

TOMADA DE DECISÃO NO MERCADO FINANCEIRO: uma comparação entre redes neurais artificiais e sistemas neuro-fuzzy para previsão do índice Bovespa

JOSÉ WILLER DO PRADO

UNIVERSIDADE FEDERAL DE LAVRAS (UFLA)

CAIO PEIXOTO CHAIN

UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO (UFRRJ)

FRANCISVAL DE MELO CARVALHO

UNIVERSIDADE FEDERAL DE LAVRAS (UFLA)

MÍRIAN ROSA

UNIVERSIDADE FEDERAL DE LAVRAS (UFLA)

TOMADA DE DECISÃO NO MERCADO FINANCEIRO: uma comparação entre redes neurais artificiais e sistemas neuro-fuzzy para previsão do índice Bovespa

1 INTRODUÇÃO

Atualmente uma das situações de risco mais comuns em ambientes econômicos é a negociação de ações nos mercados financeiros, isso se deve ao fato desses mercados possuírem estruturas dinâmicas complexas e não-lineares. Neste cenário, uma das dificuldades presentes é elaborar um conjunto adequado de regras para modelos de previsão de séries temporais que possibilitem melhores decisões de investimento.

Morettin e Toloi (2006) argumentam que as principais dificuldades para modelar a previsão de séries temporais financeiras residem nas próprias particularidades das séries, tais como: tendências, heteroscedasticidade condicional, pontos influentes (atípicos), sazonalidade e a não-linearidade, isto é, particularidades que demonstram, volatilidade e não estacionariedade. Coelho, Santos e Costa Jr. (2008) observam que o uso de modelos lineares na tentativa de explicação e previsão do comportamento dinâmico e não linear de séries temporais financeiras tem gerado críticas entre os estudiosos do campo.

As pesquisas desenvolvidas neste campo fazem contraponto a hipótese de *Random Walk* (BACHELIER, 1964) a qual, afirma que os preços do mercado de ações evoluem de acordo com um passeio aleatório e, portanto, não podem ser previstos. Essa afirmação é consistente com a hipótese de Mercado Eficiente (FAMA, 1970, 1991), na qual, todos os mercados seriam eficientes em encontrar oportunidades de lucro tão rapidamente, que essas oportunidades deixariam de existir automaticamente.

Neste cenário, um mercado é considerado eficiente apenas se seus preços são capazes de refletir todas as informações disponíveis (FAMA, 1970, 1991). Entretanto, a hipótese de Mercado Eficiente, assim como a hipótese do *Random Walk* (BACHELIER, 1964) são na verdade sob a perspectiva de Haugen (1997), um modelo sobre como o mercado se comporta, contudo, segundo o autor esse modelo como qualquer outro modelo se aplica a determinados casos e não a todos. De lado oposto à hipótese do *Random Walk*, Matsura (2007) salienta que a teoria de Charles Dow (exponente no emprego da análise técnica) indica que eventos ocorridos no passado podem vir a determinar eventos futuros. A tendência gráfica nos preços das ações está relacionada com a direção que eles adotarão no futuro, isto é, antes de um movimento expressivo de baixa ou alta nas cotações de uma determinada ação, existem características que demonstram previamente a movimentação que deverá ocorrer.

Para Brum (2006) os estudos baseados no comportamento do mercado e suas tendências apoiam-se em três proposições fundamentais: a primeira é que tudo pode ser resumido no preço dos ativos financeiros; a segunda é que os preços se movem por meio de tendências e terceira a história se repete e a compreensão de tendências futuras pode estar no estudo de acontecimentos passados.

Partindo-se do pressuposto que os fatores que influenciaram os padrões de comportamento das séries temporais no passado continuarão a influenciar o comportamento futuro (DELURGIO, 1998; MORETTIN; TOLOI, 2006; ARAÚJO; MONTINI, 2018), torna-se necessária à utilização de métodos que capturem características do comportamento passado a fim de prever o próximo acontecimento com certo grau de confiança (BÓDIS, 2004).

Diante das possibilidades de análise das séries temporais, o presente trabalho tem por objetivo realizar a previsão das séries temporais do Índice Bovespa (Ibovespa) utilizando os métodos de Redes Neurais Artificiais – RNA e *Adaptive Neuro Fuzzy Inference Systems* – ANFIS. Tendo em vista buscar alternativas a modelos lineares que podem ignorar certos aspectos das estruturas dinâmicas existentes no mercado de ações. Destaca-se que no Brasil a aplicação destes métodos ainda é incipiente no estudo de séries temporais financeiras e por isto carecem de mais aprofundamento.

2 PREVISÃO DE SÉRIES TEMPORAIS FINANCEIRAS

2.1 Algumas Evidências Empíricas

O campo de previsão de séries temporais financeiras tem produzidos importantes trabalhos que buscam questionar as hipóteses de eficiência de mercado e o *Random Walk*. Entre essas pesquisas podem-se citar os trabalhos de Fama e French (1988), Lo e Mackinlay (1988), Poterba e Summers (1988) e Maciel, Ballini e Gomide (2017). Nesses trabalhos os autores evidenciam que o retorno das ações pode ser predito em algum nível, isso em decorrência do fato que em muitas séries de tempo financeiras existem evidências de heteroscedasticidade condicional, o que demonstra que os retornos não são completamente independentes e identicamente distribuídos como pressupõe o modelo *Random Walk*.

Segundo Leite et al. (2011, p. 2798) é observando os resultados anteriores de um sistema que se pode estimar o seu comportamento futuro, neste sentido, a “previsão de séries temporais está baseada na ideia de que as séries têm potencial para transportarem as informações necessárias para prever os valores futuros. Análise de dados produzidos por fenômenos reais podem dar bons *insights* sobre o próprio fenômeno e conhecimento sobre as regras subjacentes aos dados”.

Dentro dessa perspectiva ainda pode-se citar alguns trabalhos recentes como Talarposhti et al. (2016) que propôs um método híbrido de *exponential fuzzy time series* para previsão do mercado de ações e o trabalho de Hsu et al. (2016) que realiza uma extensa simulação de previsões, em que, os resultados sugerem a previsibilidade do mercado financeiro e também encontram evidências que confirmam que os métodos avançados de previsão podem ser usados para prever as mudanças de preços em alguns mercados financeiros, se contrapondo a visão da hipótese de *Random Walk*.

2.2 Redes Neurais Artificiais

Entre as possibilidades para ser modelar séries temporais financeiras pode-se citar as redes neurais artificiais. Neste contexto, Haykin (2001) apresenta a unidade fundamental de processamento de uma rede neural artificial, o neurônio artificial. Os neurônios artificiais podem ser classificados em vários modelos. Entretanto, estes se diferenciam basicamente pelo tipo de entrada (binária ou contínua), tipo de saída e função de ativação que será utilizada. A representação de um neurônio base para o projeto de redes neurais é apresentado na Figura 1.

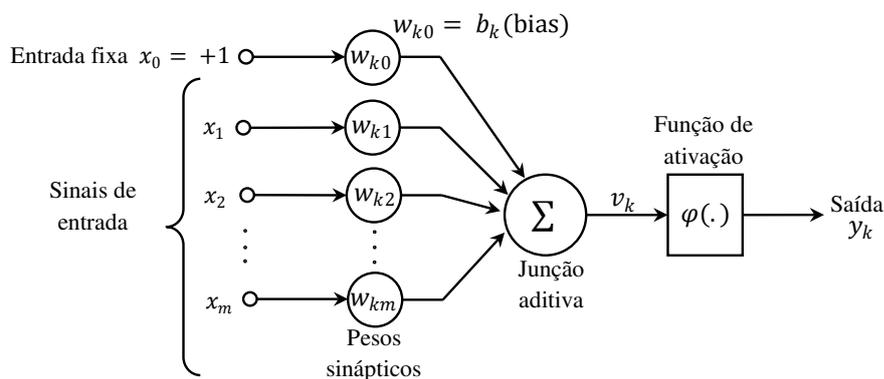


Figura 1: Modelo não linear de um neurônio.
Fonte: Adaptado de Haykin (2001, p. 38).

