

Área Temática: Finanças

**PREVISÃO COM REDES NEURAIAS ARTIFICIAIS NO MERCADO DE AÇÕES
BRASILEIRO: MODELO TÉCNICO E MODELO FUNDAMENTALISTA**

AUTORES

LEANDRO DOS SANTOS MACIEL

Universidade Estadual de Campinas

leandro_maciell@hotmail.com

ROSANGELA BALLINI

Universidade Estadual de Campinas

ballinii@hotmail.com

RESUMO

Este trabalho apresenta um modelo não linear para a predição do mercado de ações brasileiro com a utilização de um instrumento de inteligência artificial. Para sua construção, foi utilizada uma combinação entre modelos de análise técnica e análise fundamentalista. O modelo fundamentalista foi baseado na seleção de variáveis econômicas que têm relação com as séries avaliadas. O modelo técnico foi construído com base na filtragem *wavelet* para as séries temporais, assim como na construção de um modelo de rede neural multicamada tendo como entrada os dados filtrados e as variáveis selecionadas pelo modelo fundamentalista. Foram previstos os preços de fechamento das ações do Banco Múltiplo ItaúUnibanco, Banco Bradesco, Usiminas, Companhia Vale do Rio Doce, Grupo Gerdau e Petrobrás. O modelo empregado foi comparado com um modelo ARIMA, com base na raiz quadrada da média do erro de predição quadrático. Os resultados mostraram que o método proposto apresentou melhores resultados que o modelo ARIMA, comprovando a relevância da utilização do modelo fundamentalista para a predição dos preços das ações e a superioridade do modelo de rede neural em comparação com os modelos tradicionais de séries temporais.

Palavras-chave: Redes Neurais Artificiais, Séries Temporais Econômicas, Previsão.

ABSTRACT

This work presents a nonlinear method to Brazilian stock markets predicting with an artificial intelligence method. It was performed a combination between fundamental and technical analysis of script quotation. The fundamental model was based on economics variable selection that is correlated to the time series evaluated. In the technical model was used a wavelet transform to the financial series, as well as in order to construct a multilayer neural network model based on filtering data and the selected variables by fundamentalist model as inputs. It was predicted stock closed prices of ItaúUnibanco Bank, Bradesco Bank, Usiminas, Vale do Rio Doce Company, Gerdau Group and Petrobrás. The model proposed was compared with ARIMA model, based on Root-Mean-Square Error of Prediction. The results showed that the proposed method has better results in asset pricing than the ARIMA method, showing the relevance of fundamentalist model using for the stock prices prediction and the superiority of neural network model in comparison with other traditional time series methods.

Keywords: *Artificial Neural Networks, Economics Time Series, Predicting.*

1. Introdução

A maioria das séries temporais econômicas possui seu comportamento descrito por um processo estocástico, impossibilitando, assim, a construção de um modelo matemático que descreva seu comportamento. As técnicas baseadas em reconhecimento de padrões como regressão e Redes Neurais Artificiais (RNAs) apresentam-se como alternativas para esse problema, utilizadas para a previsão de valores futuros de séries temporais de comportamento estocástico. Essas técnicas identificam padrões de oscilação na série temporal observados em dados do passado ($t - 1, t - 2, \dots, t - n$) para então prever valores em momentos no futuro ($t + 1, t + 2, \dots, t + p$) (Kedem e Fokianos, 2002)¹.

Com a decretação da inconversibilidade do dólar em ouro, em março de 1973, pelo então Presidente norte-americano Richard Nixon, a flutuação das variáveis econômicas fundamentais, taxa de câmbio e taxa de juro, tornou-se muito mais intensa. Com isso, o aumento da volatilidade dos ativos financeiros atingiu todas as esferas dos mercados de capitais. Nessa nova conjuntura instaurada, a acurácia dos modelos de previsão de séries econômicas se tornou um elemento chave para os gestores de investimentos e demais agentes econômicos. No mercado de ações, as estratégias de operações, segundo Lameira (2003), baseiam-se em dois modelos: o modelo fundamentalista e o modelo técnico. O modelo fundamentalista avalia os aspectos econômicos e contábeis da empresa com ação cotada na bolsa de valores, bem como analisa as variáveis macroeconômicas que influenciam na variação no valor da empresa. Enquanto que o modelo técnico propõe modelos de predição com base nos padrões identificados nos históricos das ações no mercado (Murphy, 1991).

