

A utilização de Redes Neurais Artificiais para previsibilidade de retornos: uma comparação com os modelos lineares CAPM e Três Fatores.

CLAUDIO PILAR DA SILVA JUNIOR

Universidade Federal da Paraíba - UFPB
claudiopilar.adm@gmail.com

MÁRCIO ANDRÉ VERAS MACHADO

Universidade Federal da Paraíba - UFPB
mavmachado@hotmail.com

Área Temática: Finanças

A utilização de Redes Neurais Artificiais para previsibilidade de retornos: uma comparação com os modelos lineares CAPM e Três Fatores.

RESUMO

Este artigo teve por objetivo verificar se a utilização do modelo de Redes Neurais Artificiais (RNA) possibilita a obtenção de melhores previsões para os investidores, possibilitando, assim, o aumento de suas riquezas. Em virtude dos resultados da aplicação das redes neurais artificiais em mercado internacional e sua capacidade de aprendizagem e adaptação, tornou-se relevante questionar: como se comporta a previsão de retornos por meio da RNA, no mercado acionário brasileiro, comparativamente ao CAPM e ao modelo de três fatores de Fama e French? Para atingir o objetivo e responder o problema de pesquisa, comparou-se o modelo estatístico de redes neurais artificiais com os modelos lineares CAPM e Três Fatores de Fama e French (1993) para previsão de retornos no mercado acionário brasileiro. Adicionalmente, para testar as hipóteses de pesquisa da previsibilidade do preço das ações, utilizaram-se quatro modelos econométricos. Foram analisados, em média, por ano, os dados de 176 ações. Como resultado principal, constatou-se que o modelo de previsão baseada em redes neurais artificiais não aumentou as chances para os investidores predizerem os preços com maior acurácia pela redução do erro. Adicionalmente, verificou-se que o seu desempenho foi semelhante ao do modelo três Fatores de Fama e French.

Palavras-chave: Modelos Econométricos. Redes Neurais Artificiais. CAPM.

ABSTRACT

This article aimed to verify whether the use of Artificial Neural Networks (ANN) model allows to obtain better forecasts to investors, thus allowing for the increase of their wealth. Given the results of the application of artificial neural networks in the international market and their ability to learn and adapt, it became important to question: how behaves predicting returns by RNA, the Brazilian stock market, compared to the CAPM model and the three factors of Fama and French? To achieve the goal and answer the research problem, we compared the statistical model of artificial neural networks with linear models CAPM and Three Factor Fama and French (1993) to forecast returns in the Brazilian stock market. Additionally, to test the research hypotheses predictability of stock price, using four econometric models. On average per year, the data were analyzed for 176 shares. As a main result, it was found that the forecast model based on artificial neural networks did not increase the chances for investors to predict prices with higher accuracy by reducing error. Additionally, it was found that their performance was similar to model three factors Fame and French.

Keywords: Econometric models. Artificial Neural Networks. CAPM.

1 INTRODUÇÃO

A previsibilidade do preço das ações (e, conseqüentemente, o seu retorno) é um dos assuntos mais importantes na área de finanças e negócios (ADEBIYI, 2012). Tal importância é decorrente da busca contínua do investidor “bater o mercado”, ou seja, obter um retorno maior do que o proporcionado pelo mercado (REFENES, 1995).

Diferentes métodos são utilizados pelos investidores, seja para diminuir a incerteza associada aos investimentos (risco), seja para proporcionar um aumento dos retornos, dentro os quais se destacam: análise técnica, análise fundamentalista, estudos de eventos, modelos de precificação.

Com o aprimoramento dos métodos computacionais na última década, as redes neurais artificiais têm sido amplamente utilizadas no campo de negócios, finanças e economia para previsibilidade de séries, bem como mensuração de desempenho (AVCI, 2007). A Rede Neural Artificial (RNA) consiste em uma ferramenta de aquisição de conhecimento projetada para imitar a aquisição de conhecimento e habilidades organizacionais do cérebro humano. Essa rede é instruída por dados de amostras presentes como *inputs* e por variação de fatores ponderados no algoritmo que determina os estados de saídas correspondentes (CAO; LEGGIO; SCHNIEDERJANS, 2005).

Em virtude da sua habilidade de aprender e detectar relações entre variáveis não lineares, de poder analisar em profundidade um amplo conjunto de dados, em especial aqueles que tendem a flutuar em um curto período de tempo, as redes neurais artificiais estão sendo amplamente utilizada na previsibilidade de preços das ações em âmbito internacional (CAO *et. al.*, 2005).

Entretanto, poucos estudos realizados na área de finanças no Brasil utilizaram o método de redes neurais para a avaliação de previsibilidade do modelo (PORTUGAL, 1995; CAVALHEIRO *et. al.*, 2010; CAVALHEIRO; VIEIRA; CERETTA, 2011), bem como fizeram uma comparação dessa técnica com outros métodos já utilizados e consolidados na avaliação de investimentos, como o *Capital Asset Pricing Model* - CAPM e o modelo de três Fatores de Fama e French (1993).

Ademais, em âmbito internacional, diversos estudos lidam exclusivamente com a comparação do desempenho de previsibilidade dos modelos RNA com outros modelos lineares ou não lineares. Contudo, os resultados empíricos na literatura fornecem resultados variados para o desempenho das RNA, onde em, alguns estudos, observa-se a superioridade desse modelo (GENCAY, 1996; OLSON; MOSSMAN, 2003; CAO *et. al.*, 2005; CAO; PARRY; LEGGIO, 2011) e, em outros, não é observada nenhuma superioridade (MAASSOUMI; RACINE, 2002; PÉREZ-RODRIGUES; TORRA; ANDRADA-FÉLIX, 2005).

Adicionalmente, observam-se poucos estudos na literatura sobre o valor das redes neurais na previsibilidade das ações em mercados emergentes (CAO *et. al.*, 2005). Aliado a isso, evidências indicam que o retorno de ações, em mercados emergentes, é influenciado de forma diferente em relação aos retornos de ações em mercados desenvolvidos. Por exemplo, Harvey (1995) observou que informações locais são bastante significativas na explicação dos retornos das ações. Analisando 20 mercados emergentes, dentre eles o Brasil, verificou que os mercados emergentes eram menores, possuíam maiores retornos e maior volatilidade em relação aos mercados desenvolvidos. Ademais, constatou que a previsibilidade dos retornos em mercados emergentes era superior aos dos mercados desenvolvidos, onde mais da metade da previsibilidade dos retornos era explicada por informações locais como a taxa de juros, o retorno em dólares e o *dividend yield*. Adicionalmente, Bekaert, Harvey e Lundblad (2007) verificaram que a liquidez do mercado de ações local é um importante fator na expectativa de retornos em mercados emergentes. Bhattacharya *et. al.* (2000) concluíram que a diferença

entre o mercado emergente e o desenvolvido poderá ser decorrente da presença de *insider trading*.