Como observado por Haykin (2001), na Figura 1, pode-se visualizar três elementos básicos do modelo neural:

1. Um conjunto de sinapses, cada uma caracterizada por um peso próprio. Sendo cada sinal x_j na entrada da sinapse j ligada ao neurônio k e multiplicado pelo peso sináptico w_{kj} , onde

o primeiro subscripto indica o neurônio (k) em questão e o segundo se refere ao terminal de entrada da sinapse (j), à qual o peso se refere.

2. Uma função soma que realiza o somatório de todos os sinais de entrada, ponderados pelos seus respectivos pesos.

3. Uma função de ativação (φ é a função de ativação do neurônio k), para decidir acerca da transmissão do sinal (impulso) de um neurônio. Esta função também restringe a amplitude de sinal de saída a um valor finito. Normalmente, este é escrito em intervalo unitário fechado $[0, 1]$ ou alternativamente $[-1, 1]$ e y_k é o sinal de saída do neurônio.

Para a construção de um modelo de redes neurais artificiais, devem ser consideradas três características fundamentais, a saber: a arquitetura, que dá forma à rede (organização da rede em camadas); o algoritmo de aprendizado, mais eficaz para o modelo proposto (método para determinação dos pesos); e a função de ativação (que defini a saída ou não do impulso) (HAYKIN, 2001).

2.3 Adaptive Neuro-Fuzzy Inference System (ANFIS)

Em particular, sistemas Fuzzy são empregados devido à compreensão das regras linguísticas geradas por esses métodos. Sistemas de inferência Fuzzy (FIS, do inglês *Fuzzy Inference Systems*) são definidos como aproximadores universais que podem ser utilizados para modelar as relações não lineares entre entradas e saídas. A operação de um FIS normalmente depende da realização de quatro tarefas principais: codificação (fuzzificação), inferência, composição e decodificação (defuzzificação) (TAKAGI; SUGENO, 1985).

Há também os modelos neuro-fuzzy, que reúnem pontos fortes de redes neurais, tais como aprendizagem e capacidade de generalização, e de sistemas fuzzy, como raciocínio qualitativo e capacidade de modelagem da incerteza. O sistema de inferência adaptativo neuro-fuzzy (ANFIS, do inglês *Adaptive Neuro-Fuzzy Inference System*), proposto por Jang (1993), é um dos mais utilizados métodos neuro-fuzzy. O ANFIS é uma rede neural que modela o tipo de sistemas de inferência difusos Takagi-Sugeno-Kang (TSK) e envolve cinco camadas, cada camada sendo funcionalmente equivalente a um FIS (JANG, 1993).

Jang (1993) afirma que modelar um sistema aplicando ferramentas matemáticas convencionais (por exemplo, equações diferenciais) não é um problema trivial quando se trata incertezas e indefinições. Ao contrário, o sistema de inferência fuzzy utiliza regras *if - then* fuzzy que podem modelar aspectos qualitativos do conhecimento humano e processos de raciocínio sem empregar uma análise quantitativa precisa.

Como pode ser observado na Figura 2, geralmente, a base de regras e banco de dados são descritas em conjunto com base no conhecimento especialista, desta forma o ANFIS é fundamental para construir um conjunto de regras *if - then* fuzzy com funções de pertinência apropriadas para gerar um conjunto de pares de entrada e saída estipulados.

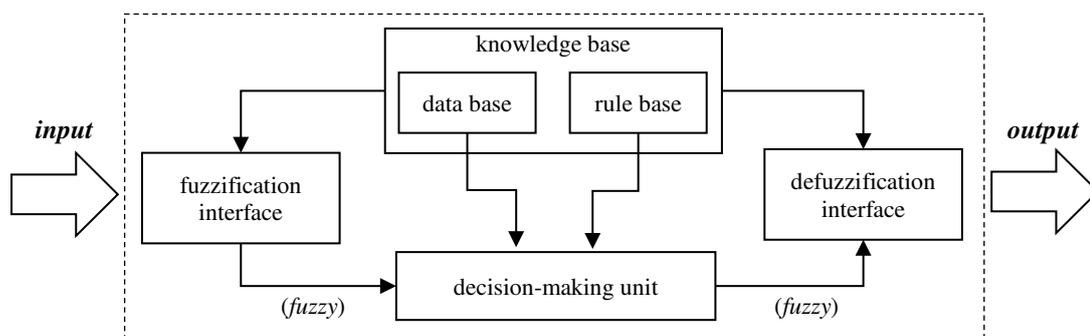


Figura 2: Sistema de inferência fuzzy.
Fonte: Jang (1993).

Basicamente, um sistema de inferência fuzzy é composto por cinco blocos funcionais:

- Uma base de regras que incluem uma série de regras nebulosas *if - then*;
- Um banco de dados que descreve as funções de pertinência dos conjuntos fuzzy utilizados nas regras fuzzy;
- Uma unidade de tomada de decisão, que realiza as operações de inferência sobre as regras;
- Uma interface Fuzzificação que muda as entradas nítidas em graus de jogo com valores linguísticos;
- Uma interface defuzzificação que altera os resultados nebulosos da inferência em uma saída nítida.

A estrutura da rede neuro-fuzzy é constituída por 5 camadas, como ilustra a Figura 3. Essa estrutura busca a obtenção dos parâmetros necessários e seus ajustes de forma a diminuir o erro do modelo.

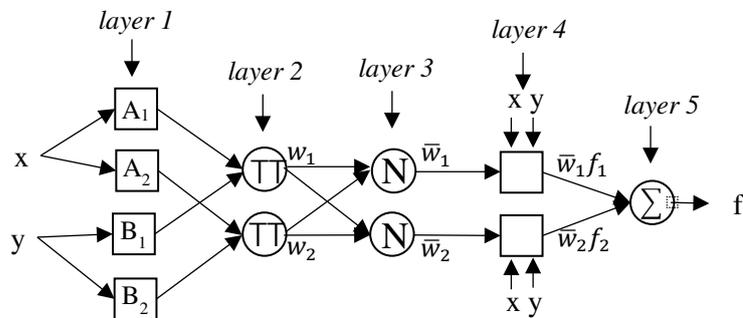


Figura 3: Estrutura do modelo ANFIS.
Fonte: Jang (1993).

Na primeira camada, cada unidade (A1, A2, B1 e B2) armazena três parâmetros para definir uma função de pertinência na forma de um sino, por exemplo, que representa um termo linguístico como sendo (JANG, 1993):

$$O_i^1 = \mu_{A_i}(x) \quad (1)$$

em que:

x : é a entrada do nó i ;

A_i : é a classificação linguística associada com a função do nó;

O_i^1 : é a função de pertinência de A_i ;

$\mu_{A_i}(x)$ é a função em forma de sino com máximo em 1 e mínimo em 0.

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (2)$$

em que a_i, b_i, c_i são um conjunto de parâmetros.

Cada unidade é conectada a exatamente uma unidade de entrada e computa o grau de pertinência do valor de entrada obtida. O limite inferior da função de pertinência na forma de um sino é representado por **a**, **b** é o limite médio desta mesma função e **c** é o limite superior.

Na segunda camada, cada nó computa o peso w_i associado as funções de ativação, ou seja:

$$\omega_i = \mu_{A_i}(x) \cdot \mu_{B_i}(\gamma), i = 1,2 \quad (3)$$

a saída de cada nó nesta camada representa o nível de ativação (*firing strength*) de uma regra (na verdade, outros operadores "*T-norm*" que executam generalizada "*AND*" pode ser usado como função do nó nesta camada).