Em essência, os modelos procuram projetar o comportamento futuro dos preços das ações no mercado financeiro. O modelo técnico mais famoso e utilizado para predição de séries temporais econômicas é o auto-regressivo integrado de média móvel – ARIMA (*AutoRegressive Integrated Moving Average*), ou conhecido como modelo Box e Jenkins. Ele unifica as principais técnicas estatísticas num único modelo para séries de comportamento estocástico (Box e Jenkins., 1976)². Aplicações de modelos de inteligência artificial para a previsão de séries temporais, como as Redes Neurais Artificiais, foram iniciadas na década de oitenta. A utilização das RNAs como estimador, ao invés de modelos ARIMA, ganharam destaque com os trabalhos de Jang (1991), Matsuba (1991) e Cannor et al. (1994). Neles, as RNAs apresentaram superioridade *vis-à-vis* o modelo de Box e Jenkins.

Segundo Kolen (1994), as RNAs são capazes de extrair relações não lineares a partir de dados de entrada ruidosos, não lineares e não estacionários, e produzem resultados mais satisfatórios se comparados aos modelos tradicionais de séries temporais. Entretanto, os estudos nesta área realizam as previsões com base em conceitos intrínsecos aos modelos, deixando de lado o referencial da teoria econômica que ajuda a explicar o comportamento das variáveis focos de previsão. Racine (2001), Grôppo (2004) e Nagano et al. (2003) afirmam em seus trabalhos que os fatores econômicos são extremamente relevantes na compreensão e predição do comportamento de uma série temporal econômica, e que o uso de dados econômicos e macroeconômicos, com base na teoria econômica ou fundamentalista, ajudam na compreensão dos padrões das séries avaliadas.

Dhatt et al. (1999) e Gurgul et al. (2003) avaliaram a relação entre variáveis fundamentalistas e comportamento de preços nos mercados de ações. Seus resultados confirmam que variáveis específicas das empresas e dos mercados influenciam o

¹ Os estudos com base em previsão de séries temporais estocásticas se iniciaram com Weigend et al. (1990), mas somente na metade da década de 1980 os modelos se tornaram mais sofisticados e difundidos baseados no modelo probabilístico bayesiano de Harrinson e Stevens (1976).

² São inúmeros os trabalhos que utilizam o modelo de Box e Jenkins para a predição de séries temporais financeiras, dentre eles: Harvey e Todd (1983) e McCabe e Tremayne (1995).

comportamento dos preços desses ativos. Esses trabalhos incitaram uma nova tendência para a predição de séries temporais do tipo econômica, em que os melhores resultados não estão associados apenas a modelos técnicos, mas em sua combinação com análises fundamentalistas. Lam (2004), por exemplo, foi a primeira a propor uma RNA que integrasse os modelos técnicos e fundamentalistas. Fazendo uso de vinte e sete variáveis fundamentalistas, Lam demonstrou que os dois modelos integrados previram com superioridade os preços das ações cotadas na bolsa de valores de Nova Iorque, em comparação a modelos do tipo ARIMA.

Este trabalho avaliou uma combinação de procedimentos econométricos, modelo fundamentalista, e de séries temporais, modelo técnico, para a predição do preço das ações do Banco Múltiplo ItaúUnibanco, Banco Bradesco, Usiminas, Companhia Vale do Rio Doce, Grupo Gerdau e Petrobrás. O modelo fundamentalista incluiu o índice Ibovespa, a taxa de câmbio, a taxa de juro básica da economia, o valor de mercado das empresas, o lucro líquido e o risco país, por serem variáveis econômicas correlacionadas às séries estudadas. Para a modelagem técnica foi aplicado um modelo de Rede Neural para a predição dos valores dos preços no futuro. Além disso, foi utilizada a filtragem *wavelet* para atenuar os efeitos não econômicos das séries para predição. A construção do modelo de rede neural foi aprimorada com a inclusão das variáveis econômicas do modelo fundamentalista. Os resultados de predição do comportamento futuro foram comparados com o modelo de previsão clássico utilizado pelos agentes de mercado, modelo ARIMA.

O presente artigo está estruturado como segue. A seção 2 apresenta sucintamente o modelo de transformada *wavelet*. As RNAs são discutidas seção 3, seguida pela metodologia empregada na seção 4. Os resultados são apresentados na seção seguinte. A seção 6 finaliza este trabalho com a conclusão, e as referências na seção 7.

2. Análise *wavelet*

A análise *wavelet*, ou transformada *wavelet*, é uma ferramenta estatística que utiliza janelas com comprimentos variáveis que se ajustam melhor às características do sinal de uma determinada série avaliada. A vantagem de sua utilização se concerne na possibilidade de análise tempo-frequência que permite a localização de altas frequências em intervalos de tempos específicos, típico de séries temporais, tornando possível a suavização do componente aleatório da série em trechos específicos. Sua utilização para filtragem de séries temporais tem sido proposta em diversos trabalhos (Renaud et al., 2005; Fryzlewicz, 2003), em confronto às técnicas clássicas, como a transformada de Fourier.

