

PREDICTION OF THE BOVESPA INDEX BY MEANS OF ARTIFICIAL NEURAL NETWORKS

PREVISÃO DO ÍNDICE BOVESPA POR MEIO DE REDES NEURAIAS ARTIFICIAIS

Renata Laíse Reis de Souza Roca¹

Doutoranda do Curso de Administração da Universidade Federal do Rio Grande do Norte UFRN).

E-mail: renata.laise@yahoo.com.br

Anderson Luiz Rezende Mól

Doutor em Administração pela Universidade Federal de Lavras (UFLA), Professor Adjunto da Universidade Federal do Rio Grande do Norte (UFRN).

E-mail: mol.ufrn@gmail.com

RESUMO

O estudo teve o intuito de analisar se as Redes Neurais Artificiais (RNAs) são um método aderente para a previsão do comportamento do índice Bovespa (Ibovespa). Para tanto, desenvolveu um estudo quantitativo que, a partir de índices econômico financeiros, elaborou dois modelos de RNA e um modelo de controle GARCH (1,1). A análise dos resultados obtidos comparou os resultados das previsões dos três modelos com os dados históricos e estudou seus erros de previsão por meio do MSE, RMSE, MAE, Desvio Padrão, U de Theil e teste abrangente de previsões. Concluiu que, para a série de dados estudada neste trabalho, as Redes Neurais artificiais se mostram um modelo mais aderente de previsão do comportamento do Ibovespa do que os modelos tradicionais de séries temporais, representado neste pelo método GARCH (1,1).

Palavras-chave: *Ibovespa. Séries de Tempo. Modelos de Previsão*

ABSTRACT

The study was intended to examine whether the Artificial Neural Networks (ANNs) are an adherent method for the prediction of the Bovespa index (Ibovespa) behavior. To this end it was developed a quantitative study, from economic and financial indexes, produced two ANNs models and a control model GARCH (1.1). The result analysis compared the results of three models forecasts with historical data and studied their prediction errors through the MSE, RMSE, MAE, standard deviation, U of Theil and forecasting encompassing tests. It was concluded, to the series of data studied, that the Artificial Neural Networks are a more adherent model of behavioral prediction of Ibovespa than the traditional models of time series, represented here by GARCH (1.1).

Keywords: *Ibovespa. Time series. Forecast models*

1 INTRODUÇÃO

Nas organizações, a previsão constitui a base para a tomada de decisões estratégicas, táticas e operacionais, tendo um papel importante para realizar em economia e finanças, uma vez que essas são ciências de decisão preocupadas com os efeitos das decisões (PANDA; NARASIMHAN; 2006).

De acordo com Morettin e Toloi (2006, p7), etimologicamente a palavra previsão, que tem origem das palavras *prae* e *vidare*, “sugere que se quer ver uma coisa antes que ela exista”. Essencialmente, a previsão supõe que “as condições presentes e passadas determinam em algum grau o futuro de tal forma que pode haver muitas interações e complexas relações entre as variáveis envolvidas” (OLIVEIRA, 2004, p.1).

Ressalta-se, entretanto que para que seja possível prever os valores futuros com base em valores passados faz-se necessária a disponibilidade de uma memória histórica de dados ocorridos anteriormente. Em adição, o conjunto

¹ Agradecimentos: Ao Programa de Pós-Graduação em Administração da Universidade Federal do Rio Grande do Norte – PPGA/UFRN, a bolsa de estudos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior –CAPES. Ao professor Adrião Duarte, do Departamento de Engenharia da Computação e Automação da UFRN, e a Carlos Padilha pelo auxílio fornecido para que o desenvolvimento dos modelos de RNA fosse bem sucedido.

de dados, por si só, não permite a previsão dos valores futuros, de forma que, para isso, faz-se necessária a utilização de algoritmos, técnicas ou métodos de previsão de séries temporais, que podem envolver cálculos simples ou procedimentos complexos (RIBEIRO, 2009).

A previsão de séries temporais tem sido uma das áreas-chave em Ciências Sociais Aplicadas (OLIVEIRA, 2004). E existem diversos métodos para auxiliar nesta tarefa, como por exemplo: modelos de Suavização Exponencial, modelos auto-regressivos (AR), de Médias Móveis (MA), Modelos ARIMA, ARCH e GARCH.

Os métodos lineares são fáceis de serem desenvolvidos e implementados, além de serem, relativamente, simples de entender e interpretar. Porém, mesmo tendo dominado os processos de previsão por várias décadas, estes métodos apresentam sérias limitações no fato de não serem capazes de capturar todas as relações não-lineares nos dados (ZHANG, 2004). Segundo Oliveira (2007), as técnicas de modelagem convencionais têm produzido previsões insatisfatórias, onde suas principais desvantagens seriam, em suma, seu alto grau de subjetividade com respeito à estrutura do modelo e sua base de informação limitada (ZHANG, 2004; OLIVEIRA, 2004; OLIVEIRA, 2007).

Por outro lado, o recente avanço da capacidade de processamento dos computadores deu grande impulso ao uso de métodos quantitativos em Administração (ALMEIDA; PASSARI, 2006) e permitiu que tecnologias de Inteligência Computacional, como Redes Neurais, Lógica Nebulosa e Algoritmos Genéticos, proporcionassem a criação de metodologias avançadas de previsão (PALIT; POPOVIC, 2005). Desta forma, modelos financeiros que exigem forte desempenho computacional agora podem ser explorados de maneira mais fácil.

Este é o caso das Redes Neurais Artificiais (RNAs), que se mostram um método relativamente recente e promissor para a previsão em negócios (ZHANG, 2004) e tem recebido muita atenção nos campos de economia e finanças (CARVALHAL; RIBEIRO, 2007; THAWORNWONG; ENKE, 2004).

Na área da Administração Financeira, as RNAs têm sido usadas para prever falência, taxa de câmbio, taxa de juros, preço de futuros, retorno acionário, volume de negociação, índice do Mercado de Capitais, preço da oferta pública inicial, valor da propriedade e outros (ZHANG, 2004). Além disso, estudos que utilizam este modelo têm obtido sucesso em uma ampla variedade de aplicações de sistemas e modelagem financeiros (OLIVEIRA, 2007), provando em muitos casos sua superioridade sobre os modelos estatísticos ARIMA-GARCH (MEDEIROS; TERASVIRTA, 2006).

A previsão em Mercado de Ações torna-se difícil porque este é influenciado por fatores diversos como eventos políticos, condições econômicas gerais e as expectativas dos investidores (OH; KIM, 2002).