Cada nó na terceira camada calcula a taxa dos *i*-ésimos nós e o grau de desempenho relativo das *i*-ésimas regras para o somatório dos níveis de ativação dos nós, isto é:

$$\bar{\omega}_i = \frac{\omega_i}{\omega_1 + \omega_2}, i = 1,2 \quad (4)$$

Por conveniência, a saída desta camada pode ser chamada nível de ativação normalizado. Na quarta camada é computado o produto da saída do nó *i* da terceira camada pela função $f_i, i = 1,2$, ou seja,

$$O_i^4 = \bar{\omega}_i \cdot f_i = \bar{\omega}_i (p_i x + q_i y + r_i) \quad (5)$$

em que, p_i, q_i, r_i é o conjunto de parâmetros associado ao nó *i*.

Por fim, a quinta camada é composta por um único nó no qual computa a saída da rede sendo o somatório de todos os sinais de entrada, isto é,

$$O_i^5 = \sum \bar{\omega}_i \cdot f_i = \frac{\sum \omega_i \cdot f_i}{\sum \omega_i} \quad (6)$$

No próximo tópico são apresentados os aspectos metodológicos empregados na pesquisa.

3 METODOLOGIA

A metodologia aqui apresentada busca dar suporte a pesquisa realizada, quanto aos fins tem caráter descritiva (VERGARA, 2008), quanto à forma de abordagem é qualificada como quantitativa (MARTINS; THEÓPHILO, 2009). Para as técnicas de análise de dados, tendo em vista as possíveis características das séries temporais financeiras, optou-se por utilizar dois métodos não lineares para a análise, ou seja, uma rede neural artificial (RNA) com arquitetura MLP (*multilayer perceptron*) com algoritmo Levenberg-Marquardt e também o método *Adaptive Neuro-Fuzzy Inference System* (ANFIS).

Buscou-se neste trabalho atingir um treinamento efetivo tanto para a rede neural artificial como para o Sistema de Lógica Fuzzy (SLF). Em ambos os casos se utilizou um algoritmo de aprendizado padrão de retro-propagação do erro como recomendado por Jang (1993) e por Haykin (2001). Para o ambiente de processamento utilizou-se do software Matlab, e de pacotes como o Fuzzy Logic Toolbox (MATHWORKS, 2014).

3.1 Amostragem e Fonte de Dados

Para coleta das séries temporais financeiras foi utilizado o banco de dados do Economática. As séries temporais escolhidas para análise foram às séries do Índice Bovespa (Ibovespa). O Ibovespa é o resultado de uma carteira teórica de ativos que é utilizado como indicador do desempenho médio (índice de retorno total) dos ativos de maior representatividade no mercado de ações brasileiro listados na B3 (B3 S.A. – Brasil, Bolsa, Balcão).

As séries temporais financeiras escolhidas para sinalizar o comportamento das ações no mercado tiveram três focos, avaliar a valorização acionária, avaliar a liquidez e definir o alvo da predição. **Para avaliar a valorização acionária:** Retorno acionário; **para avaliar a**

liquidez: Quantidade de negociações (QNegs), Quantidade de títulos (QTits), Volume financeiro negociado (Vol), Valor mínimo diário da cotação das ações (mínimo), Valor máximo diário da cotação das ações (máximo), Valor de abertura das ações (abertura), Valor médio diário da cotação das ações, Diferença entre valor mínimo e valor máximo diário da cotação das ações utilizadas (Spread); e **para a variável alvo da predição (saída):** Valor diário das ações no Fechamento em $t+1$. Em que, o tempo t , $t-1$, $t-2$ e $t-3$ da série de Fechamento foram utilizados como valores linguísticos de entrada para os modelos de RNA e ANFIS.

Camargos, Romero e Barbosa (2008) consideram que essas são as séries temporais mais comumente utilizadas. Em relação a série do *Spread*, Demsetz (1968) considera a diferença entre os preços ofertados para compra e os preços pedidos para venda (*bid-ask spread*), um indicador que pode ser utilizado como liquidez no mercado.

O período de análise foi de 02 de janeiro de 1995 até 31 de dezembro de 2015. Para os dados de treinamento utilizou-se dados diários do ano de 1995 até o ano de 2014 (5218 dias), já para os dados de verificação utilizou-se dados diários do ano de 2015 - exceto finais de semana e feriados.

Todas as séries monetárias, antes de serem utilizadas no modelo, foram deflacionadas em moeda original e ajustadas por proventos e dividendos, evitando-se assim, que tais eventos pudessem influenciar nos resultados. As séries ainda foram normalizadas para evitar possíveis distorções nos parâmetros da RNA e nas funções de pertinência do ANFIS.

Para o cálculo da variação percentual do Retorno acionário no dia t foi utilizada as cotações de fechamento diárias conforme a Equação 7.

$$Var_d = \frac{(V_d - V_{d-1})}{V_{d-1}}, \quad (7)$$

Em que, Var_d é a variação numérica do Ibovespa no dia d , e $V_d - V_{d-1}$ são os valores do Ibovespa no dia d e no dia $d-1$, respectivamente.

3.2 Janela Temporal de Dados

Para Zhang, Patuwo e Hu (1998) normalmente os problemas de previsão de séries temporais financeiras utilizam entradas referentes aos valores passados da série estudada, já a saída corresponde ao valor futuro que se deseja obter com o modelo. Observa-se que o mapeamento da função que se pretende utilizar no estudo pode ser descrito pela Equação 8.

$$\gamma_{t+1} = f(\gamma_t, \gamma_{t-1}, \gamma_{t-2}, \dots, \gamma_{t-n}) \quad (8)$$

Em que y , representa uma observação no instante de tempo t . Neste sentido, os modelos (RNA e ANFIS) equivalem-se a um modelo auto-regressivo não linear para problemas de previsão de séries temporais. Um aspecto essencial dos modelos de previsão aqui empregados é a facilidade de se incorporar variáveis explicativas (desfasada no tempo) juntamente com as observações passadas da série a ser prevista, o que segundo Zhang, Patuwo e Hu (1998) corresponde-se a um modelo de função de transferência geral.

Segundo Castro (2003) para gerar os atrasos (*lags*) de tempo da série utilizada na camada de entrada dos modelos, pode-se criar uma janela deslizante com tamanho n na série original e verificar o número de atrasos (*lags*) significativos obtidos por meio dos valores dos coeficientes de autocorrelação estimados. Brockwell e Davis (1996) considera que os valores significativos de autocorrelação demonstram dependência linear entre os dados da série em diferentes atrasos (*lags*).

3.3 Métricas de Desempenho para Previsões

As métricas de desempenho podem ser definidas com base no erro da previsão do modelo, isto é, a diferença entre o valor original da série temporal (valor desejado/target/alvo) e o valor previsto (saída do modelo, estimado, output). Essa relação pode ser representada pela equação 2.

$$e = (target_t - output_t) \quad (9)$$

Em que $target_t$ é a saída desejada para o modelo preditor no tempo t , e $output_t$ é a saída estimada pelo modelo no tempo t . Na sequência são apresentadas as métricas de desempenho utilizadas. A Métrica mais comum para analisar modelos de previsão é a Raiz do erro médio quadrado ou RMSE - *Root Mean Square Error*, conforme pode ser observado na Equação 10.

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (target_t - output_t)^2} \quad (10)$$

Em que N é a quantidade de observações da série temporal, neste sentido quanto melhor a solução do preditor menor será o resultado do RMSE. Como MSE incorpora tanto a variância do estimador e a sua polarização, ele possui as mesmas unidades de medição como o quadrado da quantidade a ser estimado. Neste sentido, a raiz quadrada do MSE produz o RMSE, que tem as mesmas unidades que a quantidade estimada; para um estimador imparcial, o RMSE é a raiz quadrada da variância, conhecido como o desvio padrão.

Outra métrica popular é o Erro Médio Absoluto Percentual, ou MAPE - *Mean Absolute Percentage Error*, pode ser definido na Equação 11.

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{target_t - output_t}{target_t} \right| \cdot 100 \quad (11)$$

O MAPE possibilita avaliar a acurácia do preditor por meio da média das distâncias absolutas entre os valores originais e os previstos pelo modelo.

Outra métrica importante é o Coeficiente de determinação que permite avaliar a qualidade do ajuste do modelo indicando a capacidade do modelo de explicar os dados trabalhados. Este coeficiente é a razão entre a soma de quadrados da regressão e a soma de quadrados total, seu cálculo pode ser expresso pela Equação 12.

$$R^2 = \frac{SQR}{STQ} = \frac{\sum_{t=1}^N (\hat{Y}_i - \bar{Y})^2}{\sum_{t=1}^N (Y_i - \bar{Y})^2} \quad (12)$$

Segundo Charnet et al. (2008, p. 88) “o coeficiente de determinação, R^2 , é interpretado como a proporção da variabilidade dos Y 's observados, explicada pelo modelo considerado. O valor de R^2 pertence ao intervalo $[0;1]$ e, [...], quanto mais próximo de 1, melhor o ajuste do modelo considerado”.

4 RESULTADOS

4.1 Estatística Descritiva

Tendo em consideração o risco envolvido na negociação de ações nos mercados financeiros e as possíveis estruturas dinâmicas, complexas e não-lineares que podem possuir as séries em estudo no presente trabalho, todo um rigor metodológico foi tomado na elaboração das regras dos modelos utilizados. A parti inicial deste processo é a melhor compressão das séries em análise. Neste sentido, apresenta-se na Figura 4, a série referente ao valor de fechamento do Ibovespa, tendo em vista que, essa série será a série alvo a qual se buscará realizar a previsão de seu valor para o dia seguinte.

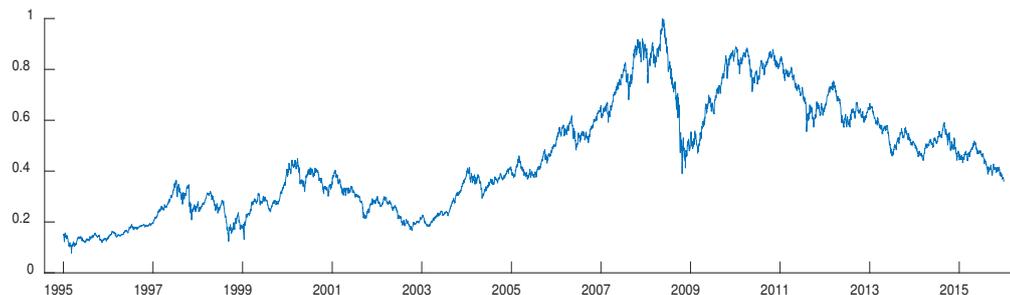


Figura 4: Série Temporal com valores de fechamento para o Ibovespa (02/01/1995 até 31/12/2015).

Fonte: Elaborado pelos autores.

É preciso observar que um índice como o Ibovespa é acompanhado por várias séries temporais que demonstram características da sua movimentação diária e por isso, são passíveis de análise na tentativa de compreender melhor o seu comportamento, tendo como meta a modelagem de seu desempenho e a previsão futura de alguma de suas séries.

Neste contexto, é preciso definir quais das 10 séries temporais selecionadas estão mais correlacionadas, isso se deve ao fato que se existirem séries que apresentam alta correlação as mesma poderão ser excluídas da amostra por carregarem as mesmas características, tendo em consideração que buscamos aqui gerar modelos que tenham uma boa acurácia e sejam também parcimoniosos (possuam um menor número de parâmetros) (MORETTIN; TOLOI, 2006). A Tabela 1, apresenta a correlação entre todas as séries em estudo.

Tabela 1: Correlação das variáveis propostas.

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)
Q Negs (1)	1									
Q Tits (2)	-0,4663	1								
Volume (3)	0,7309	-0,2685	1							
Abertura (4)	0,4188	-0,1292	0,8104	1						
Mínimo (5)	0,4189	-0,1294	0,8086	0,9996	1					
Máximo (6)	0,4186	-0,1277	0,8131	0,9997	0,9996	1				
Médio (7)	0,4185	-0,1280	0,8110	0,9996	0,9999	0,9999	1			
Spread (8)	0,1938	-0,0090	0,5250	0,4853	0,4693	0,4949	0,4819	1		
Retorno (9)	-0,0123	0,0373	0,0048	-0,0260	-0,0100	-0,0112	-0,0067	-0,0440	1	
Fechamento (10)	0,4184	-0,1279	0,8111	0,9992	0,9997	0,9997	0,9998	0,4816	0,0035	1

Coefficientes de Correlação, usando as observações 1994-01-03 - 2016-04-22.

5% valor crítico (bicaudal) = 0,0257 para n = 5820.

Fonte: Elaborado pelos autores.

E possível verificar por meio desse processo que as séries de Mínimo, Máximo e Médio são altamente correlacionadas com a série de Fechamento, que é a série alvo do presente estudo.

Sendo assim, as mesmas por não trazerem informações adicionais foram descartadas das análises futuras.

Outro aspecto importante dentro do processo temporal e identificar quais são os atrasos (*lags*) de tempo necessários para prever o valor de fechamento do Ibovespa no tempo $t+1$, para isso realizou-se uma correlação do valor de fechamento em $t+1$ com o valor das outras séries restantes (e do próprio valor do fechamento) oscilando entre t até $t-10$, na qual se buscou definir quais seriam os melhores atrasos de tempo para cada série temporal para realizar os testes para os modelos. O resultado desse processo pode ser melhor visualizado na Tabela 2.

Tabela 2: Correlação entre a variável de Fechamento (no tempo $t+1$) e as variáveis propostas (no tempo t até $t-10$).

Atrasos (<i>lags</i>)	Q Negs	Q Títs	Volume	Spread	Retorno	Fechamento
t-10	0,4152	-0,1263	0,8045	0,4752	0,0030	0,9925
t-9	0,4156	-0,1266	0,8052	0,4755	0,0024	0,9931
t-8	0,4158	-0,1275	0,8055	0,4754	0,0017	0,9937
t-7	0,4161	-0,1281	0,8063	0,4761	0,0029	0,9943
t-6	0,4166	-0,1280	0,8074	0,4775	0,0024	0,9949
t-5	0,4169	-0,1278	0,8074	0,4787	0,0029	0,9956
t-4	0,4172	-0,1277	0,8083	0,4798	0,0035	0,9963
t-3	0,4175	-0,1273	0,8088	0,4801	0,0047	0,9969
t-2	0,4177	-0,1272	0,8092	0,4811	0,0054	0,9976
t-1	0,4179	-0,1272	0,8099	0,4814	0,0060	0,9984
t	0,4180	-0,1271	0,8104	0,4821	0,0051	0,9991

Coefficientes de Correlação, usando as observações 1994-01-03 - 2016-04-22

5% valor crítico (bicaudal) = 0,0257 para $n = 5820$

Fonte: Elaborado pelos autores.

Utilizando do método de correlação os valores encontrados em negrito na Tabela 2, para cada série de tempo individualmente, indicam os possíveis atrasos (*lags*) de tempo mais correlacionados ao índice Ibovespa em $t+1$ que podem ser utilizados no modelo de previsão. Na Figura 5, são apresentadas (de forma gráfica), todas as séries que serão utilizadas nos modelos.

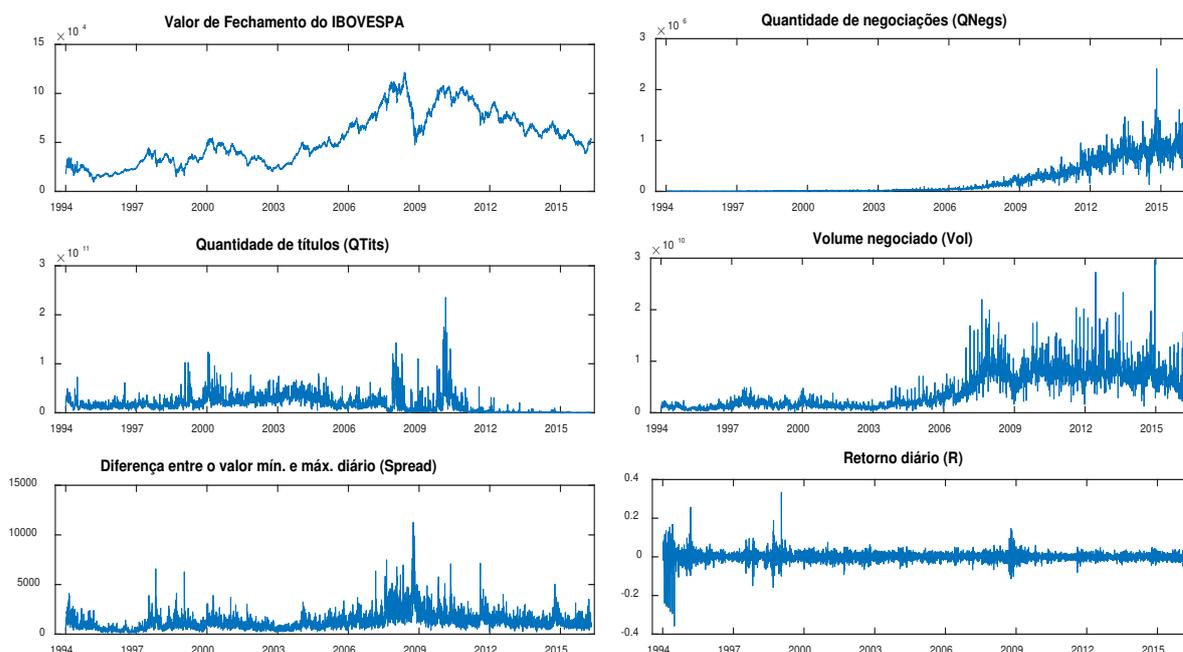


Figura 5: Séries temporais utilizadas para construção dos modelos.

Fonte: Elaborado pelos autores.

Após vários testes de agrupamentos das séries selecionadas para os modelos RNA e ANFIS, os indicadores que apresentaram melhor desempenho na previsão do valor de $Fechamento(t_{+1})$ foram: $Spread(t)$, $Retorno(t_{-1})$, $Fechamento(t_{-3})$, $Fechamento(t_{-2})$, $Fechamento(t_{-1})$ e $Fechamento(t)$. Observa-se que, as séries Q Negs e Volume contribuíram para o aumento do erro, tanto no modelo ANFIS quanto no modelo de RNA, e por isso foram excluídas do processo.

4.2 O Modelo de Redes Neurais Artificiais

Para o modelo de Rede Neural Artificiais a melhor arquitetura gerada (Figura 6), possui 6 unidades na camada de entrada e, 10 unidades tanto na primeira camada oculta como na segunda camada oculta e 1 valor para a camada de saída, neste caso observa-se que as entradas são utilizadas como atrasos (*lags*) em um processo temporal. Para a função de ativação das camadas ocultas foi utilizado a função tangente hiperbólica (*tansig*) e para a camada de saída foi utilizado uma função de ativação linear (*purelin*).

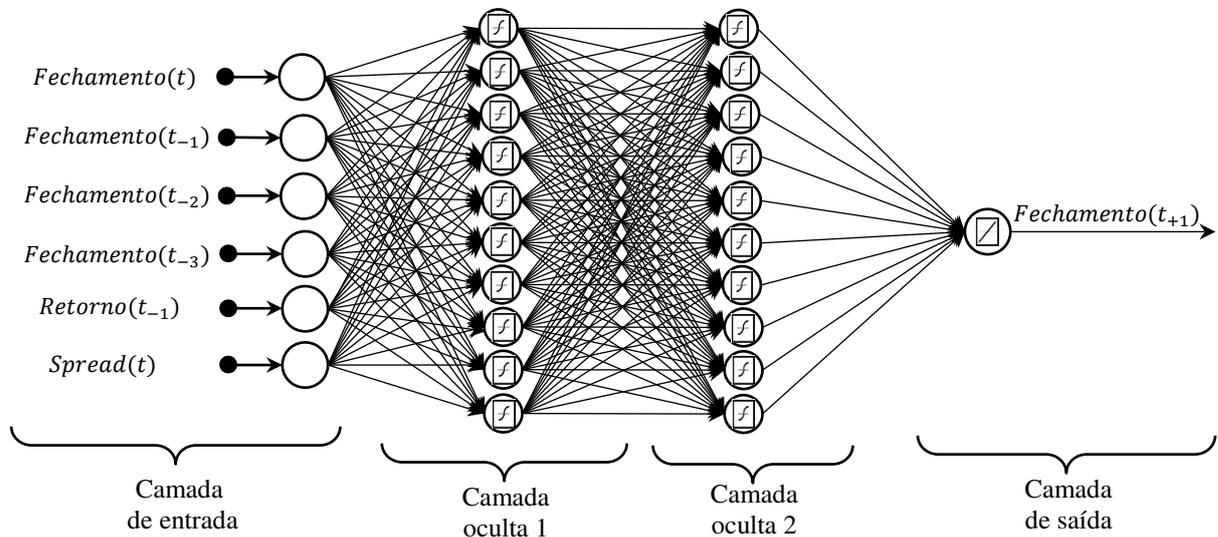


Fig. 6. Arquitetura do modelo Redes Neurais.
Fonte: Elaborado pelo autor.

4.3 O Modelo *Adaptive Neuro-Fuzzy Inference System* (ANFIS)

A modelagem por meio do método *Adaptive Neuro Fuzzy Inference Systems* – ANFIS exige várias considerações *a priori* para definição dos parâmetros utilizados. Neste sentido, a Tabela 3 especifica os parâmetros adotados para construção do modelo ANFIS.

Tabela 3: Características consideradas no ANFIS.

Método	Considerado
name	'anfis'
type	'sugeno'
andMethod	'prod'
orMethod	'max'
defuzzMethod	'wtaver'
impMethod	'prod'
aggMethod	'max'
input	1x6 struct
output	1x1 struct
rule	1x64 struct

Fonte: Elaborado pelos autores.

Outro critério importante é a definição da função de pertinência utilizada (ver MATLAB, 2014). Como pode ser observado na Tabela 4, foram testadas 8 funções de pertinência para o presente modelo, o resultado está disposto do maior erro para o menor – e foi calculado utilizando os dados normalizados (valor original e valor previsto) – neste sentido observa-se que a função “pimf” foi a que obteve melhor resultado. Apresentando erro (RMSE) de 0,00794208 para a amostra de treinamento, e erro de 0,00619975 para a amostra de validação.

Tabela 4: Funções de pertinência testadas (valores normalizados).

Funções de Pertinência	RMSE (error – treinamento)	RMSE (error – validação)
gbellmf	0,00794208	0,00640297
gauss2mf	0,00800622	0,00638388
gaussmf	0,00800632	0,00638289
dsigmf	0,00793503	0,00636233
psigmf	0,00793503	0,00636233
trapmf	0,00812549	0,00635165
trimf	0,00819679	0,00626703
pimf	0,00790669	0,00619975

Fonte: Elaborado pelos autores.

