

ARTIGO

Previsão de Preços com um Modelo de Redes Neurais Artificiais

Aureliano Angel
Bressan¹

Resumo

Neste trabalho, constrói-se um modelo de Redes Neurais Artificiais (RNA) para a previsão de preços mensais no mercado de boi gordo do estado de São Paulo para os meses de Outubro, Novembro e Dezembro de 1998. Os resultados obtidos são comparados com aqueles previstos pela Bolsa de Mercadorias e Futuros (BM&F) para o mesmo período. Conclui-se que a rede apresenta resultados satisfatórios e superiores àqueles obtidos pela cotação da BM&F na previsão de preços para o mercado físico de boi gordo.

Abstract

In this study, a Artificial Neural Network (ANN) is built to forecast monthly live cattle prices in the state of São Paulo for the months of October, November and December of 1998. The results are compared with those obtained in the Brazilian Futures Market (BM&F) for live cattle in the same period. The results indicate that the Neural Network exhibits better forecasting accuracy than the Futures Market quotation for the live cattle spot market.

TERMOS PARA INDEXAÇÃO - Redes Neurais Artificiais, Previsão de preços, Mercados Futuros, Boi Gordo.

Introdução

Aprevisão de preços é um importante instrumento de auxílio no processo de tomada de decisão de agentes econômicos envolvidos em atividades de planejamento, avaliação de políticas e redução de incerteza. Atualmente, os mercados futuros se constituem numa alternativa viável de administração e transferência do risco, envolvendo ativida-

¹ Economista (UFRJ), 1995. Doutorando em Economia Rural (UFV).



des agropecuárias. Isto porque ela permite a cotação prévia do preço a ser exercido no futuro para um determinado contrato, transferindo os riscos de oscilação de preços para agentes dispostos a assumir esses riscos (no caso, especuladores) e garantindo um preço justo, isto é, que reflita as forças de oferta e demanda naquele momento, para produtores, processadores e comerciantes do produto.

Nesse sentido, pode-se dizer então que os mercados futuros são um instrumento de previsão de preços que reflete toda a informação relativa às forças de oferta e demanda pelo produto, contribuindo no processo de tomada de decisão dos agentes envolvidos².

Modelos estatísticos paramétricos e não-paramétricos também são úteis na construção de previsões de preços para o setor agrícola. Dentre os modelos não-paramétricos, destaca-se o modelo de Redes Neurais Artificiais (RNA), que vem sendo constantemente utilizado na construção de modelos de previsão para preços e cotações do mercado financeiro em geral.

Os modelos RNA são uma tentativa não paramétrica de modelagem do processo de aprendizado do cérebro humano, através da elaboração de redes que "aprendem" a reconhecer, através de um algoritmo específico, o padrão de comportamento de uma série de dados de entrada, através de um processo de tentativa e erro³. As RNA são, desse modo, ferramentas poderosas de previsão, especialmente quando o padrão de comportamento da série em estudo é desconhecido.

No caso de variáveis econômicas, os modelos de RNA seriam então instrumentos úteis na construção de previsões que auxiliem no processo de tomada de decisão e conseqüentemente de redução da incerteza. Kuan e Liu (1995), Grudnitski e Osburn (1993), Kohzadi et ali. (1995), Ntungo e Boyd (1998), entre outros, elaboraram estudos comparativos do desempenho de modelos RNA com os mercados futuros para diversos contratos. Os resultados, em sua maioria, indicaram que as RNA apresentaram um desempenho superior aos mercados futuros na previsão de preços ou cotações de contratos.

Objetivo

O presente estudo tem por objetivo comparar os resultados das previsões obtidas com um modelo RNA aplicado ao mercado físico de boi gordo do estado de São Paulo com as previsões efetuadas pela BM&F para os meses de Outubro, Novembro e Dezembro de 1998. Para isso, são utilizados dados referentes ao preço real praticado no dia 15 de cada mês (ou o dia útil mais próximo) para o mercado físico entre janeiro de 1995 e Dezembro de 1998. Tal escolha se baseia no critério sugerido

²Teixeira, 1992.