Assim, em virtude dos resultados da aplicação das redes neurais artificiais em mercado internacional e sua capacidade de aprendizagem e adaptação, torna-se relevante questionar: como se comporta a previsão de retornos por meio da RNA, no mercado acionário brasileiro, comparativamente ao CAPM e ao modelo de três fatores de Fama e French?

De maneira objetiva, a utilização de um método que proporcione maior segurança aos investidores será preferível a aquele de menor acurácia. Nesse sentido, o presente artigo procura aplicar e comparar o modelo estatístico de redes neurais com os modelos lineares CAPM e três fatores de Fama e French (1993) para previsão de retornos no mercado acionário brasileiro e tem por objetivo verificar se esse modelo possibilita a obtenção de melhores previsões para os investidores, possibilitando o aumento de suas riquezas.

Além desta, o presente artigo possui cinco partes. Na seguinte, apresenta-se o referencial teórico, onde serão abordadas as pesquisas utilizadas na área financeira para lidar com questões relacionadas à previsibilidade de índices, ações. Na terceira parte, abordar-se a metodologia. Na quarta, os resultados da pesquisa. Na quinta, a conclusão. E, por fim, a bibliografia.

2 REVISÃO DA LITERATURA

A teoria da eficiência de mercado pressupõe que os preços correntes de mercado refletem todas as informações disponíveis, fornecendo sinais adequados para a alocação de recursos. Dessa maneira, a hipótese de mercado eficiente implica aos investidores que as informações são totalmente refletidas nos preços, sendo assim, os investidores só devem esperar obter uma taxa normal de retorno, impossibilitando ganhos extraordinários com o uso das informações disponíveis (FAMA, 1970).

Entretanto, considerado como um mercado em expansão, o mercado acionário brasileiro possui características próprias e diferentes daquelas observadas nos mercados desenvolvidos, que poderão influenciar no comportamento e na previsibilidade dos preços de suas ações (FERSON; HARVEY, 1993; HARVEY, 1995), possibilitando um comportamento ineficiente do mercado. Nesse sentido, os *traders* procuram identificar essas ineficiências e explorá-las antes que sejam corrigidas pelo mercado. Em virtude disso, a utilização de novos métodos quantitativos que possibilitem um maior nível de acurácia é constantemente objeto de pesquisa pelos *traders* e pesquisadores (CAO *et.al.*, 2005, DASE; PAWAR; DASPUTE, 2011).

O modelo tradicional utilizado na explicação dos retornos das ações, o CAPM, desenvolvido por Sharpe (1964), Lintner (1965) e Black (1972), presume que o retorno sobre qualquer ativo de risco é uma relação linear de fatores comuns. Adicionalmente, vale ressaltar que a eficiência da carteira de mercado e o CAPM são hipóteses conjuntas e inseparáveis, não se podendo testar a validade de um sem o outro (COPELAND; WESTON; SHASTRI, 2005).

Entretanto, nas últimas décadas, evidências de anomalias colocaram em xeque a validade da hipótese conjunta. Basu (1977; 1983) demonstrou as ineficiências do modelo CAPM e, devido ao problema de hipótese conjunta, também a ineficiência do mercado. Ball (1978) verificou que os retornos das ações estavam relacionados ao anúncio dos lucros, podendo ser mensurável pelo rendimento dos dividendos ou pelo índice preço-lucro. Stattman (1980), Rosenberg, Reid e Lanstein (1985) e Chan, Hamao e Lakonishok (1991) documentaram que empresas com alto índice *book-to-market* apresentam retorno superior ao apresentado pelo beta, caracterizando-o como efeito valor. Banz (1981) encontrou que a variável tamanho (valor de mercado) possui uma relação inversa com o retorno esperado.

Nesse sentido, após o desenvolvimento do CAPM, inúmeros estudos procuraram testar a previsibilidade dos retornos das ações, por meio da utilização de modelos de um único fator, multifatoriais (FAMA; FRECH, 1992, 1993; CAHART, 1997; KEENE; PETERSON, 2007), análise técnica, análise fundamentalista, teoria do caos, utilização de técnicas com base computacional (DASE *et. al.*, 2011).

Dessa forma, há uma enorme variedade de metodologias na literatura que tem sido utilizadas para *forecasting*. No Brasil, por exemplo, Rambalducci *et. al.* (2003) buscaram verificar o poder de previsibilidade do CAPM para ações do setor de alimentos e bebidas participantes do índice Bovespa, no período de 1995 a 2001. Os seus resultados demonstraram uma relação não esperada entre risco e retorno, conforme defendido pelo CAPM, indicando a não validade do modelo. Adicionalmente, Rostagno *et. al.* (2004) constataram que, utilizando o modelo de fator de retorno esperado, foi possível prever o retorno das ações negociadas na Bovespa e assim formar *portfólios* com retornos acima da média e estatisticamente significantes.

Em relação as RNA, nos últimos anos, as mesmas têm sido popularmente utilizadas na área financeira para lidar com questões relacionadas à previsibilidade de índices, ações, previsibilidade de falência e classificação de títulos (EGELI *et. al.*, 2003). Por exemplo, Mirzamohamadi e Mansouri (2013) investigaram a previsibilidade da lucratividade das empresas entrantes no mercado acionário do Irã com a utilização dos modelos OLS e RNA. Constataram a validade de ambos os modelos para previsibilidade, entretanto, o modelo RNA apresentou uma maior concordância entre o previsto e os dados reais do que o modelo OLS.

Adicionalmente, estudos verificaram que a RNA é uma ferramenta poderosa para a previsibilidade dos retornos das ações (AVCI, 2007). O primeiro estudo significativo de aplicação de modelos de redes neurais para previsibilidade do mercado de ações foi desenvolvido por White (1988). No decorrer dos anos, estudos em diferentes mercados demonstraram que a RNA é uma importante ferramenta para a descoberta de padrões no mercado financeiro, que podem então ser utilizados para a previsibilidade do movimento futuro dos preços (CAO *et. al.*, 2005).

O diferencial do modelo RNA para a utilização na previsibilidade dos preços do mercado de ações é a sua habilidade de aprender e detectar relações entre variáveis não lineares em comparação com as demais técnicas (DASE *et. al.*, 2011). Nesse sentido, o usuário do método de redes neurais não precisa conhecer a relação funcional existente entre a variável dependente e as independentes (DABERLAY; SLAMA, 2000).

Chen, Leung e Daouk (2003) tentaram prever o retorno do índice de mercado da bolsa de ações de Taiwan, utilizando redes neurais. Para verificar o desempenho das redes neurais, o modelo utilizado foi comparado com o método dos momentos generalizados. Seus achados sugerem que a utilização das redes neurais é uma ferramenta importante na previsibilidade dos retornos em comparação à previsão do modelo GMM. No mercado de ações canadense, Olson e Mossman (2003) realizaram a comparação da utilização da RNA com a previsibilidade dos modelos OLS e de regressão logística na estimação e classificação do retorno esperado das empresas estudadas, encontrando também a superioridade das redes neurais.

Cao *et. al.* (2005) realizaram uma comparação entre os principais modelos lineares utilizados para previsão (CAPM e três fatores de Fama e French (1993)) e as redes neurais artificiais, com o intuito de verificar a acurácia da previsibilidade dos modelos no mercado acionário chinês. Seus resultados demonstraram a superioridade das redes neurais na previsibilidade do preço das ações. Adicionalmente, Cao *et. al.* (2011) fizeram um novo estudo no mercado chinês de comparação de previsibilidade dos modelos lineares, utilizando modelos ARIMA e as redes neurais. Novamente, os resultados demonstraram que a utilização de redes neurais melhora significativamente o poder de acurácia de previsibilidade em relação

aos modelos lineares. Adicionalmente, constatou-se que não houve diferença estatisticamente significativa entre a previsibilidade do modelo CAPM e do de três fatores.

Kara, Boyacioglu e Bayakan (2011) compararam a utilização da RNA e do modelo de aprendizagem SVM (*Support Vector Machines*) na previsibilidade da direção diária do índice da bolsa de valores de Istanbul, no período de 1997 a 2007. Baseando-se em seus resultados, pode-se dizer que ambos os modelos apresentaram desempenho significativo na previsão da direção do índice. Contudo, o desempenho médio da RNA foi superior ao do modelo SVM.

No Brasil, Carvalho *et. al.* (2010) compararam a previsibilidade do índice Ibovespa e do S&P500 com a utilização de redes neurais polinomiais GMDH, no período de 2000 a 2009. O trabalho apresentou resultados significativos na previsão do índice Ibovespa, fato este que pode ser atribuído à menor volatilidade do índice e da menor maturidade do mercado de capitais brasileiro.

Todavia, não se observam estudos no mercado acionário brasileiro que tratem da validade do modelo RNA por meio da comparação dos seus resultados com resultados de modelos já amplamente utilizados. Nesse sentido, o presente artigo busca aplicar o modelo RNA na previsibilidade do retorno no mercado acionário brasileiro e também comparar os seus resultados com os modelos lineares CAPM e três fatores de Fama e French (1993).

Diante do exposto, serão testadas quatro hipóteses de pesquisa:

H₁: Há diferença de previsibilidade entre os modelos lineares (CAPM e três fatores).

H₂: Há diferença de previsibilidade entre os modelos não lineares (RNA e RNAM).

H₃: Não há diferença na previsibilidade dos modelos lineares e não lineares univariado (CAPM e RNA).

H₄: Não há diferença na previsibilidade dos modelos lineares e não lineares multivariados (três fatores e RNAM).

Para testar as hipóteses de pesquisa, foram utilizados quatro modelos econométricos. Especificamente, construíram-se dois modelos lineares (CAPM e três Fatores) e dois modelos não lineares (RNA). Os modelos foram estimados de Julho de 1997 à Junho de 2012 e então se realizou a previsão dos retornos do período de Julho de 2012 à Junho de 2013. Os dados e metodologia, bem como os quatro modelos utilizados, são definidos a seguir.

3 METODOLOGIA

3.1 Dados e Metodologia

Os dados analisados consistiram de todas as ações de empresas listadas na BM&FBOVESPA entre 1º de Junho de 1996 a 31 de Junho de 2013. Esse período foi escolhido devido à estabilidade da economia brasileira pós Plano Real. Entretanto, para garantir a homogeneidade da população, foram excluídas as empresas do setor financeiro, devido ao seu alto grau de endividamento (FAMA; FRENCH, 1993). Também foram excluídos os dados das empresas que: 1) não apresentaram cotações mensais consecutivas por 24 meses, sendo 12 meses anteriores à data de formação das carteiras e 12 posteriores ao mês de formação das carteiras. Os 12 meses anteriores foram necessários para o cálculo do fator momento e os 12 meses posteriores para o cálculo do retorno das ações, que serviram de base para a obtenção dos prêmios dos fatores de risco e dos retornos das carteiras; 2) que não apresentaram valor de mercado em 31 de dezembro e em 30 de junho de cada ano; 3) que não apresentaram patrimônio líquido positivo em 31 de dezembro de cada ano.

Os dados necessários para a pesquisa foram extraídos do banco de dados da Economática. Para as empresas que possuíam ações de classe ON e PN, o valor de mercado foi calculado pelo somatório das duas classes de ações quando presentes na amostra (MACHADO; MEDEIROS, 2011). Caso constasse apenas um tipo de ação, considerou-se o

valor de mercado da classe constante na amostra. Dessa maneira, foram analisados, por ano, os dados de 176 ações em média (44,67% da população).

Para o desenvolvimento do estudo, optou-se pela formação de *portfólios*, pois, por meio dessa metodologia, se obtêm estimativas mais precisas, além de resolver o problema de não independência dos resíduos sobre o erro padrão na análise de dados longitudinais, proporcionando diversos benefícios, conforme destacado por Black, Jensen e Scholes (1972), Blume e Friend (1973), Fama e French (1993) e Vaihekoski (2004), quais sejam:

- menor erro de mensuração para o seu beta estimado;
- a variância dos erros dos betas dos *portfólios* são significativamente menores;
- os retornos reais dos *portfólios* tenderão a ser menos afetados pelas flutuações dos ativos individuais; e
- a utilização de *portfólios* fornece uma maneira conveniente de ajustes para ativos não incluídos.

Foram construídas 18 carteiras com base na metodologia de Fama e French (1993), onde ao final de junho de cada ano t 1) todas as ações da amostra foram ordenadas de forma crescente pelo seu valor de mercado e, em seguida, essas ações foram divididas em três grupos: 30% inferior (*Small*), 40% médio (neutro) e 30% superior (*Big*); 2) no mesmo período, todas as ações foram reordenadas de forma crescente, em cada grupo, de acordo com o índice B/M das empresas que representam e, em seguida, essas ações foram divididas em três grupos: 30% inferior (*Low*), 40% médio (neutro) e 30% superior (*High*); 3) ainda junho de cada ano t , após as duas ordenações anteriores, as ações foram reordenadas de forma crescente pelos seus retornos históricos acumulados e pelo valor mediano dividido em dois grupos, contendo as empresas com os melhores (*Winners*) e piores (*Losers*) retornos históricos acumulados; 4) Por fim, em junho de cada ano t , após as três ordenações anteriores, foram construídas 18 carteiras, decorrentes da intersecção dos diversos grupos.

