

APLICAÇÃO DE REDES NEURAIS DIRETAS NA PREVISÃO DE PREÇOS DE OVOS

Autor(es)

Milena Tápia

Email: milena@inf.ufsc.br
Vínculo: Universidade Federal de Santa Catarina - UFSC
Endereço: Centro Tecnológico
Telefone: (048) 331.7515

Mauro Roisenberg

Email: mauro@inf.ufsc.br
Vínculo: Universidade Federal de Santa Catarina - UFSC
Endereço: Centro Tecnológico
Telefone: (048) 331.7515

Jorge Muniz Barreto

Email: barreto@inf.ufsc.br
Vínculo: Universidade Federal de Santa Catarina - UFSC
Endereço: Centro Tecnológico
Telefone: (048) 331.7515

Resumo

Este artigo, propõe discutir e avaliar a habilidade dos modelos conexionistas em realizar previsões acuradas de séries temporais, no caso específico, os preços de ovos pagos ao produtor.

O estudo justifica-se devido a inaplicabilidade da metodologia Box-Jenkins (1976) para previsões de horizontes temporais mais longos. A avaliação do modelo foi realizada comparando-se os resultados obtidos com os alcançados pela aplicação dos modelos ARIMA. Além da qualidade da previsão, foram avaliados aspectos como a facilidade de aplicação e utilização.

Os experimentos mostram que além da simplicidade, RNAs simples permitem previsões acuradas para horizontes de tempo mais longos.

Abstract

This paper, intends to discuss and to evaluate the ability of the connectionist models in accomplishing accurate time series, forecast, in this case, the producer prices of eggs.

The study is justified due to the inapplicability of the Box-Jenkins methodology (1976) for long term forecasts. The evaluation of the model was did comparing the results obtained by the NN with those reached by the application of the ARIMA models. Besides the quality of the forecast, we discussed aspects as the model building process and the applicability of the NN approach.

The experiments indicate that besides the simplicity, simple ANNs allows accurate long term forecasts.

Palavras Chaves

Previsão de Séries de Tempo; