



REDES NEURAIS APLICADAS A SÉRIES FINANCEIRAS
INSTITUTO DE ECONOMIA – UNIVERSIDADE ESTADUAL DE CAMPINAS
DEPARTAMENTO DE TEORIA ECONÔMICA

Leandro dos Santos Maciel, Rosângela Ballini
 E-mails: leandro_maciell@hotmail.com, ballini@eco.unicamp.br
 Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq
 Palavras-Chave: Redes Neurais, Séries Temporais, Modelos Não-Paramétricos.



INTRODUÇÃO

Análise e Previsão de Séries Econômico-Financeiras são de fundamental importância para gerenciamento das finanças de investidores institucionais e não-institucionais. Os modelos estocásticos mais utilizados na literatura e pelas instituições financeiras são baseados na modelagem de variância condicional, GARCH, proposta por Bollerslev em 1986. Entretanto, esses modelos exigem suposições a respeito da distribuição das séries em questão, assim como são incapazes de incorporar as relações não-lineares entre as variáveis. Redes Neurais Artificiais (RNAs), sobretudo as multicamadas com algoritmo *backpropagation*, vêm sendo sugeridas na literatura para análise de séries temporais financeiras devido sua capacidade de tratar com relações não-lineares de entrada-saída, destacando sua habilidade de aprendizado e capacidade de generalização, associação e busca paralela. Este trabalho avaliou o potencial preditivo das redes neurais comparado ao modelo GARCH para a previsão do preço de fechamento das ações da Petrobrás, Vale do Rio Doce, Natura e do índice S&P 500.

MODELAGEM GARCH

Um modelo GARCH de ordem p e q pode ser definido:

$$r_t = \sqrt{\sigma_t^2} \varepsilon_t,$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i r_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

Nesse modelo, a variância depende dos retornos, como também, das variâncias passadas (ENGL, 1982).

MODELO DE REDES NEURONAIS

As RNAs são sistemas de processamento paralelo e distribuído, baseados no sistema nervoso biológico. Seu elemento computacional básico é o neurônio artificial, composto pelos pesos sinápticos, pela função soma e de ativação como representado na Figura 1.

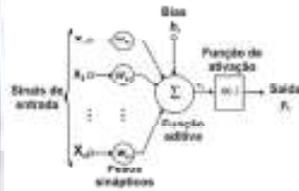


Figura 1 – Modelo de Neurônio Artificial (HAYKIN, 2001)

A estrutura de rede neural mais aplicada é a *Multilayer Perceptrons (MLP)*, uma generalização ao modelo proposto por Rosenblatt (1958). Sua topologia consiste em uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída (Figura 2).

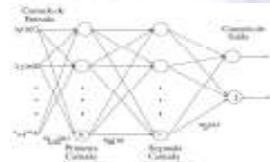


Figura 2 - Arquitetura *Multilayer Perceptrons (MLP)*

O ajuste dos parâmetros do modelo é realizado pelo algoritmo *backpropagation*, ou retro-propagação do erro (ver RUMELHART et al., 1986). Esse processo pode ser representado por:

$$\Delta w_j(n) = \eta \delta_j(n) y_j(n)$$

onde $\Delta w_j(n)$ representa a variação dos pesos sinápticos do neurônio j com as entradas y_j , η a taxa de aprendizado e δ_j o gradiente local, sendo σ_j o sinal de erro do neurônio j , e a derivada da função de ativação no ponto.

Na literatura nenhum trabalho especifica os parâmetros ideais para a construção de uma modelagem que leve aos melhores resultados, portanto, envolve escolhas empíricas de acordo com a especificidade dos dados e o objetivo de previsão.

RESULTADOS

A Figura 3, a seguir, apresenta os resultados da modelagem de Redes Neurais para o preço de fechamento das ações da Petrobrás (PETR4):

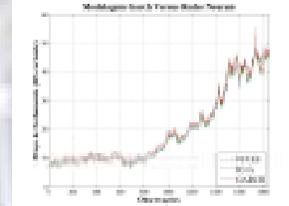


Figura 3 – Modelagem de Redes Neurais para PETR4

Para as ações da Petrobrás, foi ajustado um modelo multi-camadas com três neurônios na camada de entrada, e 26 na camada intermediária (*hidden layer*). O algoritmo de retropropagação com gradiente descendente apresentou uma taxa de aprendizagem de 0,05, composto por 2200 épocas (iterações). A variação do erro quadrático médio assumiu valores abaixo de 0,001, como representado pela Figura 4.

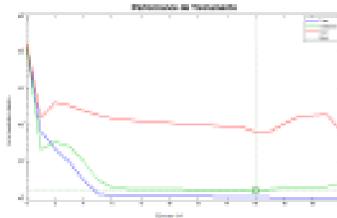


Figura 4 – Performance de Treinamento da Rede Neural

A Tabela 1, a seguir, apresenta os valores das métricas dos erros para comparação entre a modelagem GARCH e de redes neurais para a previsão do preço de fechamento das ações da Petrobrás, Vale do Rio Doce, Natura e do índice S&P 500.

Tabela 1: Comparação de desempenho: Redes Neurais Versus Modelagem GARCH

	EPQ		MEP		REQM	
	RNA	GARCH	RNA	GARCH	RNA	GARCH
Petrobrás	0,2776	8,5399	1,2960	6,9994	0,0359	0,3883
Vale	2,1991	5,6879	4,8876	7,6543	0,0432	0,6548
Natura	3,9282	6,9845	3,2220	4,5874	0,1293	0,2387
S&P 500	1,0093	5,2111	2,1099	6,9786	0,0679	0,3874

CONSIDERAÇÕES FINAIS

O presente trabalho buscou avaliar a potencialidade de previsão dos modelos de redes neuronais aplicados a séries econômico-financeiras, como o preço de fechamento das principais ações comercializadas na Bolsa de Valores de São e do índice S&P 500. Para avaliar seu desempenho, comparou-se os resultados aos do modelo de séries temporais de variância condicional, GARCH. Os resultados revelaram que a modelagem de redes neuronais mostrou-se superior em todos os indicadores de desempenho, com elevada capacidade para generalização e previsão dos dados. Além disso, apresenta a vantagem de modelar padrões não-lineares, característica fundamental das séries econômico-financeiras. Vale destacar que as RNAs não exigem suposição com relação à distribuição de probabilidades das séries empregadas, ao qual, na modelagem GARCH deve ser especificada.

REFERÊNCIAS BIBLIOGRÁFICAS

BOLLERSLEV, T. R. *Generalized Autoregressive Conditional Heteroskedasticity*. Journal of Econometrics, 51, p. 307-327, 1986.

ENGL, R. F. *Autoregressive Conditional Heteroskedasticity with Estimates of The Variance of the United Kingdom Inflation*. Revista Econométrica, 50, p.987-1008, 1982.

HAYKIN, S. *Neural Networks: a Comprehensive Foundation*. IEEE Press, New York, 2001.

ROSEBLATT, F. *The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain*. Psychological Review, 65, p.386-408, 1958.

RUMELHART, D. HINTON, G. E e WILLIAMS, R. *Learning representations by backpropagation errors*. Nature, 323, p.533- 536.