Todos os retornos foram calculados mensalmente, de julho do ano t a junho do ano $t + 1$, de forma contínua, ou seja, por meio do seu logaritmo natural. Para o cálculo do retorno mensal de cada uma das 18 carteiras, utilizou-se o processo de ponderação, pelo valor de mercado da ação em relação ao valor de mercado da carteira, dos retornos das ações que as compõem. Como *proxy* para a taxa de retorno livre de risco, foi utilizado o retorno mensal da Selic. Para o cálculo do prêmio do fator de risco *tamanho*, utilizou-se a diferença entre a média dos retornos mensais das carteiras *Small* e a média dos retornos mensais das carteiras *Big* e para o fator de risco *book-to-market* (B/M), através da diferença entre a média dos retornos mensais das carteiras *High* e a média dos retornos mensais das carteiras *Low*.

3.2 Descrições dos Modelos

3.2.1 Modelos Lineares

Modelo 1: CAPM: Conhecido também como modelo de fator único, o CAPM presume que o retorno sobre qualquer ativo de risco é uma relação linear de fatores comuns. Apesar de limitar sua aplicação a apenas um fator de risco, o CAPM fornece uma previsão precisa do relacionamento que se deve observar entre o risco de um ativo e seu retorno esperado, proporcionando uma medida quantificável do risco. Estabelecendo hipóteses simplificadoras, o modelo fundamenta que o retorno esperado de um ativo varia direta e linearmente com o beta do título, conforme a Equação 1:

$$E(R_i) = R_f + \beta_i \times [E(R_m) - R_f] + \varepsilon_i \quad (1)$$

Onde: R_i – retorno de um ativo; R_f – Taxa livre de risco; B_i – beta do ativo; $(R_m - R_f)$ – prêmio pelo risco, corresponde à diferença entre o retorno da carteira de mercado e a taxa livre de risco. ε_i = resíduo do modelo referente à carteira i no mês t .

Modelo 2: Três Fatores de Fama e French (1993): Fama e French (1993) desenvolveram o modelo de três fatores para previsibilidade do retorno das ações com a utilização de três fatores de risco: o beta de mercado, conforme CAPM, o fator tamanho, representado pela diferença mensal entre o retorno médio da carteira formada por empresas pequenas menos o retorno médio das formadas por empresas grandes (*small minus big* – SMB), e o efeito valor, representado pela diferença entre o retorno médio das carteiras formadas pelas empresas com alto índice B/M menos o retorno médio das formadas com baixo índice (*high minus low* – HML), formando um modelo multifatorial linear de três fatores, conforme a Equação 2:

$$E(R_{it}) - R_f = \alpha + \beta_i [E(R_m) - R_f] + s_i (SMB) + h_i (HML) + \varepsilon_i \quad (2)$$

Onde: R_{it} = Retorno da carteira i no mês t ; $R_m - R_f$ = Prêmio pelo fator de risco mercado no mês t ; SMB = prêmio pelo fator de risco tamanho no mês t ; HML : prêmio pelo fator de risco B/M no mês t ; ε_i = resíduo do modelo referente a carteira i no mês t .

3.2.2 Modelos Não Lineares

Existem diversos modelos de redes neurais. As RNA consistem em um método de previsão de séries de tempo que imitam as características e propriedades cognitivas do cérebro humano, sendo eficazes no reconhecimento de padrões e regularidades, tornando o conhecimento disponível para uso (PORTUGAL; FERNANDES, 1996; CAO *et. al.*, 2005). Um dos principais modelos utilizados de RNA em séries de tempo financeiras são as redes Perceptrons Multi-Camadas (*Multi Layer Perceptron* – MLP), conforme Figura 1.

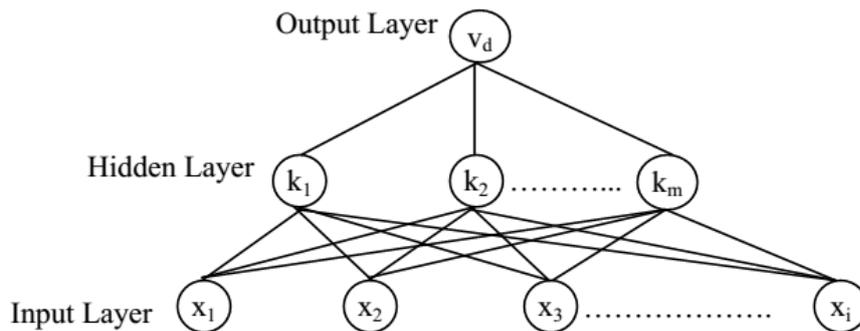


Figura 1. Redes Perceptrons Multi-Camadas (Feed-Foward)

Fonte: AVCI (2007)

O design de um modelo MLP pode ser visualizado na Figura 1. A rede é composta por três camadas: uma camada de entrada (*Input Layer*) composta por N unidades de processamento x_i ($i = 1, 2, \dots, N$); uma camada intermediária (*Hidden Layer*), onde uma função de ativação mapeia os neurônios de entrada para um intervalo pré-especificado de saída. Na camada intermediária, cada neurônio realiza uma soma ponderada dos *inputs*, que então passam por uma função não linear de ativação, que é responsável por informar os erros cometidos pela rede para as camadas anteriores com o máximo de previsão possível. Neste artigo, conforme recomendações de diferentes estudos, o número de neurônios na camada intermediária foi igual ao número de *inputs* do modelo (MACIEL; BALLINI, 2009;

KARSOLYIA, 2012). A ponderação e função de ativação dos neurônios são apresentadas nas Equações 3 e 4, respectivamente:

$$S_i = \sum_{j=0}^u w_{ij} * u_j \quad (3)$$

$$u_i = f(S_i), \text{ onde } f(x) = \frac{1}{(1 + e^{-x})} \quad (4)$$

Onde: w = ponderação e u a unidade de processamento.

Por fim, a última camada é a de saída com os *outputs* (*Output Layer*), formada por outra soma ponderada dos *outputs* dos neurônios da camada intermediária. Observa-se na Figura 1 que existe apenas um *output*, porém sua quantidade poderá variar com o número de respostas em questão. O *output* de uma rede MLP é dado conforme Equação 5:

$$y_t = f \left[(X, a, b) = \sum_{j=1}^n a_j \log \text{sig} \left(\sum_{i=1}^k b_{ij} x_i + b_{0j} \right) \right] \quad (5)$$

Onde y_t = output da rede; X= vetor de variáveis independentes; x_i = *ith input*, n= numero de unidades na camada intermediária; k= número de *inputs*; a= vetor de ponderações da camada intermediária; b= matriz de coeficientes de *input* da camada intermediária.

O modelo RNA têm similaridades com os modelos de regressão. Nas RNA, as variáveis independentes podem ser vistas como os *inputs* da camada de entrada, enquanto que a variável dependente é representada pelo output da rede (PORTUGAL; FERNANDES, 1996). Assim, utilizaram-se dois modelos não lineares: um univariado com apenas um *input* (beta) e outro multivariado com três *inputs* (beta, SMB e HML).