Os preços das ações podem variar por fatores relacionados à empresa ou por fatores externos, como o crescimento do país, do nível de emprego e da taxa de juros (BM&F BOVESPA, 2015). Tendo isto em vista, a Bolsa de Valores, Mercadorias e Futuros de São Paulo (BM&F BOVESPA) – principal instituição brasileira de intermediação para operações financeiras, com o intuito de orientar as decisões de investimento, criou alguns índices que buscam retratar a situação dos investimentos realizados durante os pregões. Esses índices são indicadores de desempenho de um conjunto de ações, ou seja, mostram a valorização de um determinado grupo de papéis ao longo do tempo.

Atualmente existem 23 Índices da BM&F BOVESPA, onde cada um mostra o comportamento de um grupo diferente de ações. Destes, o Índice de maior destaque é o Índice Bovespa (Ibovespa), que tem por finalidade básica “indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade do mercado de ações brasileiro” (BM&F BOVESPA, 2015, s/n). Assim, até certo ponto, o Ibovespa pode ser utilizado para estudos do comportamento do Mercado de Capitais, visto que reflete o comportamento das principais ações negociadas na bolsa.

Dentre os estudos que utilizam Redes Neurais para previsão no Mercado Financeiro, costuma-se focalizar os preços dos ativos, como os trabalhos de Kalyvas (2001) e Oliveira (2007), entretanto, ao se trabalhar com previsão de Índices, como o trabalho de Carvalhal e Ribeiro (2007), passa-se a trabalhar com o comportamento não de um ativo em especial, mas sim do comportamento de um segmento do mercado.

Nesta conjuntura, este trabalho enfoca a seguinte questão-problema: *Seriam as Redes Neurais Artificiais um método aderente para a previsão do comportamento do Índice Bovespa?*

2. SÉRIES TEMPORAIS E REDES NEURAS ARTIFICIAIS (RNAs)

2.1 Séries Temporais

De acordo com Lima *et al* (2010, p.189), uma série temporal pode ser conceituada como “qualquer conjunto de variáveis estocásticas equiespaçadas e ordenadas no tempo $\{X_t\}_{t=1}^n = \{X_1, X_2, \dots, X_n\}$ ”. Onde, qualquer sinal que depende do tempo e é medido em instantes particulares no tempo pode ser representado por uma série temporal (ENDERS,2003). Conforme Morettin (2002), o que se chama de série temporal é uma parte de uma trajetória, dentre muitas que poderiam ter sido observadas, de um processo estocástico. (LIMA *et al*, 2010, p.189)

Segundo os autores, o objetivo principal da análise de séries temporais é a realização de previsões. E, para isto, utiliza-se uma metodologia que estabelece mecanismos onde “valores futuros de uma série possam ser previstos com base apenas em seus valores presentes e passados. As técnicas desse processo de previsão fundamentam-se na exploração da correlação temporal que pode existir entre os valores exibidos pela série” (LIMA *et al*, 2010, p.189).

Uma vez que os modelos utilizados para descrever séries temporais são processos estocásticos, ou seja, controlados por leis probabilísticas, os modelos de previsão analisam as propriedades estocásticas destas séries com base nos valores passados das próprias variáveis e do termo estocástico (termo de erro). Onde ao contrário das séries determinísticas, nas quais os valores futuros de uma série temporal são determinados exatamente por alguma função matemática, nas séries temporais estocásticas (não-determinísticas), os valores futuros podem ser descritos apenas em termos de uma distribuição de probabilidade à série temporal (OLIVEIRA, 2007).

Basicamente, existem duas abordagens para a análise de séries temporais: análise no domínio temporal e análise no domínio de frequência, onde ambas apresentam o objetivo de construir modelos para as séries com propósitos determinados. Na primeira, os modelos propostos são modelos paramétricos (com número definido de parâmetros) e na segunda os modelos propostos são modelos não-paramétricos (MORETTIN; TOLOI, 2006)

Independente da classificação para os modelos de séries temporais, pode-se considerar um número muito grande de modelos diferentes para descrever o comportamento de uma série em particular. A construção destes modelos depende de vários fatores, tais como o comportamento do fenômeno ou o conhecimento a priori que temos de sua natureza e do objetivo da análise (MORETTIN; TOLOI, 2006). Na prática, depende, também, da existência de métodos apropriados de estimação e da disponibilidade de programas (*softwares*) adequados.

Muitos modelos financeiros dependem de entendimento de séries temporais para prever a funcionalidade dos Mercados Financeiros e utilizam inferências estatísticas para fins de prospecção. As séries temporais são uma forma especial de dados onde os valores passados podem influenciar os valores futuros. E a relação entre variáveis influenciadas pelo tempo, em finanças, pode ser caracterizada por tendências, ciclos, e o comportamento não-estacionário entre pontos de dados que servem a um propósito de previsão ou informação para o modelo (WALLACE, 2008)

O nível de sucesso destes métodos de previsão varia de estudo para estudo e depende dos conjuntos de dados subjacentes e a forma que estes métodos são aplicados a cada vez. No entanto, nenhum deles foi provado ser a ferramenta de previsão consistente que o investidor gostaria de ter (KALYVAS, 2001).

Na literatura, diferentes métodos têm sido aplicados de forma a prever retornos de ações no mercado. Estes métodos podem ser agrupados em quatro categorias principais: 1) métodos de análise técnica, 2) métodos de análise fundamentais, 3) previsões tradicionais de séries temporais e 4) métodos de aprendizado de máquina.

Os modelos de previsão em séries temporais podem ser estacionários, como os modelos ARMA, ou não estacionários, como os modelos ARCH e GARCH. Entretanto, embora modelos lineares venham sendo utilizados no passado para extrair essas relações, existem relações não-lineares entre diversas variáveis financeiras. Desta forma, métodos como as Redes Neurais Artificiais tem um lugar específico na literatura financeira visto que podem ser treinadas para mapear valores futuros de séries temporais, de modo a extrair estruturas ocultas e das relações que podem governar os dados (WALLACE, 2008).

2.2 As Redes Neurais Artificiais (RNAs)

Trabalhando analogamente com o cérebro humano, as Redes Neurais Artificiais empregam uma interligação maciça de células computacionais simples denominadas “neurônios” ou “unidades de processamento” (HAYKIN, 2001). E, segundo Haykin (2001), assemelham-se ao cérebro em dois aspectos: (1) O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; e (2) Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Através dos neurônios e suas ligações, de forma computacional, as informações interligam-se por uma rede na qual cada unidade recebe e combina uma série de entradas numa única saída, que dá entrada a uma nova unidade até a saída final da rede, ou a resposta ao problema (BIALOSKORSKI NETO *et al*, 2006).