A transformada *wavelet*, em sua versão discreta é dada por:

$$f(t) = \sum_{k=-\infty}^{\infty} d_k \phi_k(t) + \sum_{j=0}^{\infty} \sum_{k=-\infty}^{\infty} c_k^j \mathcal{G}_k^j(t) \quad (1)$$

em que

$$\mathcal{G}_k^j(t) = \mathcal{G}(2^j t - k) \quad (2)$$

é chamada de *wavelet* mãe, enquanto que

$$\phi_{j,k}(t) = 2^{\frac{j}{2}} \phi(2^j t - k) \quad (3)$$

é chamada de função escala ou *wavelet* pai e os coeficientes j e k são os coeficientes da análise ou transformada *wavelet*.

A análise *wavelet* especifica a localização (via translação) e frequência (via compressão) utilizando, respectivamente, a *wavelet* mãe e pai.

$$g_{c,b}(t) = \frac{1}{\sqrt{c}} g\left(\frac{t-b}{c}\right) \quad (4)$$

$$\phi_{c,b}(t) = \frac{1}{\sqrt{c}} \phi\left(\frac{t-b}{c}\right) \quad (5)$$

em que os parâmetros b e c variam continuamente no espaço \mathfrak{R} , de forma a obter a *wavelet* comprimida ou dilatada pela fator c e deslocada pelo fator b . Com esses processos é possível aproximar qualquer sinal nos planos \mathfrak{R} e \mathbb{I} (irracionais).

O efeito dilatação da função *wavelet* é obtido quando $c > 1$, porém, para $c < 1$ obtém o efeito contração, sendo possível analisar os aspectos globais e locais das séries. À medida que varia b , a função f é analisada localmente em torno de b^3 .

3. Redes Neurais Artificiais

As RNAs são modelos computacionais não lineares, que na tentativa de emular o cérebro humano, organizam-se por meio de elementos básicos de processamento denominados neurônios artificiais, que se interligam na formação de redes capazes de processar, armazenar e transferir informações vindas de um meio exterior (Haykin, 2001). A figura 1 apresenta um modelo de neurônio artificial, conhecido como neurônio de McCulloch-Pitts (Haykin, 2001), que, de forma similar ao neurônio biológico, recebe informações de outros neurônios ou de um meio externo e as processa de forma a obter uma resposta em sua saída.




Figura 1: Neurônio Artificial

No neurônio artificial da figura 1, x_1, x_2, \dots, x_n representam os sinais de entrada, w_1, w_2, \dots, w_n são os pesos sinápticos do neurônio, φ é o limiar de ativação do neurônio que define se a saída será disparada, u é a saída do combinador linear em que $u = \sum_{i=1}^N w_i \cdot x_i - \varphi$, e $g(\cdot)$ é uma função de ativação da saída do combinador linear que processa o conjunto de entradas recebidas e as transforma em estado de ativação⁴.

³ Para mais detalhes da transformada *wavelet* ver o trabalho de Donoho (1995).

⁴ As principais funções de ativação são: sigmóide ou logística, degrau bipolar e hiperbólica.

3.1 Arquitetura das Redes Neurais Artificiais

Os neurônios artificiais podem ser conectados e organizados de várias formas, o que configura a arquitetura da rede neural, com características e aplicações bastante distintas. Em geral, as redes neurais podem ser arquitetadas em forma de camada única ou múltiplas camadas. Numa rede formada por uma camada única, tem-se a entrada de dados e uma única camada de neurônios em paralelo, que é a própria camada de saída. Esse tipo de rede, entretanto, sofre limitações em representar funções linearmente separáveis. Porém, são superadas pela utilização de redes multi-camadas, formadas por uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. As arquiteturas das redes neurais também podem ser classificadas como recorrentes e não recorrentes (Russel e Norvig, 1995).

Redes não recorrentes, também conhecidas como redes multi-camadas, são redes que não possuem realimentação de suas saídas para suas entradas (Haykin, 2001). Podem ser formadas por uma camada única ou por múltiplas camadas. RNAs multi-camadas não recorrentes contêm um conjunto de entradas, uma ou mais camadas escondidas e uma camada de saída (ver figura 2).