3.3 Procedimentos para avaliação da previsibilidade dos modelos

Tendo em vista que tanto nos modelos de regressão, quanto na estimação das RNA, busca-se a minimização da função erro médio quadrado, ou qualquer outra função objetivo escolhida (PORTUGAL; FERNANDES, 1996), são utilizadas três medidas de erro para mensurar a acurácia na previsibilidade dos modelos, conforme Equações 6 a 8:

$$\text{Desvio Médio Absoluto (MAD)} = \frac{1}{N-n} \sum_{t=n+1}^N |y_t - \hat{y}_t| \quad (6)$$

$$\text{Erro Percentual Médio Absoluto (MAPE)} = \frac{1}{N-n} \sum_{t=n+1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (7)$$

$$\text{Erro Quadrado Médio (MSE)} = \frac{1}{N-n} \sum_{t=n+1}^N \left(\frac{y_t - \hat{y}_t}{y_t} \right)^2 \quad (8)$$

Onde n é o número de observações utilizadas na estimação; N é o número total de observações e \hat{y}_t é o valor previsto do retorno das ações para o período t .

O MAD e o MSE são medidas mais comumente utilizadas para previsibilidade de erros, pois calculam o desvio total entre o valor previsto e o real. Já o MAPE é uma medida alternativa que mensura a acurácia do modelo em termos percentuais, o que facilita o seu entendimento. Ademais, vale ressaltar que o Erro Quadrado Médio (MSE) é a medida mais relevante para comparação dos modelos, pois está relacionada à variação padrão dos erros de previsão (SILVER et. al., 1998 *apud* WALLSTROM; SEGERSTEDT, 2010).

4 RESULTADOS

A análise da previsibilidade dos modelos foi realizada por meio da aplicação dos modelos propostos, realizando-se a estimação dos modelos de Julho de 1997 à Junho de 2012

e então se projetando a previsão dos retornos do período de Julho de 2012 à Junho de 2013. Os dados foram estimados utilizando o software R. A Tabela 1 apresenta a comparação das medidas de acurácia para os quatro modelos de previsão utilizados, onde o menor valor para o indicador é considerado o melhor.

Inicialmente, conforme pode ser observado na Tabela 1, analisando-se o poder de previsibilidade dos modelos lineares, observa-se que, nas carteiras S/L/WIN, M/H/WIN, M/L/LOS e M/L/WIN, o modelo CAPM apresentou a melhor previsibilidade do retorno para as carteiras. Por outro lado, nas carteiras B/H/LOS, B/L/LOS, S/H/LOS, S/H/WIN, S/L/LOS, S/M/LOS, S/M/WIN, M/H/LOS, M/M/LOS e M/M/WIN, as medidas de erro médio quadrado são menores para o modelo de três Fatores de Fama e French. Nas demais carteiras, as previsões apresentaram resultados iguais, em virtude da não significância das variáveis SMB e HML. Nesse sentido, observa-se uma superioridade do modelo de três Fatores de Fama e French na previsibilidade dos retornos, comparativamente ao modelo CAPM, dando indícios da validade da Hipótese 1. Ademais, observa-se resultado semelhante nas demais medidas de erro, porém vale ressaltar que esse resultado nas três medidas não é uma constante, pois as medidas de erro MAD e MAPE têm o seu valor influenciado por valores extremos.

Tabela 1. Comparativo das medidas de erro

Carteira	MSE				MAD				MAPE			
	CAPM	FF	RNA	RNAM	CAPM	FF	RNA	RNAM	CAPM	FF	RNA	RNAM
B/H/LOS	0,0053	0,0047	0,0103	0,0047	0,065	0,059	0,079	0,060	211,833	187,177	100,352	175,224
B/H/WIN	0,0009	0,0009	0,0050	0,0010	0,022	0,023	0,061	0,025	70,082	57,336	105,093	63,474
B/L/LOS	0,0008	0,0006	0,0055	0,0012	0,025	0,021	0,064	0,029	64,302	56,007	99,983	51,543
B/L/WIN	0,0013	0,0016	0,0050	0,0016	0,032	0,036	0,052	0,036	130,647	134,755	153,771	136,890
B/M/LOS	0,0014	0,0014	0,0083	0,0014	0,031	0,031	0,070	0,032	82,342	82,342	99,368	84,127
B/M/WIN	0,0005	0,0005	0,0043	0,0004	0,016	0,017	0,053	0,017	336,283	350,883	536,020	335,205
S/H/LOS	0,0050	0,0038	0,0099	0,0038	0,057	0,049	0,078	0,049	171,386	165,708	100,407	169,577
S/H/WIN	0,0041	0,0032	0,0080	0,0032	0,055	0,046	0,075	0,047	126,825	176,324	132,130	192,164
S/L/LOS	0,0071	0,0035	0,0153	0,0036	0,064	0,048	0,101	0,043	97,995	78,638	114,894	79,171
S/L/WIN	0,0016	0,0017	0,0090	0,0015	0,032	0,035	0,077	0,034	485,757	461,548	675,348	501,566
S/M/LOS	0,0054	0,0035	0,0145	0,0036	0,060	0,047	0,093	0,049	82,880	63,204	93,021	64,928
S/M/WIN	0,0029	0,0023	0,0080	0,0023	0,039	0,034	0,061	0,034	99,387	109,043	116,408	108,946
M/H/LOS	0,0035	0,0033	0,0097	0,0033	0,043	0,047	0,083	0,047	91,855	168,892	109,860	168,654
M/H/WIN	0,0008	0,0012	0,0046	0,0012	0,024	0,031	0,055	0,031	379,964	381,060	198,069	380,580
M/L/LOS	0,0013	0,0014	0,0086	0,0014	0,028	0,031	0,074	0,033	54,452	61,204	108,419	72,608
M/L/WIN	0,0007	0,0008	0,0059	0,0008	0,024	0,023	0,059	0,021	78,586	87,801	114,213	81,922
M/M/LOS	0,0010	0,0008	0,0073	0,0011	0,027	0,021	0,068	0,025	56,876	55,045	80,131	62,702
M/M/WIN	0,0015	0,0011	0,0052	0,0010	0,028	0,025	0,056	0,025	45,034	56,054	72,798	56,017
Média	0,0025	0,0020	0,008	0,0021	0,0373	0,0347	0,0699	0,0354	148,138	151,834	167,238	154,739

Adicionalmente, comparando-se a previsibilidade dos modelos não lineares, observa-se que o modelo multifatorial RNA apresentou melhor previsibilidade em todas as carteiras, dando indícios de diferença de previsibilidade entre os modelos não lineares, conforme Hipótese 2. Novamente, na avaliação dos métodos de previsão, os resultados são consistentes: o modelo de três fatores é preferível ao modelo CAPM na previsibilidade dos retornos tanto no modelo linear, quanto no modelo de redes neurais. Em geral, observa-se que os modelos três fatores de Fama e French e RNAM apresentaram boa previsibilidade dos retornos na

maioria das carteiras, não se podendo chegar a um consenso do melhor modelo para o período em estudo, pois a previsibilidade média de ambos os modelos é bastante próxima.

Em virtude dos resultados da análise dos erros e para fornecer um resultado de comparação mais formal entre os modelos e possivelmente indicar um melhor modelo de previsão, realizou-se o teste de *Wilcoxon* para amostras pareadas para os modelos estudados. Os resultados são apresentados na Tabela 2.

Tabela 2 – Comparação entre previsibilidade dos modelos univariado e multifatoriais.

Análise	Carteira	MSE	MAD	MAPE	Carteiras	MSE	MAD	MAPE
Hipótese 1	B/H/LOS	-1,020	-1,020	-0,706	S/L/WIN	-0,157	-0,392	-0,392
	B/H/WIN	-0,157	-0,314	-0,549	S/M/LOS	-2,040**	-2,040**	-1,255
	B/L/LOS	-0,863	-1,098	-0,941	S/M/WIN	-0,784	-0,392	-0,235
	B/L/WIN	-1,177	-1,177	-0,471	M/H/LOS	-0,941	-1,177	-1,412
	B/M/LOS	0,000	0,000	0,000	M/H/WIN	-1,334	-1,255	-0,471
	B/M/WIN	-0,392	-0,941	-0,392	M/L/LOS	-0,314	-0,078	-0,314
	S/H/LOS	-1,020	-1,177	-0,471	M/L/WIN	-0,078	-0,314	-0,471
	S/H/WIN	-1,177	-1,490	-0,706	M/M/LOS	-0,706	-1,412	-0,392
	S/L/LOS	-2,275**	-2,197**	-1,726***	M/M/WIN	0,000	-0,235	-0,549
Hipótese 2	B/H/LOS	-1,098	-0,314	-0,863	S/L/WIN	-1,647***	-1,569	-1,569
	B/H/WIN	-2,197**	-2,197**	-2,275**	S/M/LOS	-2,510**	-2,353**	-1,569
	B/L/LOS	-2,667*	-2,667*	-2,667*	S/M/WIN	-1,726***	-1,647***	-0,628
	B/L/WIN	-1,255	-1,177	-0,863	M/H/LOS	-2,118**	-1,883***	-0,549
	B/M/LOS	-2,118**	-1,961***	-1,569	M/H/WIN	-1,412	-1,334	-0,706
	B/M/WIN	-2,746*	-2,589**	-2,824*	M/L/LOS	-1,804***	-1,726***	-1,804***
	S/H/LOS	-1,098	-1,177	-0,628	M/L/WIN	-1,569	-1,726***	-1,412
	S/H/WIN	-1,883***	-1,647***	-0,471	M/M/LOS	-1,804***	-1,726***	-0,706
	S/L/LOS	-1,647***	-1,804***	-1,490	M/M/WIN	-1,490	-1,412	-0,706

*, **, ***, significativos a 1%, 5% e 10%, respectivamente.

A Hipótese 1 verifica se há diferença de previsibilidade entre os modelos lineares. Conforme indícios da análise dos erros, verificou-se que o modelo de três Fatores de Fama e French apresentou uma melhor previsibilidade, por apresentar erros menores. Para verificar se existe de fato a diferença entre as previsibilidades dos modelos CAPM e três Fatores de Fama e French, utilizou-se o teste de *Wilcoxon* para amostras pareadas para comparação dos erros. Conforme se pode observar na Tabela 2, a estatística *Z* do teste de *Wilcoxon* para o erro quadrado médio (MSE) e o Desvio Médio Absoluto (MAD) apresentaram significância ao nível de 10% somente nas carteiras S/L/LOS e S/M/LOS. Para o Erro Percentual Médio Absoluto (MAPE), o teste foi significativo apenas na carteira S/L/LOS. Nesse sentido, pode-se afirmar que não há diferença de previsibilidade para os modelos lineares, indo de acordo com os achados de Cao *et. al.* (2011).

Ademais, realizou-se o teste de *Wilcoxon* para confirmar que os modelos não lineares apresentam previsibilidades distintas, conforme indícios anteriores. Observa-se na Tabela 2, pelo teste para o erro quadrado médio, que, na maioria das carteiras, a previsibilidade foi significativa, podendo-se rejeitar a hipótese nula de igualdade dos modelos e, consequentemente, confirmar a Hipótese 2.

Por fim, realizou-se também o teste de comparação dos modelos para verificar se há diferença de previsibilidade entre os modelos lineares e não lineares, conforme Hipóteses 3 e 4. Os resultados do teste de *Wilcoxon* para amostras pareadas para comparação de médias é apresentado na Tabela 3.

Tabela 3 – Comparação entre previsibilidade dos modelos lineares e não linear.

Análise	Carteira	MSE	MAD	MAPE	Carteiras	MSE	MAD	MAPE
Hipótese 3	B/H/LOS	-0,863	-0,706	-0,314	S/L/WIN	-3,059*	-3,059*	-3,059*
	B/H/WIN	-1,961***	-2,118**	-1,726***	S/M/LOS	-2,197**	-2,040**	-1,177
	B/L/LOS	-2,824*	-2,589*	-2,118**	S/M/WIN	-1,412	-1,490	-0,941
	B/L/WIN	-1,412	-1,334	-1,177	M/H/LOS	-2,353**	-2,353**	-1,177
	B/M/LOS	-1,726***	-1,726***	-1,098	M/H/WIN	-1,961***	-1,804***	-1,020
	B/M/WIN	-2,903*	-2,824*	-2,746*	M/L/LOS	-2,432**	-2,432**	-2,040**
	S/H/LOS	-1,177	-1,255	-0,863	M/L/WIN	-1,961***	-1,883***	-1,490
	S/H/WIN	-1,490	-1,412	-1,098	M/M/LOS	-2,667*	-2,353**	-1,569
	S/L/LOS	-1,647***	-1,647***	-0,941	M/M/WIN	-1,804***	-1,490	-1,177
Hipótese 4	B/H/LOS	-0,392	-0,392	-0,392	S/L/WIN	-1,098	-1,098	-0,471
	B/H/WIN	-1,177	-1,883***	-1,961***	S/M/LOS	-1,255	-1,255	-0,941
	B/L/LOS	-1,490	-1,569	-0,235	S/M/WIN	-0,471	-0,549	-0,471
	B/L/WIN	-0,314	-0,392	-0,471	M/H/LOS	-0,706	-1,255	-0,941
	B/M/LOS	-0,235	-0,235	-0,235	M/H/WIN	-0,078	-0,157	-0,235
	B/M/WIN	-0,863	-1,412	-1,098	M/L/LOS	-0,235	-0,628	-0,549
	S/H/LOS	-0,078	0,000	-0,392	M/L/WIN	-1,020	-1,412	-1,490
	S/H/WIN	-0,941	-0,392	-0,784	M/M/LOS	-1,961***	-1,883***	-1,647***
	S/L/LOS	-1,098	-0,784	-0,941	M/M/WIN	-1,255	-0,863	-0,549

*, **, ***, significativos a 1%, 5% e 10%, respectivamente.