Para melhor visualização do ajuste das funções de pertinência realizados pelo ANFIS na camada de entrada do sistema pode-se observar na Figura 7, o quanto as funções de pertinência foram deslocadas de sua posição original. Observa-se que as linhas contínuas, na Figura 7 representam a posição original da grade gerada pelo modelo, já as linhas pontilhadas representam as funções de pertinência ajustadas pelo ANFIS.

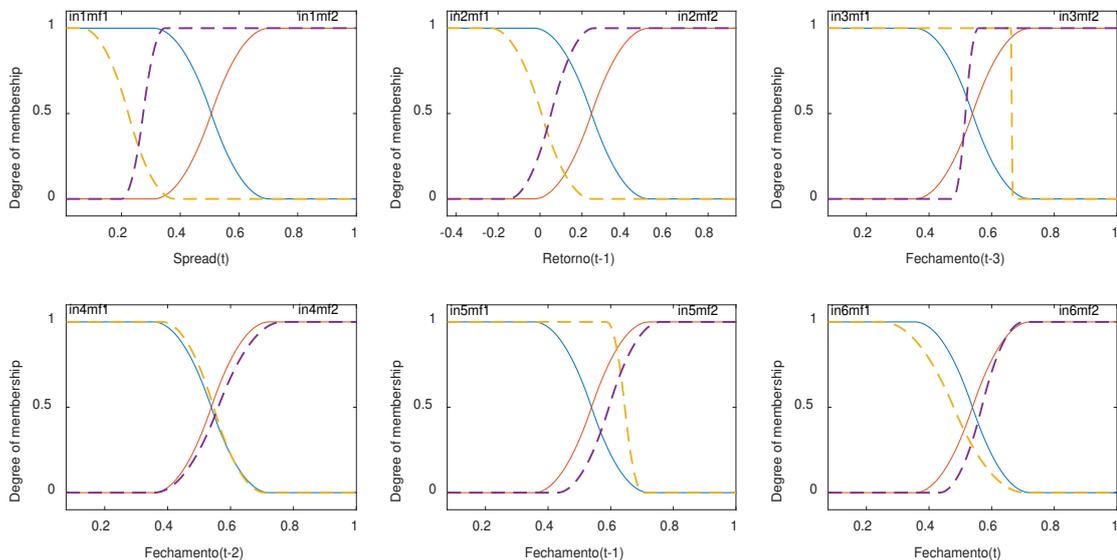


Figura 7: Ajuste das funções de pertinência para ANFIS.

Fonte: Elaborado pelos autores.

Outra visualização importante é a estrutura final gerada pelo ANFIS, esta pode ser visualizada na Figura 8a. Já para melhor compreender as alterações ocorridas no espaço amostral, pode-se ver na Figura 8b, que as relações geradas pela entrada 1 ($Spread_t$) e pela entrada 2 ($Retorno_{t-1}$) juntamente com a saída do modelo ($Fechamento_{t+1}$), neste caso observa-se que quando a entrada 1 ($Spread_t$) é alta e a entrada 2 ($Retorno_{t-1}$) é baixa o valor da saída

($Fechamento_{t+1}$) é baixo, para esse caso o inverso também é verdadeiro como pode ser visto na Figura 8b.

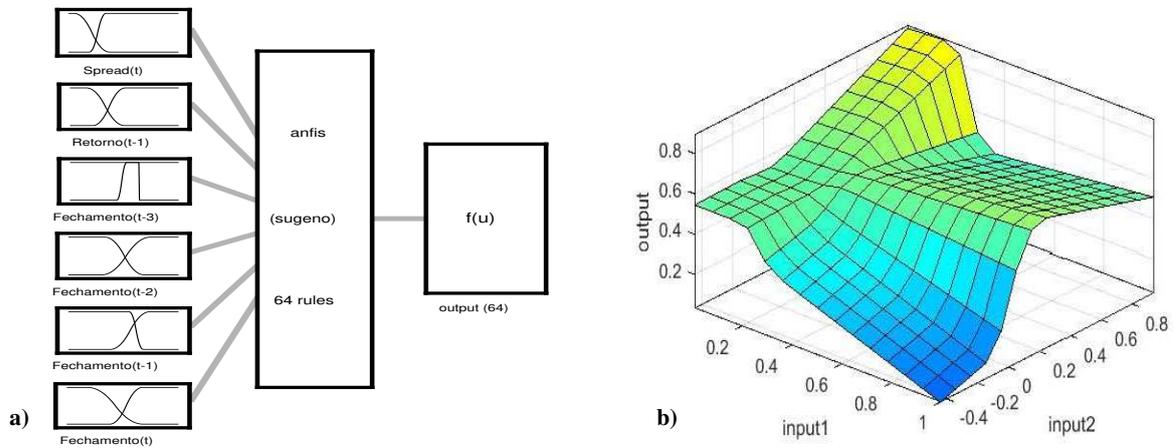


Figura 8: a) Estrutura do modelo ANFIS, b) Espaço amostral gerado.
Fonte: Elaborado pelos autores.

4.4 Acurácia dos Modelos de Previsão

Para defini qual dos dois modelos, Redes Neurais Artificiais – RNA ou *Adaptive Neuro Fuzzy Inference Systems* – ANFIS, obteve melhor resultado, foram utilizadas as seguintes métricas de avaliação: Raiz do erro médio quadrado (RMSE - *Root Mean Square Error*), Erro Médio Absoluto Percentual (MAPE - *Mean Absolute Percentage Error*) e o Coeficiente de Determinação (R^2). Os resultados encontrados ainda foram apresentados para a amostra de validação/teste (*chk*) e para amostra de treinamento (*tran*), isto porque espera-se que os modelos sejam capazes de generalizar e consigam prever observações que não foram utilizadas para construir suas regras durante o treinamento.

Para confrontar os resultados encontrados para os dois modelos apresenta-se na Tabela 4 as medidas de erro encontrados para os ajustes e, também, o Coeficiente de determinação (R^2) que apresentou resultados relevante na casa dos 0,99 de determinação para ambos os modelos.

Tabela 5: Métricas de desempenho para previsões (valor original da série temporal).

Métrica	ANFIS		RNA	
	Treinamento	Validação	Treinamento	Validação
RMSE	995,15	765,01	996,46	765,93
MAPE	0,0141	0,0114	0,0142	0,0117
R2	0,9998	0,9998	0,9998	0,9998

Fonte: Elaborado pelos autores.

Na Tabela 5, observa-se que os resultados para o Modelo ANFIS apresentam um erro MAPE (*Mean Absolute Percentage Error*) de 0,0141 para o treinamento e 0,0114 para validação, em previsões um dia à frente ($t+1$), o que possibilita uma boa margem de previsão para tomada de decisão dentro do mercado financeiro. Por outro lado, o Modelo RNA apresenta um erro MAPE (*Mean Absolute Percentage Error*) próximo ao citado anteriormente, porem um pouco maior, ou seja, 0,0142 para o treinamento e 0,0117 para validação, em previsões um dia à frente ($t+1$).

No que se refere ao RMSE (*Root Mean Square Error*), o Modelo ANFIS também obteve melhores acertos do que o Modelo de RNA (Tabela 5). Neste sentido, pode-se auferir que a presente configuração encontrada para o ANFIS e superior a configuração realizada para a RNA

para a presente amostra. A seguir são apresentados os resultados gerados apenas para o Modelo ANFIS.