A estrutura de um neurônio, como ilustrada na figura 1, permite um conjunto de valores como entradas (x_1, x_2, \dots, x_m) para a produção de uma saída única (y_k). Tais entradas são ponderadas por respectivos pesos sinápticos ($w_{k1}, w_{k2}, \dots, w_{km}$) e somadas ao valor de um *bias* b_k aplicado externamente. O *bias* b_k tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo. Em seguida uma função de ativação $\varphi(\cdot)$ é utilizada para restringir a amplitude do sinal de saída.




Figura 1: Modelo não linear de neurônio artificial.
Fonte: Haykin, 2001, p.38.

A função de ativação $\phi(\cdot)$ define a saída de um neurônio, a regra para o mapeamento das entradas somadas do neurônio até sua saída, introduzindo a capacidade de processar a não-linearidade na rede (OLIVEIRA *et al*, 2008). Segundo Oliveira *et al* (2008) e Haykin (2001), a função de ativação mais comum utilizada na construção de RNAs é a *sigmoide*, definida por uma função “de estreitamento crescente que exhibe um balanceamento adequado entre comportamento linear e não linear” (HAYKIN, 2001, p.40).

O processamento realizado pelos neurônios, além de estar disposto em uma arquitetura paralela, também lança mão de uma propagação sequencial na qual os neurônios de camadas posteriores recebem como sinal de entrada o resultado do processamento ocorrido nas camadas anteriores (ZHANG *et al*, 1998; PANDA; NARASIMHAN, 2006). Estas operações consistem na multiplicação do valor de cada entrada pelo respectivo peso associado e na posterior soma para resultar em um valor (BOSAIPO, 2001). Nos modelos de Redes Neurais Artificiais, estas características são simuladas através da adoção de estado, função e limiar de ativação (BRAGA; CARVALHO; LUDERMIR, 2007).

A forma como as interconexões de neurônios serão estruturadas pode variar quanto ao número de camadas, neurônios em cada camada, função de ativação dos neurônios em uma camada e a forma como as camadas são conectadas (totalmente ou parcialmente).

Existem basicamente três tipos de arquitetura de RNA: (1) as redes *feedforward* de camada única, (2) as redes *feedforward* de múltiplas camadas e (3) as redes recorrentes. Convindo ressaltar que uma Rede Neural do tipo *feedforward* é especialmente adequada para realizar previsão de séries que apresentam volatilidade, devido ao tratamento da não-linearidade realizada pela utilização de funções sigmoides na camada de entradas (OLIVEIRA *et al*, 2008).

Na maior parte das aplicações de previsão, somente uma camada oculta é usada, embora algumas situações excepcionais justifiquem um número maior. Já o número de neurônios nas camadas de entrada e de saída depende da dimensionalidade dos dados, enquanto que o número de neurônios nas camadas intermediárias depende da complexidade do problema, de forma que quanto maior o número de neurônios nas camadas intermediárias, mais complexas são as funções mapeadas com a RNA. (RIBEIRO *et al*, 2009).

A escolha da estrutura da Rede Neural determina diretamente a qualidade do modelo obtido e diversas atividades são necessárias para a definição da arquitetura de uma RNA para a qual um problema específico deverá ser resolvido de forma ótima (RIBEIRO *et al*, 2009).

3 METODOLOGIA

3.1 Tipo Da Pesquisa

Este trabalho está baseado em teorias quantitativas de análise, sendo assim os modelos matemáticos e estatísticos são utilizados a fim de atender o objetivo da pesquisa. Segundo Markoni e Lakatos (1990), os estudos quantitativos são aqueles em que os pesquisadores estabelecem hipóteses e as testa por meio da mensuração de variáveis operacionais definidas, quantificando o resultado com o uso de variados métodos matemáticos e estatísticos. Sendo um tipo de pesquisa tradicionalmente aceito como tendo confiabilidade, fidedignidade e validade, desde que realizado seguindo uma metodologia rigorosa (LAKATOS; MARKONI, 1990).

Para fins de estudo dos resultados obtidos pelos modelos de RNA gerados, realizou-se a modelagem de um modelo de controle baseado nos modelos tradicionais de análise de séries temporais. Visto as características dos dados estudados e do objetivo do modelo, optou-se pela utilização do método ARCH/GARCH para a modelagem deste modelo.

3.2 Amostragem E Coleta De Dados

Os dados econômicos e financeiros necessários para o estudo consistiram basicamente de séries históricas e o acesso aos mesmos ocorreu através de consulta ao *site* da BM&F Bovespa. Além o Índice Bovespa, foco deste estudo, a coleta de dados abrangeu todos os demais Índices disponíveis na BM&F Bovespa.

Optou-se por coletar os dados sobre os demais Índices para que os mesmos fossem inseridos como *inputs* nos modelos de previsão baseados em Redes Neurais visto que o Ibovespa pode ser considerado um reflexo do comportamento geral do mercado. Esta decisão foi baseada no fato de que a literatura aponta que modelos baseados em RNAs podem extrair relações interessantes ao seu modelo de previsão a partir do comportamento de outras variáveis e identificação de inter-relações no sistema, considerando-se, portanto, válida a inserção de dados referentes ao comportamento dos diferentes setores do mercado abordados pelos Índices visto os mesmos retratarem segmentos e portfólios distintos do mercado ao mesmo tempo em que apresentam potencial para adicionar contribuições significativas às Redes Neurais modeladas.

Dentre os dados coletados estão os valores diários dos Índices da BM&F Bovespa, quando disponíveis, durante um horizonte de tempo que abrangeu desde o primeiro dia útil do ano de 2006 (dois de janeiro) até o último dia útil do mês de janeiro do ano de 2011, a saber, dia 31.

Optou-se por este período de tempo visto que o mesmo seria capaz de prover um número razoável de entradas para estudo da série temporal (aproximadamente 1250 dados para cada Índice), ao mesmo tempo em que permite a inclusão de quase todos os índices (dezenove, dos vinte e três) atualmente trabalhados pela BM&F Bovespa devido à existência de dados referentes aos mesmos durante todos os períodos deste horizonte de tempo.