Figura 2: RNA multi-camada não recorrente

No modelo da figura 2, a camada de saída apresenta a saída da rede. São denominadas camadas intermediárias ou ocultas, as camadas que não possuem ligações diretas com a entrada. Além disso, não existem conexões ligando um neurônio de uma camada a outro de uma camada anterior, nem a um neurônio da mesma camada, as conexões somente são feitas para neurônios da camada seguinte.

Nas redes não recorrentes a saída é apenas uma resposta imediata ao estímulo da entrada, ou seja, as informações prévias não são reutilizadas, produzindo apenas mapeamentos estatísticos. Por isso que esse modelo apresenta restrições para representar sistemas variantes no tempo, uma vez que o vetor de saída da rede neural depende apenas do vetor de entrada definido no mesmo instante t (Kolen, 1994), por isso é recomendável o uso de RNAs do tipo recorrente.

Redes neurais recorrentes se caracterizam pela realimentação das saídas pelas entradas, sendo suas saídas determinadas pelas entradas atuais e pelas saídas anteriores (Haykin, 2001). As interconexões entre esse tipo de arquitetura é bem mais complexo que entre redes não recorrentes, pois, quando organizadas em camadas, possuem interligações entre neurônios da mesma camada e entre camadas não consecutivas (Jain, 2001). Outra questão chave na caracterização de um modelo de rede neural é a utilização do algoritmo de treinamento, que será descrito a seguir.

O treinamento de uma rede neural consiste no ajuste dos pesos sinápticos w_j e dos limiares φ . O treinamento objetiva fazer com que a rede seja capaz de generalizar um problema, i.e., a rede não precisa conhecer todas as entradas necessárias para obter a saída, de forma que a aplicação de um conjunto de entradas desconhecidas seja capaz de gerar dados de saída desejáveis (Haykin, 2001).

Os algoritmos de treinamento de uma rede neural podem ser supervisionados ou não supervisionados. No treinamento do tipo supervisionado a rede recebe os vetores de entrada assim como as saídas desejadas. O treinamento, portanto, ajustará os pesos entre os neurônios de maneira a se obter a saída desejada, ou seja, a rede é treinada para fornecer um conjunto de saída desejada a um estímulo de entrada específico. Na literatura, o algoritmo de treinamento *backpropagation*, ou conhecido como algoritmo de retropropagação do erro, é o mais citado.

O mecanismo de funcionamento do algoritmo *backpropagation* é formado por dois passos. No primeiro passo, a entrada é fornecida aos neurônios da camada de entrada da RNA, passo da propagação, o sinal se propaga para frente, ou seja, no sentido das conexões, em cada camada da rede até apresentar o primeiro resultado, na camada de saída. Nesse momento, não ocorrem alterações nos pesos da rede. Apenas a diferença entre a saída da rede e a resposta desejada é objetivada.

$$E = \frac{1}{2} \sum_n \sum_{i=1}^p (x_i - \hat{x}_i)^2 \quad (6)$$

em que E é a função da medida do erro total da rede, n é o número de padrões apresentados à rede, p é o número de neurônios na camada de saída, x_i é a i -ésima saída desejada e \hat{x}_i é a i -ésima saída gerada pela rede.

O passo de retropropagação, segundo passo, é caracterizado pelo ajuste dos pesos da rede de forma a minimizar a função E . O ajuste dos pesos deve ser feito proporcionalmente ao negativo do gradiente do erro em relação aos pesos da rede, conforme

$$\Delta w_{ij} = -\eta \cdot \left(\frac{\partial E}{\partial w_{ij}} \right) \quad (7)$$

em que os índices i e j referem-se ao neurônio i da camada posterior e ao neurônio j da camada anterior e η é a taxa de aprendizagem que determina a “velocidade” do passo em direção ao mínimo da função de erro E . Um valor muito elevado para a taxa de aprendizagem pode levar a rede a chegar a níveis ao redor do mínimo de E sem conseguir atingi-lo, enquanto que um η muito pequeno poderá deixar a convergência do treinamento muito lenta.

Ao calcular a derivada para todas as camadas da rede, as fórmulas para a atualização dos pesos w_{ij} , para cada padrão de entrada individualmente, são:

$$\Delta W_{ij} = \eta \cdot \delta \cdot x_j \quad (8)$$

em que

$$\delta = g'_j \left(\sum_{k=1}^{N2} \delta_k w_{kj} \right) \quad (9)$$

e g'_j é a derivada da função de ativação do neurônio j ⁵.

Apesar de ser o algoritmo de treinamento mais utilizado, o *backpropagation* apresenta baixa velocidade de convergência quando próximo de um mínimo da função de erro E , uma vez que a atualização dos pesos é proporcional ao valor do gradiente do erro, além disso, tem-se um problema com os mínimos locais, pois o mínimo global de E não é atingido quando se atinge um mínimo local.

4. Metodologia

O objetivo deste trabalho é fazer a previsão do preço de fechamento das ações preferenciais das seguintes empresas: Banco Múltiplo ItaúUnibanco, Banco Bradesco, Usiminas, Companhia Vale do Rio Doce, Grupo Gerdau e Petrobrás. Para isso faremos uma combinação de modelos de previsão fundamentalista e técnico.

4.1 Modelo Fundamentalista

No modelo fundamentalista, o objetivo principal é explicar o comportamento dos preços das ações por meio de dados financeiros e econômicos co-relacionados com as séries em estudo. Partimos do pressuposto que os indicadores econômicos selecionados possam contribuir na predição das séries, são elas: índice Ibovespa, a taxa de câmbio, a taxa de juro básica da economia, o valor de mercado das empresas, o lucro líquido e o risco país⁶.

As variáveis do modelo foram divididas em variáveis financeiras e variáveis macroeconômicas. As variáveis macroeconômicas são as que estão relacionadas ao desempenho geral da economia, em nível de mercado nacional ou internacional, em que a companhia referente à ação está inserida. Enquanto que as variáveis financeiras estão relacionadas quanto ao desempenho individual da empresa em questão, como lucro líquido, por exemplo. Portanto, as variáveis financeiras são: valor de mercado da empresa e lucro líquido; as macroeconômicas: índice Ibovespa, taxa de juro básica da economia (SELIC), taxa de câmbio e risco país⁷.

A seleção dessas variáveis se deu pelo uso do coeficiente de correlação de Sperman (SRCC – *Sperman Rank Correlation Coefficient*), que avalia a correlação entre as variáveis e a série a ser predita. O coeficiente de Sperman é dado por:

$$|r| = 1 - \frac{6 \sum_{i=0}^n d_i^2}{n(n^2 - 1)} \quad (10)$$

em que n é o número de pares entre as variáveis x_1 e x_2 a serem analisadas e d_i é:

$$d_i = (P_{x_1}) - (P_{x_2}) \quad (11)$$

sendo P_{x_j} o posto de x_j dentre os valores de x_j .

Um teste muito aplicado para avaliar a correlação linear entre variáveis é o coeficiente de Pearson. Entretanto, segundo Jaeger (1990), o teste de correlação de Sperman não requer

⁵ Uma apresentação mais detalhada do algoritmo de *backpropagation* pode ser vista no trabalho de Rumelhart e McClelland (1986).

⁶ Os dados foram obtidos em: <<http://www.cvm.gov.br>>; <<http://www.ipeadata.gov.br>>; e <<http://www.fgv.br>>. Acesso em: 13/04/09.

⁷ A seleção dessas variáveis baseia-se nos trabalhos de Nagano et al (2003) e Grôppo (2004).

suposição de linearidade, como no coeficiente de Pearson, e apresenta a possibilidade de se fazer a correlação de dados de fontes distintas e grandezas diferentes, assim como não requer nenhuma suposição sobre a distribuição de frequências das variáveis, enquanto que o coeficiente de Pearson requer a assunção de inovações Gaussianas. Dessa forma, as variáveis selecionadas serão inseridas no modelo técnico, baseado nas RNAs, para se realizar a modelagem de previsão das ações.

4.2 Modelo Técnico

Para a construção do modelo técnico foi selecionado os dados históricos dos preços de fechamento das ações avaliadas para o período de 2003 a 2007⁸. Após a seleção das variáveis para a composição da amostra, elas foram avaliadas de forma independente uma da outra, tratando-se, portanto, de um modelo de série temporal univariado.

Os dados do modelo técnico foram filtrados pela aplicação da transformada *wavelet*, com base no *toolbox* dessa aplicação no *software* Matlab®. Com isso, suavizam-se os componentes aleatórios da série, ou seja, das altas frequências presentes nos dados das séries avaliadas, uma vez que as altas frequências são de difícil compreensão e modelagem, pois podem estar relacionadas a especulações no mercado de ações, não possuindo lógica econômica ou temporal.

4.3 Predição

Com a seleção das variáveis do modelo fundamentalista e a filtragem das variáveis do modelo técnico foi construído um modelo de rede neural para realizar a previsão de p valores no futuro. Uma característica importante dos modelos de inteligência artificial, como RNAs, é que não existe na literatura uma estrutura de rede que forneça os melhores resultados para determinado tipo de variável estudada (Haykin, 2001). Portanto, são tentativas empíricas que permitem a escolha do melhor modelo de acordo com o objetivo de aplicação. Neste trabalho, foram avaliadas diversas estruturas de rede para os dados, alterando os diversos componentes que caracterizam o modelo, e será apresentada a estrutura de rede que mais se adequou à amostra avaliada. A tabela 1 resume as variáveis utilizadas para a construção do modelo de predição.