4.5 Os Resultados do Modelo de Previsão ANFIS

Para demonstrar a qualidade do ajuste realizado, apresenta-se na Figura 9 a série temporal do valor de fechamento original (em azul) sobreposta pela série estimada (em vermelho) pelo modelo ANFIS. Observa-se que foi possível realizar um bom ajustamento e uma boa previsão do valor de fechamento para um dia a frente (t_{+1}).

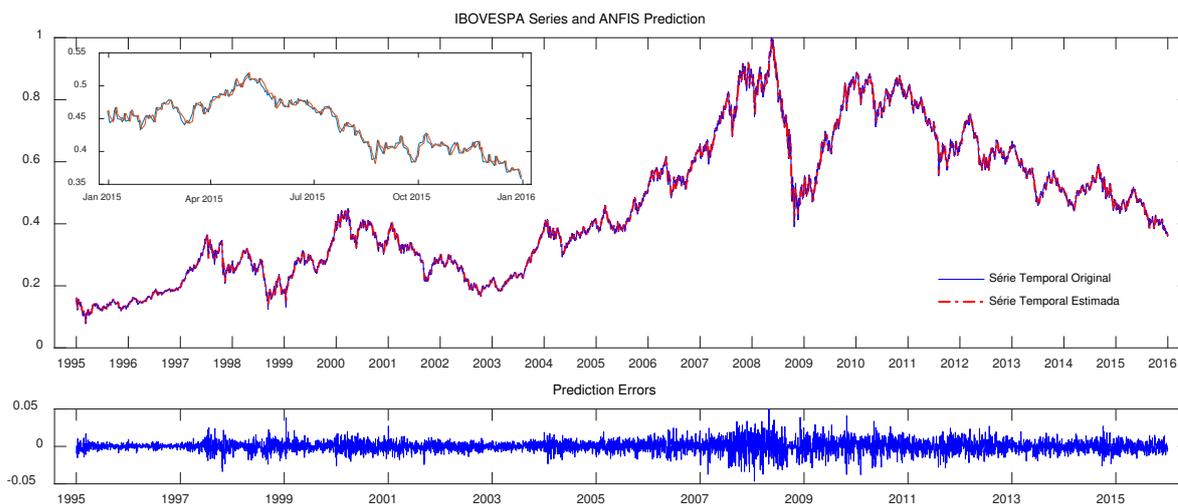


Figura 9: Comparação da série temporal do valor de fechamento original com o valor previsto.

Fonte: Elaborado pelos autores.

Já no que se refere especificamente aos dados de validação utilizados na modelagem (observações que não foram utilizadas para criar as regras do modelo), pode-se visualizar a qualidade do ajuste realizado para o ano de 2015 ao comparar a série original (azul) e a série prevista (vermelha) na Figura 10, que apresenta a previsão um dia a frente gerada pelo ANFIS.

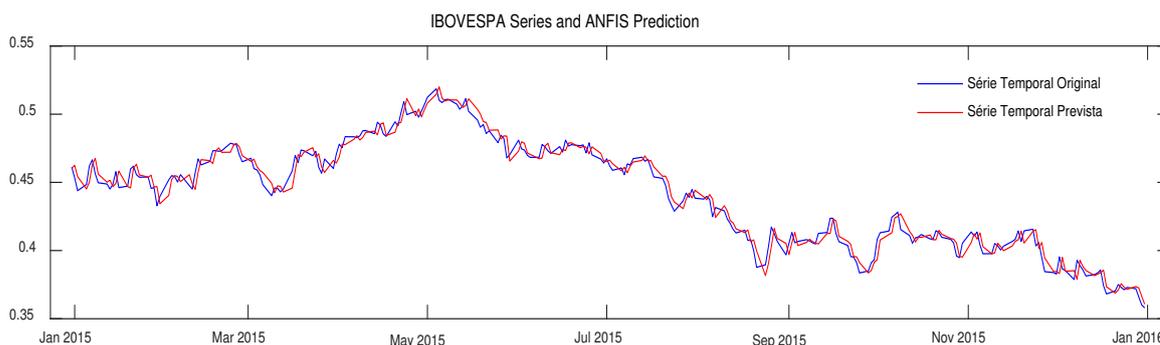


Figura 10: Comparação do valor de fechamento original com o valor previsto para 2015.

Fonte: Elaborado pelos autores.

Buscando verificar a aplicabilidade do modelo, verificou-se qual seria a acurácia da previsão para no máximo uma semana a frente. Os resultados demonstram que o erro apresenta comportamento linear e não exponencial, o que pode ser verificado na Figura 11. Esse resultado é relevante, pois, revela que se pode realizar previsões para o mercado de ações com certa previsibilidade de acerto.

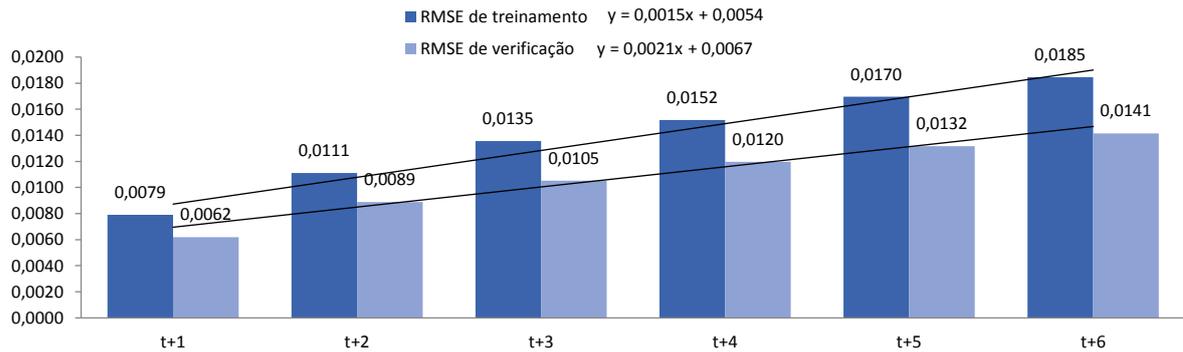


Fig. 11. Erro projetado para uma semana a frente.
Fonte: Elaborado pelo autor.

Na Figura 12, pode-se visualizar a dispersão do valor causado pelo erro em torno do valor da série original, que tende a aumentar, ao passo que os dias vão se distanciando do tempo t . Entretanto, como a previsão se mantém dentro de uma dispersão coerente com o valor original, isso auxilia a tomada de decisão no mercado acionário.

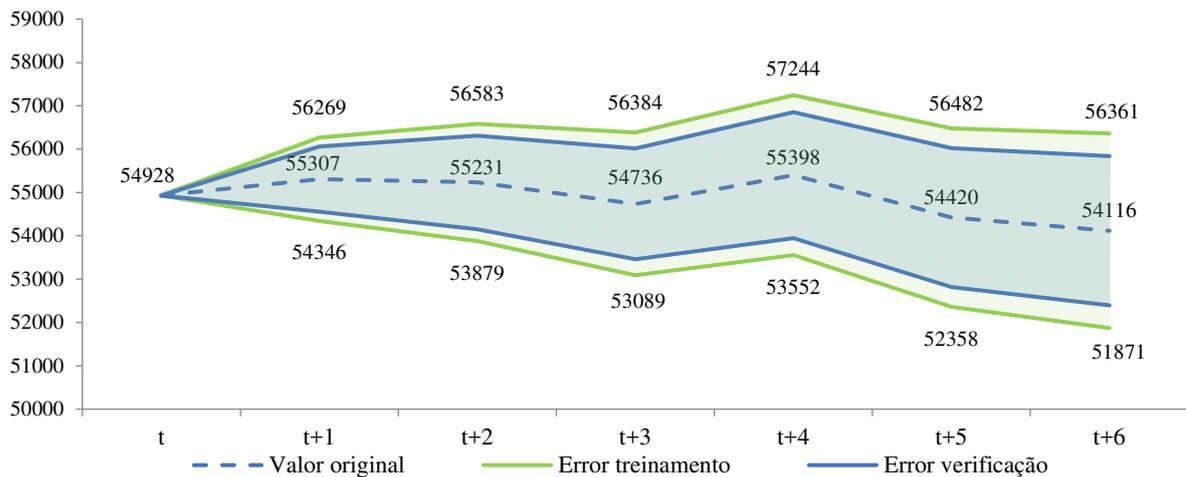


Fig. 12. Dispersão do erro projetado para uma semana a frente.
Fonte: Elaborado pelo autor.