Ressalta-se que quatro dos 23 Índices – BDRX, ICON, ICO2 e IGC-NM - não apresentavam dados referentes aos seus valores durante um longo período de tempo da série, optando-se por excluí-los dos parâmetros estudados para fins de tornar a inter-relação modelada pela RNA mais coesa, restando assim 19 parâmetros (Índices) para estudo.

3.3 Tratamento Dos Dados

Uma vez coletados os dados, os mesmos foram tratados por meio de métodos estatísticos e financeiros de acordo com as necessidades dos modelos a serem utilizados (Redes Neurais e GARCH).

Após esta etapa de adequação dos dados, desenvolveram-se modelos de previsão para o Ibovespa através dos métodos das Redes Neurais Artificiais e GARCH (modelo de controle).

Foram utilizados os softwares MS Excel – para organização e tratamento inicial dos dados, *Eviews* – para modelagem do método GARCH e MATLAB (versão estudante) – para modelagem do método de RNA.

3.3.1 Tratamento Dos Dados Para A Rna

Baseado no fato amplamente conhecido de que a literatura recomenda que em estudos de séries financeiras sejam utilizados dados de retornos ao invés de preços (visto sua menor instabilidade no decorrer do tempo), resolveu-se por desenvolver dois modelos de RNA. Um com seus dados de entrada baseados na série de dados originais (cujos valores diários expressavam preços) - doravante denominado de RNA baseada em Preços e outro baseado em uma versão convertida da base de dados, resultada da conversão dos dados de preços diários em retornos diários - doravante denominada RNA baseada em Retornos.

Para a base de dados de entrada da RNA baseada em retornos, realizou-se a conversão dos dados de valores diários (preços) em retornos diários. Onde, denotando observações sucessivas de uma variável tomada nos instantes t e $t+1$ a transformação da série de valores em uma série de retornos foi dada por: $Y_t = \text{Log}_{(t+1)} - \text{Log}_t$.

Embora os dados de entrada e saídas sejam diferentes (preços – retornos), ambas utilizaram a mesma metodologia e estrutura. Para fins de padronização de resultados, a RNA baseada em Preços teve seus resultados finais convertidos para retornos diários.

Para a modelagem das Redes Neurais a base de dados foi dividida em dois grupos. Para o modelo baseado em preços, o grupo de treinamento consistiu nos dados referentes aos valores do período 1 ao período 1200, ou seja, de dois de janeiro de 2006 a 11 de novembro de 2010. Já o grupo de teste e validação foi composto pelos 50 períodos seguintes do banco de dados, abarcando o período de 12 de novembro de 2010 a 26 de janeiro de 2011. Para o modelo baseado em retornos, o grupo de treinamento abarcou do período 2 (visto a perda da primeira observação ao se realizar a transformação da série de preços para retornos) ao 1196, enquanto que o grupo de teste e validação gerou previsões para os 50 períodos seguintes.

Depois de selecionados os dados, iniciou-se o estudo da melhor estrutura a ser utilizada na rede. Após uma análise inicial optou-se, para um melhor tratamento dos dados, por utilizar não apenas um período (n) para realizar a previsão do próximo ($n+1$), mas sim a carga histórica do período atual mais os quatro anteriores, o que totalizava 95 entradas para a RNA. Entretanto, após tentativas de modelagem através desta estrutura e do nível de erro obtido, resolveu-se pela utilização da Análise dos Componentes Principais (PCA) para fins de reduzir o número de entradas e, assim, aumentar a relevância dos dados levados em consideração pela rede (*Multilayer Perceptron* - MLP) em si. Desta forma conseguiu-se reduzir o número de entradas a serem fornecidas à rede de 95 para 20, como pode ser visualizado através da seguinte figura:

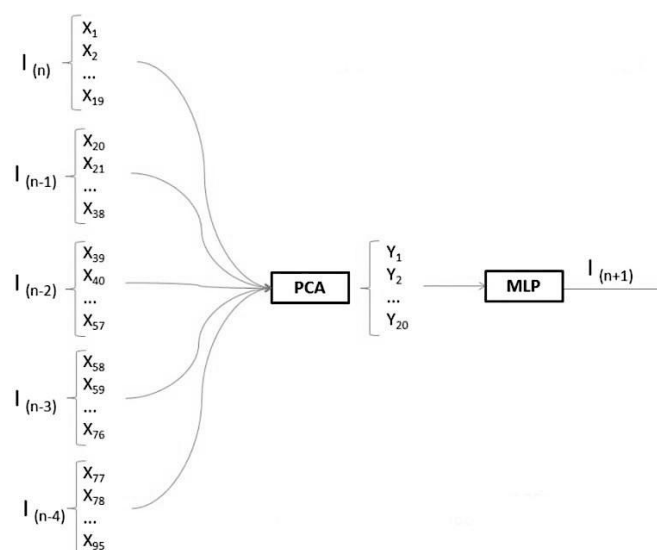


Figura 2: Estrutura Final da RNA
Fonte: Dados de Pesquisa.

Por meio desta estrutura, pôde-se chegar a uma Rede Neural Artificial do tipo *feedforward* e de aprendizado supervisionado, cuja arquitetura, ilustrada pela figura 3, consistiu em 20 dados na camada de entrada, 90 neurônios em uma camada oculta e um dado na camada de saída (previsão do Ibovespa).

Nesta rede empregou-se o *BackPropagation*, através da ferramenta disponível na *Toolbox* (caixa de ferramentas) do *software* utilizado (MATLAB). Para fins deste estudo optou-se também por se utilizar a função de ativação de entrada como sendo a tangente *Sigmoid* e uma função de saída linear.




Figura 3: Arquitetura da Rede Neural Artificial
Fonte: Dados de Pesquisa.

3.3.2 Tratamento Dos Dados Para O Modelo De Controle

Primeiramente, com o intuito de se transformar a série de dados a ser trabalhada em uma série estacionária, realizou-se a conversão da mesma de valores diários (preços) do Ibovespa em uma série de retornos diários deste Índice utilizando-se, novamente, a fórmula $Y_t = \text{Log}(t+1) - \text{Log}(t)$. Esta nova série de dados foi chamada de RIBOV (Retornos Diários do Ibovespa).

Em seguida, verificou-se a presença dos fatos estilizados (assimetria, linearidade, normalidade, estacionariedade, volatilidade e curtose) como elemento primário para determinar se o modelo GARCH seria um modelo estatístico adequado à série temporal sob análise.

Embora verificada a não necessidade da aplicação de um modelo ARMA, devido a sua característica heteroscedástica optou-se por realizar um modelo ARMA (1,1) com o intuito de se gerar a possibilidade da observação dos resíduos deste modelo, viabilizando o estudo das variâncias (efeitos ARCH) da série estudada. Para este modelo, utilizou-se um filtro de correção de Newey-West tornando-o robusto à heteroscedasticidade e autocorrelação no processo do resíduo, obtendo-se os resultados ilustrados por meio da tabela 1, abaixo.

Tabela 1: Resultados do Modelo ARMA (1,1) para geração de resíduos para estudo.

Equação de Variância				
	Coefficiente	Erro Padrão	Estatística-z	P Valor
AR (1)	0,737926	0,189690	3,890165	0,0001
MA (1)	-0,790481	0,173818	-4,547755	0,0000
Critério de Informação de Akaike	- 4,911962			
Critério de Informação de Schwarz	- 4,903742			
Máxima Verossimilhança	3067,064			

Fonte: Dados de Pesquisa.

Uma vez de posse dos resíduos gerados por meio do Modelo ARMA (1,1), pôde-se aplicar o teste de ARCH de Engle (1982) para estudo dos mesmos (tabela 2).

Tabela 2: Testes de efeitos ARCH.

TESTE ARCH	1 lag	5 lags	10 lags	20 lags
F-statistic	51,55367	88,21203	64,54719	39,39459
p-valor	0,000000	0,000000	0,000000	0,000000

Fonte: Dados de pesquisa.

Conforme os p-valores, os testes para efeitos ARCH forneceram fortes evidências contra a hipótese nula de não haver heteroscedasticidade condicional na volatilidade dos modelos para a série estudada (RIBOV). Assim, modelou-se a série transformada levando-se em consideração o padrão heteroscedástico da volatilidade para a média condicional dos resíduos, através do método GARCH (1,1).

Visto que o modelo ARMA foi realizado apenas para fins de estudo de seus resíduos, ao se desenvolver a modelagem GARCH optou-se por ignorá-lo, utilizando-se apenas os dados da série RIBOV. Com objetivo de se reduzir o erro embutido no modelo, como mencionado anteriormente e baseando-se no fato de que testes anteriores já haviam comprovado a não necessidade de tal modelagem para a implementação do GARCH (1,1), cuja representação algébrica encontra-se na expressão:

$$GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1)$$

3.4 Procedimento Da Análise Dos Resultados

Os resultados obtidos por meio da implementação das RNAs e do modelo de controle (GARCH (1,1)) foram analisados estudando-se as previsões e erros obtidos em cada modelo de forma a se visualizar qual seria aquele mais aderente à base de dados utilizada.

Para uma padronização dos resultados, foram estudadas e comparadas as previsões geradas pelos modelos para do período número 1202 (16 de novembro de 2010) ao 1246 (19 de janeiro de 2011) do Índice Bovespa , analisando-se assim, uma amostra de 45 observações do grupo de previsão gerado por cada modelo.

Para estudo da precisão das previsões realizadas foram calculados os indicadores MSE (Erro Quadrado Médio), RMSE (Raiz do Erro Quadrado Médio) e o MAE (Erro Médio Absoluto), onde de acordo com estes indicadores, o modelo com menores MSE, RMSE e MAE apresentaria evidência de ser superior.

Outro indicador calculado foi o coeficiente de U de Theil, o qual avalia o desempenho das previsões contra os valores da previsão ingênua, também conhecida por previsão naïve, a qual considera que a estimativa do período futuro é igual a estimativa do valor atual.

O U de Theil é calculado de acordo com a seguinte fórmula:

$$U_{Theil} = \frac{\sqrt{\sum_{j=1}^N (A_t - F_t)^2}}{\sqrt{\sum_{j=1}^N (A_t - A_{t-1})^2}}$$

Onde A_t é o valor atual e F_t é o valor predito. E de forma que se $U_{Theil} > 1$, significa que o erro do modelo é maior do que da previsão ingênua e, conseqüentemente, se $U_{Theil} < 1$, significa que o erro do modelo é menor que da previsão ingênua. Assim, quanto mais próximo de zero for a estatística de U de Theil, melhor será o resultado da previsão do modelo.

Por fim, complementou-se a análise da precisão das previsões dos modelos por meio dos testes abrangente de regressões (forecast encompassing tests), nos quais, para cada par de modelos, realizam-se duas regressões dos erros de previsão de um para com a previsão do outro :

$$\begin{aligned} (p_{ai} - o_i) &= \gamma p_{bi} + \varepsilon_i \\ (p_{bi} - o_i) &= \Phi p_{ai} + \upsilon_i \end{aligned}$$

Onde: p_{ai} e p_{bi} são os valores previstos nos modelos **a** e **b**, respectivamente; o_i é o valor atual , $(p_{ai} - o_i)$ e $(p_{bi} - o_i)$ são os erros de previsão dos dois modelos, **a** e **b**, e ε_i e υ_i são os erros aleatórios.

De acordo com estes testes, se γ é significativamente diferente de zero mas Φ não é, rejeita-se a hipótese nula de que nenhum modelo é superior ao outro, a favor da hipótese alternativa de que o modelo **b** é superior ao modelo

a. Por outro lado, se γ é significativamente diferente de zero, mas Φ não é, pode-se concluir que o modelo a é superior ao b. E se ambos γ e Φ não forem significantes, ou se ambos forem, pode-se concluir que nenhum dos modelos é superior ao outro (CARVALHAL; RIBEIRO, 2007).

Para este estudo, trabalhou-se considerando um nível de significância de 5%.

4 RESULTADOS E ANÁLISE

4.1 Redes Neurais Artificiais

Para fins de comparação foram realizados dois modelos de RNA por meio da metodologia previamente especificada. Abaixo, os resultados destes modelos.

4.1.1 Rna Baseada Em Preços

Como destacado na metodologia, para o modelo de RNA os dados foram separados em dois grupos, o de treinamento e o de teste e validação. Na etapa de treinamento a rede recebe os valores de entradas, quais devem ser os resultados de saída e estabelece os pesos das correlações. Após esta etapa foi-se realizada a etapa de teste e validação, que consistiu em prever o valor diário do Ibovespa para os últimos 50 períodos da série estudada. O comportamento dos resultados obtidos por esta fase são ilustrados abaixo.