Tabela 1: Variáveis: modelo técnico e modelo fundamentalista

Modelo Fundamentalista	
<i>Variáveis Financeiras</i>	
Variável	Descrição
v_1	Valor de Mercado
v_2	Lucro Líquido
<i>Variáveis Macroeconômicas</i>	
v_3	Índice Ibovespa
v_4	Taxa de Juro
v_5	Taxa de Câmbio
v_6	Risco País
Modelo Técnico	
v_7	Preços Históricos das Ações

⁸ Os dados foram obtidos em: <<http://www.bovespa.com.br>>. Acesso em: 25/05/09.

Foi construído um modelo de rede neural recorrente multi-camadas. A camada de entrada é composta pelas variáveis fundamentalistas e pelos dados históricos dos preços das ações, após passarem pela filtragem *wavelet*. Portanto, o preço da ação das empresas avaliadas no futuro é explicado pela combinação das variáveis financeiras relacionadas a cada empresa, das variáveis macroeconômicas observadas no mercado e do próprio histórico de cotação das ações⁹. A camada intermediária é composta por 26 neurônios e finalmente a camada de saída possui um neurônio, que indica o preço no instante $t+1$, com base nos dados $t, t-1, \dots, t-n$.

A amostra total foi dividida em três conjuntos: treinamento, validação e teste. Característica básica na construção de um modelo de rede neuronal, essa divisão permite que a rede seja treinada com base no conjunto de treinamento, o erro, avaliado pelo conjunto validação e, finalmente, o conjunto denominado teste apresenta valores nunca vistos pela rede para avaliar seu grau de aprendizado e generalização. Os conjuntos treinamento, validação e teste possuem um total de 85%, 10% e 5% do total da amostra, respectivamente.

O treinamento da rede se deu com base no algoritmo de retropropagação do erro, ou *backpropagation*. O número de épocas foi estipulado em torno de 800¹⁰, para permitir um maior grau de generalização à rede e alcançar o menor valor para a função de erro E , apresentada na seção anterior. O nível de erro foi estipulado em torno de 10^{-4} , uma vez que são níveis de erro aceitáveis para um modelo de previsão de séries temporais, e permite que se obtenha um mínimo local da função de erro mais próximo do mínimo global.

4.4 Métrica de Erro

Para a avaliação da predição obtida pelo modelo proposto, foi utilizada a raiz quadrada da média do erro de predição quadrático (*Root-Mean-Square Error of Prediction, RMSEP*), obtida por:

$$RMSEP = \sqrt{\frac{1}{N} \sum_{t=1}^N (x(t) - \hat{x}(t))^2} \quad (12)$$

em que $x(t)$ é o valor da série temporal real no tempo t , $\hat{x}(t)$ é o valor predito pelo modelo e N o número de observações¹¹.

5. Resultados

Na suavização da componente aleatória das séries avaliadas, por meio da transformada *wavelet*, os resultados mostraram que três níveis de decomposição foram suficientes. A utilização de níveis maiores que três distorceu o comportamento das séries. Com as séries suavizadas, a aplicação do teste SRCC estabeleceu a adição das variáveis fundamentalistas. A tabela 2 apresenta o resultado do teste de Serman assim como as variáveis selecionadas para cada modelo:

⁹ A amostra utilizada para composição da camada de entrada corresponde a uma só janela temporal: janeiro de 2003 a dezembro de 2007.

¹⁰ Uma época é definida como a realização dos dois passos do algoritmo *backpropagation*: apresentação dos dados de entrada, obtenção da primeira saída da rede, e posterior apresentação da primeira saída com os dados de entrada novamente à rede (retroalimentação).

¹¹ Todas as aplicações foram desenvolvidas no *software* Matlab®.