³Kuan e White, 1994.

por Kenyon et ali. (1993) para a determinação do preço representativo de cada mês analisado.

O critério de comparação dos resultados será a estatística de erro quadrado médio de previsão (EQMP), tal como proposto por Kohzadi et ali. (1995). Algebricamente, o EQMP se define por:

$$EQMP = \frac{\sum (P - V)^2}{n} \quad (1)$$

onde P é o valor previsto e V é o valor observado para a cotação mensal do preço do boi gordo no mercado físico de São Paulo, e n é o número de períodos previstos. Quanto menor o EQMP, melhor a previsão estimada do modelo.

Metodologia

Os modelos de Redes Neurais Artificiais (RNA) se diferenciam dos modelos tradicionais de previsão por serem modelos não paramétricos envolvendo algoritmos de aprendizado. Tais algoritmos buscam imitar a estrutura de interconexões do cérebro humano, com o intuito de incorporar o padrão de comportamento de uma série temporal de modo a prever da maneira mais eficiente possível valores futuros da mesma.

A construção de um modelo RNA envolve desde a modelagem adequada da rede, até as transformações utilizadas para transmitir os dados à rede e métodos utilizados para interpretar os resultados obtidos pela mesma. Esses três aspectos (modelagem, transformações e interpretação) são fundamentais na utilização das RNA para previsão de preços futuros.


De acordo com Zirilli (1997), as RNA são constituídas por um número determinado de neurônios artificiais (ou elementos processadores) unidos por um grande número de conexões ponderadas que codificam o conhecimento da rede. Muitos neurônios podem processar sua informação independentemente dos outros, embora existam ligações e dependências básicas entre a maioria.

A ênfase das RNA reside no aprendizado automático das representações internas ou ponderações, através de dois métodos de treinamento (algoritmos): *supervisionado* e *não supervisionado*. No algoritmo supervisionado, a solução ótima desejada deve ser especificada *a priori*, com o processo de aprendizado montado a partir de valores aleatórios para as ponderações, modificando-as iterativamente até a obtenção da solução ótima. O algoritmo não supervisionado não requer a especificação da solução ótima, permitindo que os neurônios determinem quais as ponde

rações características da série de modo a determinar o padrão de comportamento desta⁴.

A unidade básica de uma RNA é o neurônio artificial. Sua estrutura busca reproduzir a estrutura do neurônio humano, tendo assim três componentes básicos (figura 1): um elemento somatório S ; uma *função de ativação* f ; e as ponderações w_i .

Figura 1
O neurônio artificial⁵



O neurônio artificial soma os x_n entradas/insumos ponderados por w_i , que passa pela função de ativação f ⁶ resultando no produto y . Matematicamente, esse procedimento equivale a

$$y = f\left(\sum_{i=0}^N x_i w_i\right) \quad (2)$$

Na modelagem das RNA, a forma típica da função de ativação é a seguinte⁷:

$$f = \frac{1}{1 + e^{-z}} \quad (3)$$

onde

$$z = \sum_{i=0}^N x_i w_i \quad (4)$$

Como pode ser observado na equação (2), o somatório vai de 0 a N. Isto porque x_0 constitui o *viés* e assume o valor 1, conforme ilustrado na figura 1. O viés é adicionado para dar capacidade do neurônio tender para um nível específico.

A RNA é então constituída por diferentes *camadas*⁸ (figura 2). A camada de entrada (x) fornece os insumos (dados ou informações), sem ne-

⁴ Zirilli (1997).

⁵ Extraído de Zirilli (1997).


⁶ Que segue um tipo específico de não linearidade de acordo com o padrão dos insumos x_i .

⁷ Corrêa e Portugal (1998).