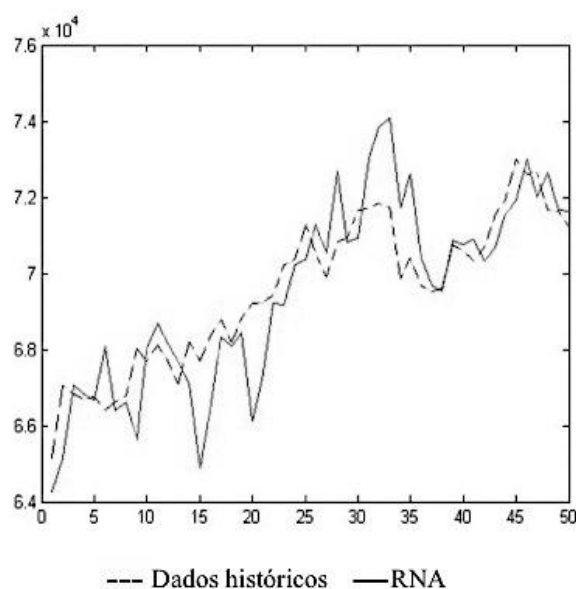


Figura 4: Comportamento da RNA em comparação com os dados históricos – etapa de utilização.
Fonte: Dados de pesquisa.

Uma vez de posse dos valores históricos e dos valores previstos pela RNA pôde-se calcular o erro obtido pelas previsões da rede.

A seguir, a figura 5 demonstra o comportamento do erro e seu desvio padrão, para fins de ilustração.




Figura 5: Comportamento do erro e seu desvio padrão (RNA – preços).
Fonte: Dados de pesquisa.

Por fim, para fins de comparação do resultado obtido pela RNA e pelo modelo de controle, adaptou-se os dados previstos pela RNA, convertendo-os de preço para retorno nos períodos de previsão, calculando-se assim um novo erro e, então, um erro quadrático.

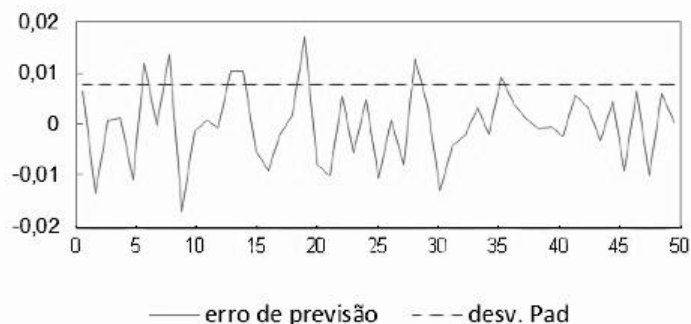


Figura 6: Comportamento do erro e seu desvio padrão (RNA – preços, após conversão de seus resultados para retornos).

Fonte: Dados de pesquisa.

4.1.2 Rna Baseada Em Retornos

Para o segundo modelo de RNA, converteu-se a base de dados de valores diários para retornos diários e os quais foram então submetidos a uma modelagem RNA de mesma estrutura daquela do modelo anterior. Por meio desta, foram obtidos o seguinte comportamento na fase de teste e validação (figura 7).

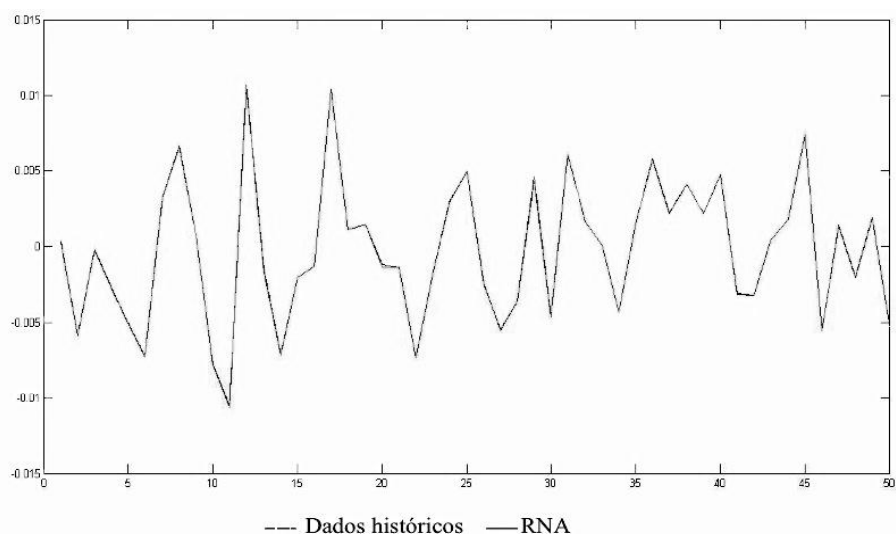


Figura 7: Comportamento da RNA (retornos) em comparação com os dados históricos – etapa utilização.

Fonte: Dados de pesquisa.

Observa-se graficamente que o modelo de previsão gerado parece se adequar bem aos dados estudados e, além disso, de forma superior aos modelos previamente desenvolvidos. Entretanto, para comprovação, realizou-se um cálculo do erro quadrático da mesma, bem como se observou o comportamento dos erros frente ao seu desvio padrão (figura 8).




Figura 8: Comportamento do erro e seu desvio padrão (RNA – retornos).

Fonte: Dados de pesquisa.

Embora ambos os modelos tenham sido desenvolvidos satisfatoriamente, percebe-se que o modelo baseado diretamente nos retornos dos Índices ao invés dos preços diários apresentou menores erros e, logo, desvio padrão indicando uma melhor adequação à base de dados utilizada visto suas previsões estarem mais próximas do real que o primeiro modelo.

Isto indica que o fato de se trabalhar com uma base de dados de menor volatilidade (retornos, frente a preços) parece ter influenciado no resultado final obtido pela RNA.

4.2 Modelo De Controle - Garch (1,1)

De acordo com a metodologia relatada, obteve-se um modelo GARCH(1,1) cujos resultados estão representados na tabela 3.

Tabela 3: Resultados do Modelo GARCH para previsão do RIBOV.

Equação de Variância	Coefficiente	Erro Padrão	Estatística-z	P Valor
C	7,07E-06	1,95E-06	3,619919	0,0003
$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i}$	0,084944	0,013013	6,527458	0,0000
$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i}$	0,895420	0,015103	59,28715	0,0000
Crítério de Informação de Akaike	-5,243055			
Crítério de Informação de Schwarz	-5,230733			
Máxima Verosmelhança	3277,288			

Fonte: Dados de Pesquisa.

Realizando-se então um novo teste de Efeitos ARCH de Engle, comprova-se a resolução dos problemas de ARCH, como pode ser observado na tabela 4.