Tabela 2: Resultados teste SRCC para o modelo fundamentalista

	v_1	v_2	v_3	v_4	v_5	v_6	<i>Variáveis Seleccionadas</i>
<i>ItaúUnibanco</i>	0,18	0,16	0,18	0,13	0,04	0,01	$v_1, v_2, v_3, v_4,$
<i>Bradesco</i>	0,16	0,19	0,15	0,16	0,12	0,06	v_1, v_2, v_3, v_4, v_5
<i>Usiminas</i>	0,14	0,17	0,19	0,02	0,21	0,12	v_1, v_2, v_3, v_5, v_6
<i>Vale do Rio Doce</i>	0,12	0,18	0,16	0,01	0,16	0,02	v_1, v_2, v_3, v_5
<i>Gerdau</i>	0,17	0,12	0,19	0,07	0,19	0,04	v_1, v_2, v_3, v_5
<i>Petrobrás</i>	0,14	0,13	0,20	0,06	0,23	0,14	v_1, v_2, v_3, v_5, v_6

Os resultados na tabela 2 mostram que para cada empresa avaliada foi selecionado um conjunto de variáveis fundamentalistas, de acordo com características individuais. Vale ressaltar, entretanto, que as variáveis financeiras das empresas foram muito significativas, mostrando que são fontes fundamentais para explicar o comportamento dos preços das ações, visto que refletem na atitude dos agentes que operam no mercado de ações. Dessa forma, com as variáveis fundamentalistas selecionadas, elas foram apresentadas para o modelo de rede neural proposto juntamente com os dados históricos das ações. Para uma comparação, as séries foram previstas pelo modelo convencional de séries temporais, ARIMA, para evidenciar as diferenças entre esse modelo, técnico, e o modelo proposto pela combinação de modelo técnico e fundamentalista. A tabela 3 apresenta os resultados, com base na métrica de erro RMSEP.

Tabela 3: Comparação dos modelos de predição com base no RMSEP

	<i>ARIMA</i>	<i>Modelo Combinado</i>
<i>ItaúUnibanco</i>	$4,7 \cdot 10^{-1}$	$8,6 \cdot 10^{-2}$
<i>Bradesco</i>	$7,3 \cdot 10^{-1}$	$1,2 \cdot 10^{-1}$
<i>Usiminas</i>	$5,2 \cdot 10^{-1}$	$6,6 \cdot 10^{-2}$
<i>Vale do Rio Doce</i>	$9,8 \cdot 10^{-2}$	$2,7 \cdot 10^{-3}$
<i>Gerdau</i>	$8,4 \cdot 10^{-1}$	$3,6 \cdot 10^{-2}$
<i>Petrobrás</i>	$6,3 \cdot 10^{-1}$	$2,0 \cdot 10^{-2}$

Pela tabela 3 pode-se perceber que o modelo combinado apresentou os melhores resultados para a predição das séries avaliadas neste trabalho, por meio da verificação do baixo erro de previsão se comparado ao modelo ARIMA. Pelos resultados, nota-se que as chamadas informações fundamentalistas são essenciais para a explicação do comportamento e previsão das séries dos preços das ações estudadas. A discussão do modelo fundamentalista vem recebendo bastante atenção na área de predição por agentes econômicos e pela comunidade científica e, agora, pode ser discutida e implementada com técnicas de inteligência artificial, como as redes neurais, que, segundo a literatura e este trabalho, vêm apresentando melhores resultados para séries econômicas e financeiras se comparado com modelos convencionais de séries temporais.

6. Conclusão

Este trabalho propôs um modelo não linear de predição para o preço das ações do Banco ItaúUnibanco, Banco Bradesco, Usiminas, Companhia Vale do Rio Doce, Grupo

Gerdau e Petrobrás. Esse modelo se tratou de uma combinação entre análise fundamentalista e análise técnica com aplicações para um modelo de rede neural artificial. O modelo fundamentalista avaliou o poder de explicação de variáveis financeiras e macroeconômicas para o comportamento e predição dos preços das ações das empresas selecionadas. No modelo técnico, foi utilizada a série temporal com o histórico dos preços das ações, filtrado pela transformada *wavelet*, para suavizar os componentes aleatórios das séries. Dessa forma, foi proposto um modelo de rede neural recorrente para a predição dos preços futuros com base nos dois modelos empregados, utilizando as variáveis fundamentalistas e as variáveis da análise técnica filtradas.

Os resultados mostraram que a combinação entre análise técnica e análise fundamentalista explica acuradamente o comportamento e o preço futuro das ações estudadas, e é superior se comparada ao modelo de predição convencional de séries temporais, modelo ARIMA, baseado apenas na análise técnica. Sobretudo, foi confirmada a relevância do estudo de variáveis fundamentalistas para a predição de séries econômicas, e, além disso, apresentou sua aplicação para análise com modelos de inteligência artificial, o que pode permitir que gestores de investimento e agentes em geral possam obter melhores resultados em suas decisões com a utilização de modelos que mais se aproximam da realidade.

Trabalhos futuros podem constar a utilização e estudo de mais variáveis fundamentalistas, o aprimoramento da filtragem pela transformada *wavelet*, assim como na utilização de outras estruturas de rede neural com diferentes algoritmos de aprendizagem e, também, utilização de outras técnicas de inteligência artificial como a lógica *fuzzy*, por exemplo.