⁸ Zirilli (1997) e Kohzadi et al. (1995)

nhum procedimento computacional. A camada oculta (h) recebe as informações da camada de insumos ou de outra camada oculta e fornece informações para outra camada oculta ou para a camada de saída. A camada de saída (y) recebe informações da camada oculta e fornece o produto da rede. A rede descrita na figura 2 é do tipo *feed forward* (transmissão em um só sentido), um exemplo simplificado de RNA, uma vez que as informações podem na verdade movimentar-se em várias direções.

Figura 2
RNA do tipo *feed forward*



O algoritmo mais usual utilizado no processo de aprendizagem de uma RNA é o algoritmo de *backpropagation*, que permite realizar as transformações necessárias para a transmissão dos dados para a rede, possibilitando a formação de previsões consistentes com o comportamento da série em estudo.

O algoritmo de *backpropagation* ajusta as ponderações de modo a minimizar os erros de previsão dentro da amostra. As ponderações são revisadas a cada iteração, de acordo com a superfície de erros tentando atingir um mínimo global. O algoritmo de *backpropagation* é formalizado nas seguintes equações, de acordo com Corrêa e Portugal (1998):

$$\Delta w_{ij,k}^n = \eta \cdot \delta_{j,k} \cdot y_{i,k-1} \quad (5)$$

$$w_{ij,k}^{n+1} = w_{ij,k}^n + \Delta w_{ij,k}^n \quad (6)$$

$$\delta_{j,k} = \left(\frac{dy}{dz} \right)_{i,k} \cdot (y_{i,k} - y_{i,k}^T) \quad (7)$$

com $i = 1, 2, \dots, I$; $j = 1, 2, \dots, J$ e $k = K$
onde:

η é o coeficiente de aprendizado ($0,01 \leq \eta \leq 1,00$)

$y_{i,k}$ é a saída do neurônio i na camada k ;

$y_{i,k}^T$ é o valor desejado para $y_{i,k}$;

$w_{ij,k}^n$ é a ponderação ligando o neurônio i na camada $k - 1$ ao neurônio j na camada k no passo n .

O algoritmo só pode ser aplicado à camada de saída, pois pressupõe-se que o valor desejado de saída é conhecido, o que é possível na última camada, onde $k=K$. Nas camadas ocultas, o valor de $\delta_{i,k}$ é dado por uma propagação para trás de $\delta_{i,k}$ a partir das ponderações em cada camada, com

$$\delta_{j,k} = \left(\frac{dy}{dz} \right)_{i,k} \left(\sum_j \delta_{j,k} w_{ij,k} \right); \quad k = 1, 2, \dots, K - 1. \quad (8)$$

A convergência ao mínimo pode ser obtida a partir de (5) e (6) através de uma transformação auto-regressiva levando a⁹


$$\Delta w_{ij,k}^{n+1} = \eta (\delta_{j,k} \cdot y_{i,k-1}) + \alpha (\Delta w_{ij,k}^n) \quad (9)$$

$$w_{ij,k}^{n+1} = w_{ij,k}^n + \Delta w_{ij,k}^{n+1} \quad (10)$$

Definido o algoritmo, a RNA pode identificar o padrão da série de preços no mercado físico e realizar previsões a partir de generalizações da série num espaço N-dimensional (figura 3).

FIGURA 3

Esquema de uma RNA para previsão de preços no mercado físico



Este esquema simplificado ilustra o procedimento necessário na modelagem de uma RNA aplicada à previsão de preços no mercado físico de boi gordo. Contudo, a escolha da estrutura ideal da RNA é uma tarefa difícil, envolvendo desde a definição do número de observações a ser utilizado até a determinação dos componentes da camada oculta.

Raposo (1992) sugere um critério baseado no comportamento das funções de autocorrelação e autocorrelação parcial da série em estudo, para o caso de modelagem univariada da rede neural.