Tabela 4: Teste de Efeitos ARCH, após a modelagem do GARCH (1,1).

TESTE ARCH	1 lag	5 lags	10 lags	20 lags
F-statistic	1,403809	0,542138	0,658516	0,577361
Probabilidade	0,236313	0,744435	0,763599	0,929842

Fonte: Dados de Pesquisa, 2011.

A partir deste modelo obteve-se o seguinte resultado da variância, que mostra o comportamento da volatilidade da previsão, ilustrado graficamente abaixo.

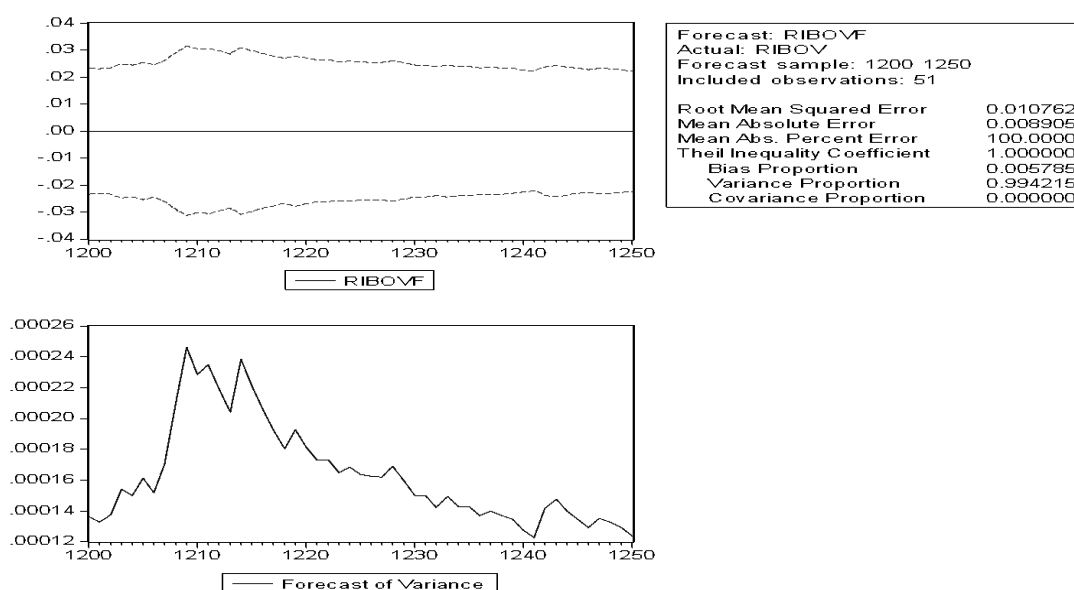


Figura 9: Representação gráfica dos resultados obtidos pelo modelo GARCH (1,1)

Fonte: Dados de pesquisa.

A partir do modelo GARCH(1,1) calculou-se o erro e o erro quadrático baseados no retorno da série Ibovespa.

Percebe-se que o Modelo de Controle apresenta-se mais limitado que os modelos RNA uma vez que se utiliza apenas dos dados históricos do próprio Ibovespa para realizar a modelagem de um modelo de previsão do mesmo. Desta forma, os erros relativamente superiores encontrados por este modelo em relação aquele pode ser reflexo desta limitação.

4.3 Análise Dos Resultados

Uma vez realizadas as modelagens das Redes Neurais e do modelo GARCH, calculou-se o desvio padrão dos erros de previsão de cada modelo e, em seguida, realizou-se a comparação dos erros quadráticos, e suas médias, do período 1202 ao 1246, de forma a se ter o mesmo número de observações para cada modelo. Tal comparação pode ser observada através da tabela 5.

Tabela 5: RMSE, MAE e Desvios Padrão dos erros de previsão dos modelos.

Modelo	MSE	RMSE	MAE	U de Theil	Desvio Padrão do Erro de Previsão
GARCH (1,1)	0,000309	0,017570	0,014796	0,045541	0,011296
RNA preços	0,000060	0,007714	0,006085	0,019994	0,007799
RNA retornos	0,000000	0,000072	0,000045	0,000186	0,000063

Fonte: Dados de Pesquisa.

Por meio destas informações, percebe-se que dentre os três modelos desenvolvidos, aquele com maior aderência à série de dados estudada seria o modelo de RNA com base em retornos, seguido pelo modelo de RNA baseado em preços, o qual além de a menor média dos erros quadráticos também apresenta menor erro padrão.

Além disso, observa-se também que, de acordo com a estatística do U de Theil, os resultados dos três modelos podem ser considerados superiores a um modelo de previsão ingênua, sendo que aquele que apresentaria melhores previsões seria o modelo de RNA baseado em retornos, visto ser o mais próximo a 0.

Ressalta-se que, embora tenha sido obtido um resultado com base em retorno para ambos os modelos de Redes Neurais, aquele que utilizou os dados baseados em retorno como dados de entrada obteve resultados superiores que aquele que utilizou a base formada por preços como dados de entrada, segundo os indicadores da tabela 5. O que indica que, assim como em diversos modelos financeiros, a estrutura de RNA utilizada se adapta melhor a séries de retornos que as de preços, visto a maior volatilidade desta em comparação com aquelas, e/ou ainda que a exclusão de um filtro extra no modelo de RNA foi capaz de reduzir o nível de erro obtido pelo modelo.

Em adição aos indicadores destacados acima, realizou-se também um teste abrangente de regressões, comparando os erros e previsões do modelo de forma a observar se as diferenças de previsão entre eles são significantes para classificar um ou outro como modelo superior. Os resultados deste teste encontram-se na tabela 6, abaixo.

Tabela 6: Teste Abrangente de regressões

Variável Dependente: Erro de Previsão do	Variável Independente: previsão do		
	GARCH (1,1)	RNA preços	RNA retornos
GARCH (1,1)	0,941757	-	0,000080
RNA preços	0,856382	0,727804	-
RNA retornos	0,220935	0,844127	0,267209

Fonte: Dados de Pesquisa.

Com base nesta tabela, observa-se que ambos os modelos de RNA podem ser classificados como superiores ao modelo de controle. Entretanto, a superioridade da RNA baseada em retornos não é confirmada, visto que ambos os coeficientes das regressões das RNAs não são significativamente diferentes de zero, concluindo-se que uma rede não supera a outra. Ou seja, mesmo que os indicadores MSE, MRSE, MAE e U de Theil evidenciem o contrário, este teste demonstra que as diferenças nos erros de previsão dos modelos baseados em RNA não são significantes.