7. Referências

BOX, G.; JENKINS, G. Time series analysis, forecasting and control. *Rev. Ed. San Francisco: Holden Day*, 1976.

CANNOR, J. T.; MARTIN, R. D.; ATLAS, L. E. Recurrent neural networks and robust time series prediction. *IEEE Transactions on Neural Networks*, v.5, n.2, p.240, 1994.

DHATT, M. S.; KIM, Y. H.; MUKHERJI, S. Relations between stock returns and fundamental variables: Evidence from a segmented market. *Asia-Pacific Financial Markets*, v.6, p.221-233, 1999.

DONOHU, D. L. De-noising by soft-thresholding. *IEEE Transactions on Information Theory*, v.41, n.3, p.613-627, 1995.

FRYZLEWICZ, P. Z. *Wavelet Techniques for Time Series and Poisson Data*. Tese (Doutorado), University of Bristol, 2003.

GRÔPPO, G. S. Causabilidade das variáveis macroeconômicas sobre o ibovespa. Dissertação (Mestrado), Escola Superior de Agricultura Luiz de Queiroz – Universidade de São Paulo, Piracicaba, 2004.

GURGUL, H.; MESTEL, R.; CHLEICHER, C. Stock market reactions to dividend announcements: empirical evidence from the Australian stock markets. *Financial Markets and Portfolio Management*, v.17, n.3, p.332-350, 2003.

HARRISON, P.; STEVENS, C. Bayesian forecasting. *Journal of the Royal Statistical Society*, v.38, n.3, p.205-267, 1976.

HARVEY, A. C.; TODD, P. Forecasting economic time series with structural and box-jenkins models: a case study. *Journal of Business and Economic Statistics*, v.1, n.4, p.299-311, 1983.

HAYKIN, S. *Redes Neurais: Princípios e Práticas*. 2. ed. São Paulo: Bookman, 2001.

JAEGER, R. M. *Statistics: A Spectator Sport*. 2. ed. London: Sage Publications, 1990.

JAIN, I. *Recurrent Neural Networks: Design and Applications*. Departments of Physics and Computer Science and Information Systems American University Washington, D. C.: CRC Press, 2001.

JANG, G. S. An intelligent stock portfolio management system based on short-term trend predicting using dual-module neural networks. *International Conference on Artificial Neural Networks*, v.1, p.447-452, 1991.

KEDEM, B.; FOKIANOS, K. *Regression Models for Time Serie Analysis*. University of Maryland and Cyprus, John Wiley Sons, 2002.

KOLEN, J. *Exploring the Computational Capabilities of Recurrent Neural Networks*. Tese (Ph.d.), The Ohio State University, USA, 1994.

LAM, M. Neural networks techniques for financial performance prediction: integrating fundamental and technical analysis. *Decision Supporting Systems*, v.37, n.4, p.567-581.

LAMEIRA, V. J. *Negócios em Bolsa de Valores: Estratégias para Investimentos*. São Paulo: Alaúde, 2003.

MCCABE, B. P. M.; TREMAYNE, A. R. Testing a time series for different stationarity. *The Annals of Statistics*, v.23, n.3, p.1015-1028.

MATSUBA, I. Neural sequential associator and its applications to stock price predictions. *IECON*, v.91, n.2, p.1476-1479, 1991.

MURPHY, J. J. *Intermarket Technical Analysis*. New York: John Wiley Sons, 1991.

NAGANO, M. S.; MERLO, E. M.; da SILVA, M. C. The fundamental variables and yours impacts in scripts return tax in Brazil. *FAE*, v.6, n.2, p.13-28, 2003.

RACINE, J. On the nonlinear predictability of stock returns using financial and economic variables. *Journal of Business and Economics Statistics*, v.19, n.3, p.380-382, 2001.

RUMELHART, D. E.; MCCLELLAND, J. L. *Parallel Distributed Processing*. Volume 1. The MIT Press, 1986.

RENAUD, O.; STARCK, J.; MURTAGH, F. Wavelet-based combined signal filtering and prediction. *IEEE Transaction on Systems, Man and Cybernetics*, v.25, n.6, p.1241-1251, 2005.

RUSSELL, S. J.; NORVIG, P. *Artificial Intelligence: a modern approach*. New jersey: Prentice Hall, 1995).

WEIGEND, A. S.; HUBERMAN, B. A.; RUMELHART, D. E. Predicting the future a connectionist approach. *International Journal of Neural Systems*, v.1, p.193-209, 1990.