De acordo com o autor, se o comportamento gráfico da função de autocorrelação apresenta uma tendência de declínio exponencial, oscilante ou senoidal, é necessária uma análise da função de autocorrelação parcial. Se esta apresenta uma queda rápida a partir de uma determinada defasagem k , então o número de camadas de entrada da rede será dado por $N = k + 1$.

⁹ De acordo com Corrêa e Portugal (1998).

Por outro lado, se a função de autocorrelação apresenta uma queda rápida a partir de uma determinada defasagem k , o número de entradas será determinado pela maior defasagem em ambos os gráficos das funções de autocorrelação e autocorrelação parcial.

Resultados e Discussão

Os dados para a construção da rede foram obtidos junto à BM&F, e se referem ao preço praticado no dia 15 de cada mês, ou o dia útil mais próximo. No total, são utilizadas 48 observações. A rede foi construída com duas entradas (definidas pelo autocorrelograma e autocorrelograma parcial), faixa de treinamento de 36 observações e faixa de teste de 9 observações.

Os resultados são comparados com aqueles apresentados pela cotação do contrato futuro de boi gordo da BM&F para o dia 15 de setembro de 1998, última observação na qual os modelos RNA se basearam para a formulação das previsões.

O correlograma e o correlograma parcial da série têm o seguinte comportamento:

Autocorrelação	Autocorrelação Parc.	N	Valores	
			AC	ACP
. *****	. *****	1	0.867	0.867
. *****	. . .	2	0.767	0.060
. *****	. . .	3	0.717	0.161
. *****	** . .	4	0.593	-0.288
. ****	** . .	5	0.552	0.277
. ****	. . .	6	0.559	0.127
. ****	. . .	7	0.510	-0.041
. ****	. . .	8	0.496	0.021
. ****	. . .	9	0.474	-0.073
. ***	** . .	10	0.373	-0.192
. ***	. . .	11	0.332	0.105
. **	. . .	12	0.283	-0.115
. . .	** . .	13	0.154	-0.267
.	14	0.078	-0.137
.	15	0.002	-0.115
.	16	-0.082	0.080
.	17	-0.093	0.051
.	18	-0.135	-0.180
.	19	-0.195	-0.048
.	20	-0.210	-0.007

Visualizando o comportamento dos dois gráficos, observa-se que a função de autocorrelação apresenta uma tendência de queda exponencial, ao passo que a função de autocorrelação parcial cai abruptamente após a primeira defasagem. Deduz-se então que as entradas da rede neural são p_{t-2} e p_{t-1} , dado que a autocorrelação parcial de primeira ordem tem o valor de 0,867.

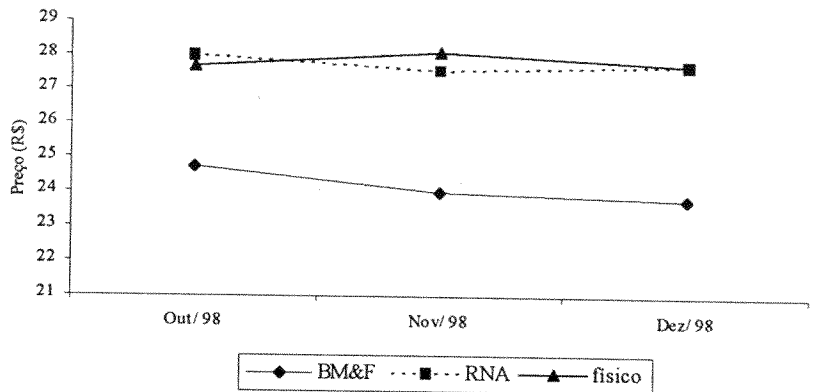


O modelo utilizado é então de natureza recursiva, uma vez que se baseia no comportamento passado da variável para prever seu comportamento futuro. A estruturação, treinamento da rede e realização das previsões feita utilizando-se o software *Braincel 3.0* (Promised Land Technologies, 1996).