A primeira parte da Tabela 3 apresenta o teste *de Wilcoxon* para verificar a Hipótese 3 de que não há diferença na previsibilidade dos modelo linear e não linear univariado. Conforme pode ser observado, com exceção das carteiras B/H/LOS, B/L/WIN, S/H/LOS, S/H/WIN e S/M/WIN, as demais carteiras apresentaram o teste significativo ao nível de 1%, rejeitando-se a hipótese de igualdade dos modelos. Nesse sentido, constata-se que a previsibilidade dos modelos é diferente e que o modelo CAPM apresenta melhor desempenho na previsibilidade dos retornos do que a RNA, conforme pode ser observado na Tabela 2.

Na segunda parte da Tabela 3, observa-se a estatística Z do teste de *Wilcoxon* para verificar se não há diferença na previsibilidade dos modelos lineares e não lineares multifatoriais, de acordo com a Hipótese 4. Com exceção dos resultados para as carteiras B/H/WIN e M/M/LOS, os demais testes *t* não apresentaram significância estatística, não se podendo rejeitar a hipótese de igualdade dos modelos, confirmando a Hipótese 4. Ademais, observa-se na Tabela 1 que, na maior parte das carteiras, as medidas de erro analisadas dos dois modelos multifatoriais foram bastante próximas, o que pode ter contribuído para a não rejeição do teste de *Wilcoxon*.

5 CONCLUSÃO

A acurácia de previsibilidade é um dos fatores mais importantes na seleção de qualquer método de previsão. Nesse sentido, este artigo teve por objetivo verificar se a utilização de redes neurais artificiais é uma alternativa viável na previsibilidade dos retornos de ações negociadas no mercado acionário brasileiro.

Para se alcançar o objetivo, foram construídos dois modelos lineares (CAPM e Três Fatores de Fama e French) e dois modelos não lineares (RNA). Os modelos foram estimados de Julho de 1997 à Junho de 2012 e então se realizou a previsão dos retornos do período de Julho de 2012 à Junho de 2013.

Para se testarem os modelos, foram estabelecidas quatro hipóteses de pesquisa. Com a análise das medidas de erros estabelecidas, verificou-se que, em relação aos modelos lineares, o modelo de três Fatores de Fama e French apresentou indícios de uma melhor previsibilidade, por apresentar erros menores. Entretanto, utilizou-se o *teste de Wilcoxon* pareado para comparação dos erros e verificou-se que em apenas uma das 18 carteiras a diferença de previsibilidade dos modelos foi significativa, rejeitando-se assim a Hipótese 1 da presente pesquisa. Cao *et. al.* (2011) atribuem a esse resultado a existência de uma ou mais variáveis não observadas que influenciam as medidas dos retornos das ações, bem como o tamanho e o índice B/M. Uma possível explicação para o caso brasileiro seria o fato da não observância dos prêmios para tamanho e B/M no período analisado (MACHADO; MEDEIROS, 2011).

Ademais, verificou-se que há diferença de previsibilidade entre os modelos não lineares, confirmando a Hipótese 2 da pesquisa. Também foi realizada a comparação de previsibilidade entre os modelos univariados e multivariados. Os achados da pesquisa demonstraram que entre os modelos univariados, o CAPM apresentou menores medidas de erro, além de que, na maioria das carteiras, o *teste de Wilcoxon* de comparação dos modelos apresentou-se significativo ao nível de 5%, rejeitando-se a Hipótese 3 de igualdade dos modelos univariados.

Adicionalmente, realizou-se o teste de comparação entre os modelos multivariados. Pela análise de resíduos, constatou-se que o modelo três Fatores de Fama e French apresentou um melhor desempenho em relação ao modelo de redes neurais. Contudo, com a comparação dos erros por meio do *teste de Wilcoxon*, constatou-se que há diferença de previsibilidade dos modelos em apenas três carteiras das 18 formadas. Dessa forma, não se podendo rejeitar a hipótese de igualdade dos modelos, confirmando a Hipótese 4.

Em virtude dos resultados alcançados, constatou-se que o modelo de previsão baseada em redes neurais não aumenta as chances para os investidores predizerem os preços com maior acurácia pela redução do erro. Constatou-se que, em relação ao modelo univariado, a inclusão de relações não lineares foi prejudicial à previsibilidade do modelo. Já em relação ao modelo multifatorial, a inclusão de relações não lineares não influenciou na previsibilidade, onde o seu desempenho foi semelhante ao do modelo três Fatores de Fama e French.

Acredita-se que resultados diferentes poderão ser alcançados com a utilização de um maior período de estimação, tendo em vista que quanto maior a base de dados, maior o aprendizado da rede. Ademais, com o avanço computacional e de novos algoritmos, pesquisas futuras e novos resultados certamente poderão ser encontrados.

REFERÊNCIAS

ADEBIYI, A. A. *et. al.* **Stock Price Prediction using Neural Network with Hybridized Market Indicators.** Journal of Emerging Trends in Computing and Information Sciences. V. 3, No. 1, 2012.

AVCI, E. **Forecasting daily and sessional returns of the ISE-100 index with neural network models.** *Doğuş Üniversitesi Dergisi*, 8 (2), p. 128-142, 2007.

BALL, R. Anomalies in Relationships between Securities Yields and yield-surrogates. **Journal of Financial Economics**, v.6, p. 103-126, 1978.

BANZ, R. W. The relationship between return and market value of common stocks. **Journal of Financial Economics**, v.9, p. 3-18, 1981.

BASU, S. Investment performance of common stocks in relation to their price-earnings ratios: a test of the efficient market hypothesis. **Journal of Finance**, v.32, n.3, p. 663-682, 1977.

_____. The relationship between earnings yield, market value, and return for NYSE common stocks: further evidence. **Journal of Financial Economics**, v.12, p. 129-156, 1983.

BEKAERT, G.; HARVEY, C. R.; LUNDBLAD, C. Liquidity and Expected Returns: Lessons from Emerging Markets. **Review of Financial Studies**, 20 (6), p.1783-1831, 2007.

BHATTACHARYA, U. et. al. When an event is not an event: the curious case of an emerging market. **Journal of Financial Economics**, v.55, p. 69–101, 2000.

BLACK, F. Capital market equilibrium with restricted borrowing. **Journal of Business**, v.45, p. 444 - 455, 1972.

BLACK, F.; JENSEN, M. C.; SCHOLES, M. **The capital asset pricing model: some empirical tests.** *Studies in the theory of capital markets*, ed. Michael Jensen, pp. 79–121. New York: Praeger, 1972.

