.), p. 68-86.

VASCONCELLOS, Marco Antonio Sandoval de; ENRIQUEZ GARCIA, Manuel. **Fundamentos de economia**. 2. ed. São Paulo: Saraiva, 2004.

ZHANG, GUOQIANG; PATUWO, B. EDDY; HU, MICHAEL Y. **Forecasting with artificial neural networks: The state of the art**. *International Journal of Forecasting*, Kent, Ohio, vol. 14, ps. 35 – 62, 1998.