A rede foi estruturada com duas entradas, uma camada oculta e uma saída. Para o treinamento da rede, foram testadas diversas combinações para os valores da taxa de aprendizado e do peso inicial. Cada combinação foi testada cinco vezes, e aquela que apresentou o menor erro quadrado para a faixa de teste foi escolhida para a realização das previsões.

O gráfico a seguir mostra o valor das previsões do modelo RNA e do mercado futuro de boi gordo para os preços nos meses de Outubro, Novembro e Dezembro de 1998.

Gráfico 1
 Valores previstos e observados dos preços de boi gordo



O desempenho estatístico das previsões é descrito pelo quadro abaixo. Nele, observa-se que as previsões do modelo RNA apresentaram menor EQMP para o período analisado.

Quadro 1
 Previsões para o preço de boi gordo

	BM&F	RNA	M.Físico
15 de Outubro/98	24,73	28,00	27,68
14 de Novembro/98	24,00	27,57	28,09
15 de Dezembro/98	23,80	27,74	27,73
EQMP	13,63	0,12	—

Conclusões

Os modelos de Redes Neurais Artificiais são um importante instrumento no processo de tomada de decisões de agentes econômicos ao possibilitar a formulação de previsões para o comportamento de diversas variáveis. Os resultados obtidos nesse trabalho vêm a confirmar tal fato, ao mostrar que o desempenho da rede construída para prever preços do mercado físico de boi gordo para São Paulo apresentou resultados superiores àqueles observados nas cotações da BM&F para os meses de Outubro, Novembro e Dezembro de 1998. Os resultados são convergentes com aqueles verificados em outros estudos que comparam o desempenho das redes com mercados futuros de diversos produtos. Assim, pode-se concluir que as redes neurais são um importante instrumento de auxílio no processo de tomada de decisão quando as variáveis-chave do processo apresentam comportamento não linear.

Bibliografia

- CORRÊA, W.R. PORTUGAL, M.S. Previsão de séries de tempo na presença de mudança estrutural: redes neurais artificiais e modelos estruturais. in.: *Economia Aplicada*, vol. 2, n° 3, 1998.
- GRUDNITSKI, G., OSBURN, L. Forecasting S&P and Gold Futures Prices: An Application of Neural Networks, in.: *The Journal of Futures Markets*. Vol. 13, n° 6, 1993.
- JUST, R.E., RAUSSER, G.C. Commodity Price Forecasting with Large-Scale Econometric Models and the Futures Markets, in.: *American Journal of Agricultural Economics*. n° 63, 1981.
- KENYON, D., JONES, E., MCGUIRK, A. Forecasting Performance of Corn and Soybean Harvest Futures Contracts. in.: *American Journal of Agricultural Economics*, vol. 75, 1993.
- KOZHADI, N.; BOYD, M. S.; KAASTRA, I.; KERMANSHAHI, B. S.; SCUSE, D. Neural Networks for Forecasting: An Introduction. in.: *Canadian Journal of Agricultural Economics*, n° 43, 1995.
- KUAN, C.M., LIU, T. Forecasting Exchange Rates Using Feedforward and Recurrent Neural Networks, in.: *Journal of Applied Econometrics*, vol. 10, 1995.

KUAN, C.M., WHITE, H. Artificial Neural Networks: An Econometric Perspective. in.: *Econometric Reviews*, vol. 13, 1994.

NTUNGO, C., BOYD, M. Commodity Futures Trading Performance Using Neural Networks Models versus ARIMA Models. in.: *The Journal of Futures Markets*, vol. 18, 1998.

RAPOSO, C.M. *Redes Neurais na Previsão de Séries Temporais*. Rio de Janeiro, COPPE/UFRJ, 1992 (Tese Mestrado).

TEIXEIRA, M. A. *Mercados Futuros: Fundamentos e Características Operacionais*. São Paulo, BM&F, 1992.

ZIRILLI, J.S. *Financial Prediction Using Neural Networks*. New York, International Thomson Publishing, 1996.