5 CONSIDERAÇÕES FINAIS

Conclui-se para a série de dados estudados, onde predominam relações não lineares, que o método de RNA apresentou resultados mais próximos dos dados reais do que o modelo GARCH(1,1), visto que através da comparação dos resultados obtidos por tais modelos, observou-se uma melhor adequação das RNAs desenvolvidas frente ao modelo GARCH (1,1).

Tal conclusão pode ser justificada através da análise dos erros resultantes de cada modelo, bem como seus desvios padrões e observação gráfica. Desta forma infere-se que, para a base de dados adotada, as Redes Neurais Artificiais são um método aderente para a previsão do Ibovespa.

Para estudos futuros, sugere-se que sejam desenvolvidos modelos para previsão de outros Índices além do Ibovespa, para fins de averiguação de possível réplica de resultados. Bem como a realização de novos estudos para fins de uma melhor observação da adequação dos modelos preditivos de RNA em séries financeiras, utilizando-se abordagens diferenciadas e possivelmente mais abrangentes que possibilitem uma maior robustez e precisão das previsões geradas tanto pelos modelos de Redes Neurais Artificiais quanto pelos modelos aos quais estes sejam eventualmente comparados.

REFERÊNCIAS

- ALMEIDA, Fernando Carvalho de; PASSARI, Antônio Fabrizio Lima. Previsão de vendas no varejo por meio de redes neurais. **R.Adm.**, São Paulo, v.41, n.3, p.257-272, jul./ago./set. 2006
- BIALOSKORSKI NETO, Sigismundo; NAGANO, Marcelo Seido; MORAES, Marcelo Botelho da Costa. Utilização de redes neurais artificiais para avaliação socioeconômica: uma aplicação em cooperativas. **R.Adm.**, São Paulo, v.41, n.1, p.59-68, jan./fev./mar. 2006.
- BM&F BOVESPA – Bolsa de Valores, Mercadorias e Futuros de São Paulo.** Disponível em: <<http://www.bmfbovespa.com.br>>. Acesso em 15/março/2015.
- BOSAIPO, Cláudia Rödel. Aplicação das redes neurais na previsão do comportamento de mercados financeiros. **Revista de Informação e Tecnologia.** (online) Maio, 2001.
- BRAGA, Antônio de Pádua; CARVALHO, André Carlos Ponce de Leon Ferreira de; LUDEMIR, Teresa Bernarda. **Redes neurais artificiais: teoria e aplicações.** 2.ed. Rio de Janeiro: LTC, 2007.
- HAYKIN, Simon S.. **Redes neurais artificiais: princípios e práticas.** Porto Alegre: Bookman, 2001.
- KALYVAS, Efstathios. **Using neural networks and genetic algorithms to predict stock market returns.** 2001. 166 p. Tese (Master of Science in Advanced Computer Science) – University of Manchester, Manchester, 2001.
- LAKATOS, Eva Maria; MARCONI, Marina de Andrade. **Técnicas de pesquisa.** 2. ed. São Paulo: Atlas, 1990.
- MEDEIROS, M .; TERASVIRTA, T.; RECH, G. Building neural network models for time series: a statistical approach. **Journal of Forecasting**, v.25, p. 49-75. 2006
- LIMA, Fabiano Guesti et al. Previsão de preços de commodities com modelos ARIMA-GARCH e redes neurais com ondaletas: velhas tecnologias – novos resultados. **R.Adm.** v.45, n.2, p.188-202, abr./mai./jun., 2010.
- MORETTIN, Pedro A.; TOLOI, Célia M.C.. **Análise de séries temporais.** 2.ed. São Paulo: Edgard Blücher, 2006. 538 p.
- OH, Kyong Joo; KIM, Kyoung-jae . Piecewise nonlinear model for financial time series forecasting with artificial neural networks. **Intelligent Data Analysis.** v.6, p. 175–185, 2002.
- OLIVEIRA, Mauri Aparecido de. **Aplicação de redes neurais artificiais na análise de séries temporais econômico-financeiras.** 2007. 317p. Tese (Doutorado em Administração) – Universidade de São Paulo (USP), São Paulo, 2007.
- _____. **Previsão de sucessões cronológicas econômico-financeiras por meio de redes neurais artificiais recorrentes de tempo real e de processos ARMA-GARCH: um estudo comparativo quanto à eficiência de previsão.** 2004. 193 p. Dissertação (Mestrado em Administração) – Universidade de São Paulo (USP), São Paulo, 2004.
- OLIVEIRA, Mauri Aparecido de; MONTINI, Alessandra de Ávila. BERGMANN, Daniel Reed. Construção de intervalos de predição para redes neurais via regressão multivariada e sua aplicação em séries heterocedásticas. **FACEF PESQUISA** , v. 10, n. 3, p.271-283 , 2007
- OLIVEIRA, Mauri Aparecido de; MONTINI, Alessandra de Ávila. BERGMANN, Daniel Reed. . Previsão de retornos de ações dos setores financeiro, de alimentos, industrial e de serviços, por meio de rna e modelos arima-garch. **RAM – Revista De Administração Mackenzie** , v. 9, n. 1, p. 130-156, 2008.
- PANDA, Chakradara. NARASIMHAN, V..Predicting stocks returns: an experiment of the artificial neural network in Indian stock market. **South Asia Economic Journal**, v7, n.2, p.205-218, 2006.

-
- PALIT, A. K., POPOVIC, D. **Computational intelligence in time series forecasting**. Londres: Springer-Verlag, 2005. 372p.
- RIBEIRO, Claudio Vasconcelos; GOLDSCHMIDT, Ronaldo Ribeiro; CHOREN, Ricardo. Métodos para previsão de séries temporais e suas tendências de desenvolvimento. **Monografias em Sistemas e Computação**. Rio de Janeiro, n.3, p.1-26. Setembro, 2009.
- THAWORNWONG, Suraphan; ENKE, David. Forecasting stock returns with artificial neural networks. In: WALLACE, Martin P.. Neural networks and their application to finance. **Business Intelligence Journal**. p. 67-76. Julho, 2008.
- ZHANG, Peter G.. **Neural business in business forecasting**. Hershey: Idea Group Publishing, 2004.
- ZHANG, Guoqiang; PATUWO, B. Eddy; HU, Michael Y. Forecasting with artificial neural networks: the state of the art. **International Journal of Forecasting**, Amsterdam, v.14, p.35-62,1998.