Os resultados encontrados apresentam erro (RMSE - *root-mean-square error*) de 753,73 para previsões um dia à frente ($t+1$), generalizando o modelo para previsões em $t+2$ até $t+6$ (uma semana à frente) percebe-se que o erro aumenta de forma linear o que possibilita uma maior margem de previsão para tomada de decisão.

5 CONCLUSÕES

O objetivo do estudo foi realizar a previsão das séries temporais do Índice Bovespa (Ibovespa) utilizando os métodos de Redes Neurais Artificiais – RNA e *Adaptive Neuro Fuzzy Inference Systems* – ANFIS, tendo em vista buscar alternativas a modelos lineares que podem ignorar certos aspectos das estruturas dinâmicas existentes no mercado de ações. Dentro deste contexto, verificou-se um bom ajuste do modelo para a série estudada, o que confirma que modelos híbridos utilizando Sistemas Fuzzy (em termos de regras difusas) apresentam características que podem ser úteis para lidar com séries temporais que possuem estruturas dinâmicas complexas e não-lineares como é o caso das séries temporais financeiras.

Como limitações do presente estudo, salienta-se que o artigo analisou apenas a série do Ibovespa, sendo necessário verificar a aplicabilidade dos resultados em mais séries como por exemplo em índices como S&P 500, IPSA, NASDAQ e Merval entre outros. Como sugestão

para estudos futuros recomenda-se utilizar outros modelos para comparação, tanto modelos lineares como não lineares para se ter medidas mais robustas na previsões e comparações.

Por fim, observa-se que os resultados encontrados são relevantes, pois, demonstram que por meio de métodos como o *Adaptive Neuro Fuzzy Inference Systems* – ANFIS, pode-se realizar previsões para o mercado acionário com certa previsibilidade, comprovando que eventos ocorridos no passado podem vir a determinar eventos futuros como salienta a teoria de Charles Dow e refutando a hipótese do *Random Walk* de Bachelier (1964) para a presente amostra.

REFERÊNCIAS

ARAÚJO, A. C.; MONTINI, A. High Frequency Trading: análise de retorno, volume e volatilidade. **Revista de Administração Faces Journal**, v. 17, p. 55-73, 2018.

BACHELIER, L. Théorie de la speculation. **Annales scientifiques de l'École Normale Supérieure**, v. 3, n. 17, p. 21-86, 1900.

BÓDIS, L. **Financial times series forecasting using artificial neural networks**. Master Thesis – “Babes-Boluai” University, Faculty of Mathematics and Computer Science – Department of Computer Science, Cluj-Napoca, Romania, 2004.

BROCKWELL, P. J.; R A. DAVIS. **Time Series: Theory and Metlwds**. 2. ed. Springer Verlag, New York, 1991.

BRUM, C. A. H. **Aprenda a investir em ações e a operar na bolsa via internet**. Rio de Janeiro: Ciência Moderna, 2006.

CAMARGOS, M. A.; ROMERO, J. A. R.; BARBOSA, F. V. Análise empírica da prática de insider trading em processos de fusões e aquisições recentes na economia brasileira. **REGE Revista de Gestão**, v. 15, n. 4, p. 55-70, 2008.

CASTRO, C. L. **Sistema Inteligente baseado em Redes Neurais Artificiais para Previsão On-line do Índice Ibovespa**. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal de Minas Gerais, UFMG, 2003.

CHARNET, R. et al. **Análise de modelos de regressão linear com aplicações**. São Paulo: Unicamp, 2008.

COELHO, L. S.; SANTOS, A. A. P.; COSTA JR., N. C. A. Podemos prever a taxa de cambio brasileira? Evidência empírica utilizando inteligência computacional e modelos econométricos. **Gestão & Produção**, v. 15, p. 635-647, 2008.

DELURGIO, S. A. **Forecasting: principles and applications**. Boston, USA: Irwin McGraw-Hill, 1998.

DEMSETZ, H. The cost of transacting. **Quarterly Journal of Economics**, v. 82, n. 1, p. 33-53, 1968.

FAMA, E. F. Efficient capital markets II. **Journal of Finance**, Oxford, v. 46, n. 5, p. 1575-1618, 1991.

FAMA, E. F. Efficient capital markets: A review of theory and empirical work. **Journal of Finance**, v. 25, n. 2, p. 383-417, 1970.

- FAMA, E. F.; FRENCH, K. R. Permanent and temporary components of stock prices. **Journal of Political Economics**, v. 96, n. 2, p. 246-273, 1988.
- HAUGEN, R. A. **Modern Investment Theory**. Upper Saddle River, New Jersey: Prentice Hall, 1997.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.
- HSU, M-W. et al. Bridging the divide in financial market forecasting: machine learners vs. financial economists. **Expert Systems with Applications**, v. 61, p. 215-234, 2016.
- JANG, J.-S. R. ANFIS: adaptive-network-based fuzzy inference system. **IEEE transactions on systems, man, and cybernetics**, v. 23, n. 3, p. 665-685, 1993.
- LEITE, D.; GOMIDE, F.; BALLINI, R.; COSTA, P. Fuzzy granular evolving modeling for time series prediction. In: **Fuzzy Systems (FUZZ), IEEE International Conference on**. IEEE, 2011. p. 2794-2801.
- LO, A. W.; MACKINLAY, C. Stock market prices do not follow random walks: evidence from a simple specification test. **Review of Financial Studies**, v. 1, n. 1, p. 41-66, 1988.
- MACIEL, L.; BALLINI, R.; GOMIDE, F. Evolving possibilistic fuzzy modeling for realized volatility forecasting with jumps. **IEEE Transactions on Fuzzy Systems**, v. 25, n. 2, p. 302-314, 2017.
- MARTINS, G. A.; THEÓFILO, C. R. **Metodologia da investigação científica para ciências sociais aplicadas**. São Paulo: Atlas, 2009.
- MATLAB. **The MathWorks - Fuzzy Logic Toolbox**. User's guide, Versão 2, p. 2-11, 2014.
- MATSURA, E. **Comprar ou vender: como investir na bolsa utilizando análise gráfica**. 6. ed. São Paulo: Saraiva, 2007.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. 2. ed. São Paulo: Edgar Blücher, 2006.
- POTERBA, J.; SUMMERS, L. Mean reversion in stock prices: evidence and implications. **Journal of Financial Economics**, v. 22, n. 1, p. 27-59, 1988.
- TAKAGI, T.; SUGENO, M. Fuzzy identification of system and its applications to modelling and control. **IEEE Trans. Syst., Man, and Cyber**, 1:5. 1985.
- TALARPOSHTI, F. M. et al. Stock market forecasting by using a hybrid model of exponential fuzzy time series. **International Journal of Approximate Reasoning**, v. 70, p. 79-98, 2016.
- VERGARA, S. C. **Projetos e Relatórios de Pesquisa em Administração**. 9. ed. São Paulo: Atlas, 2008.
- ZHANG, G.; PATUWO, B. E.; HU, M. Y. Forecasting with artificial neural networks: The state of the art. **International journal of forecasting**, v. 14, n. 1, p. 35-62, 1998.