BLUME, M.; FRIEND, I. A new look at the capital asset pricing model. **Journal of Finance**. v. 28, n. 1, p. 19-33, 1973.

CARHART, M. M. On persistence in mutual fund performance. **Journal of Finance**, v.52, n.1, p 57–82., 1997.

CAVALHEIRO, E. A. *et. al.* Previsibilidade de mercados: um estudo comparativo entre Bovespa e S&P500. **Sociais e Humanas**, Santa Maria, v. 23, n. 01, p. 61-74, 2010.

CAVALHEIRO, E. A.; VIEIRA, K. M.; CERETTA, P. S. Aplicação de Redes Neurais Polinomiais GMDH na Previsão do Índice Ibovespa. **Revista CAP**. n.05, v.5, 2011.

CHAN, L. K. C.; HAMAQ, Y.; LAKONISHOK, J. Fundamentals and stock returns in Japan. **Journal of Finance**, v.46, n.5, p. 1739-64, 1991.

CAO, Q; LEGGIO, K. B.; SCHNIEDERJANS, M. J. A comparison between Fama and French's model and artificial neural networks in predicting the Chinese stock market. **Computers & Operations Research**, v.32, 2005.

CAO, Q; PARRY, M. E.; LEGGIO, K. B. The three-factor model and artificial neural networks: predicting stock price movement in China. **Ann Oper Res**, v.185, p. 25–44, 2011.

CHEN, A.S.; LEUNG, M.T.; DAOUK, H. Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. **Computers & Operations Research**, 30(6), p. 901-923, 2003.

COPELAND, T. E.; WESTON, J. F.; SHASTRI, K. **Financial theory and corporate policy**. Pearson Addison Wesley, 2005.

DARBELLAY, G. A., SLAMA, M. Forecasting the short-term demand for electricity? Do neural networks stand a better chance? **International Journal of Forecasting**, v. 16, p.71–83, 2000.

DASE, R. K.; PAWAR, D. D.; DASPUTE, D. S. Methodologies for Prediction of Stock Market: an Artificial Neural Network. **International Journal of Statistika and Matematika**, v. 1, p. 08-15, 2011.

EGELI, B.; OZTURAN, M.; BADUR, B. Stock market prediction using artificial neural networks. **In** Proceedings of the third Hawaii international conference on business, Honolulu, Hawaii, 2003.

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. The cross-section of expected stock returns. **Journal of Finance**, v.47, p. 427-466, 1992.

_____. Common risk factors in the returns on bonds and stocks. **Journal of Financial Economics**. v.33, p. 3-56, 1993.

FERSON, W. HARVEY, C. R. The Risk and Predictability of International Equity Returns. **Review of Financial Studies**, 6, 527-566, 1993.

GENCAY, R. Non-linear prediction of security returns with moving average rules. **Journal of Forecasting**, 15, p. 165-174, 1996.

HARVEY, C. R. Predictable risk and returns in emerging markets. **The Review of Financial Studies**; v. 8, p. 773–816, 1995.

KARA, Y.; BOYACIOGLU, M. A.; BAYKAN, O. K. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. **Expert Systems with Applications**, 38, p. 5311–5319, 2011.

KARSOLIYA, S. Approximating Number of Hidden layer neurons in Multiple Hidden Layer BPNN Architecture. **International Journal of Engineering Trends and Technology**. v.3, 2012.

KEENE, M. A.; PETERSON, D. R. The importance of liquidity as a factor in asset pricing. **The Journal of Financial Research**, v.30, n.1, p. 91-109, 2007.

- LINTNER, J. The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets. **Review of Economics and Statistics**, v.47, n.1, p. 13-47, 1965.
- MAASSOUMI, E.; RACINE, J. Entropy and predicability of stock market returns. **Journal of Econometrics**, 107, p.291-312, 2002.
- MACHADO, M. A. V.; MEDEIROS, O. R. Modelos de precificação de ativos e o efeito liquidez: evidências empíricas no mercado acionário brasileiro. **Revista Brasileira de Finanças**, v.9, p. 383-412, 2011.
- MACIEL, L. S.; BALLINI, R. Design a neural network for time series financial forecasting: accuracy and robustness analysis. **In: Encontro Brasileiro de Finanças**, 2009.
- MIRZAMOHAMMADI, S.; MANSOURI, M. Application of Regression and Neural Networks for Prediction of the Profit Rise on Assets Log in Tehran Stock Exchange. **Journal of Basic and Applied Scientific Research**, v.3 (5), p.262-269, 2013.
- OLSON, D.; MOSSMAN, C. Neural network forecasts of Canadian stock returns using accounting ratios. **International Journal of Forecasting**, v. 19, p.453–465, 2003.
- PÉREZ-RODRÍGUEZ, J. V.; TORRA, S.; ANDRADA-FÉLIX, J. STAR and ANN models: forecasting performance on the Spanish “Ibex-35” stock index. **Journal of Empirical Finance**, 12, p.490–509, 2005.
- PORTUGAL, M. S. Neural Networks versus time series methods: a forecasting exercise. **Revista Brasileira de Economia**, v.49, n.4, p. 611-629, 1995.
- PORTUGAL, M. S.; FERNANDES, L. G. L. Redes neurais artificiais e previsão de séries econômicas: uma introdução. **Nova Economia**, v.6, n.1, 1996.
- RAMBALDUCCI, M. J. G.; CANDIDO, M. R. L.; DALMAS, J. C. Avaliação da previsibilidade de retornos de ações emergentes negociadas no Brasil pelo coeficiente beta. **Rev. Ciên. Empresariais da UNIPAR**, Toledo, v.4, 2003.
- REFENES, A.P. Testing Strategies and Metrics. **In: Neural Networks in the Capital Markets**. John Wiley & Sons, Inc., p. 67-76, 1995.
- ROSENBERG, B.; REID, K.; LANSTEIN, R. Persuasive Evidence of Market Inefficiency. **Journal of Portfolio Management**, v. 11, p. 9-17, 1985.
- ROSTAGNO, L. M.; KLOECKNER, G. O.; BECKER, J. L. Previsibilidade de Retorno das Ações na Bovespa: Um Teste Envolvendo o Modelo de Fator de Retorno Esperado. **Revista Brasileira de Finanças**, v.2, n.2, 2004.
- SHARPE, W. F. Capital asset prices: a theory of market equilibrium under conditions of risk. **Journal of Finance**, v.19, n.3, p. 425-442, 1964.
- STATTMAN, D. Book Values and Stock Returns. The Chicago MBA: **Journal of Selected Papers**, v. 4, p. 25-45, 1980.

WALLSTROM, P.; SEGERSTEDT, A. Evaluation of forecasting error measurements and techniques for intermittent demand. **Int. J. Production Economics**, v.128, p.625–636, 2010.

WHITE, H. Economic prediction using neural networks: The case of IBM daily stock returns. **In** Proceedings of the IEEE International Conference on Neural Networks, p. 451-458, 1988.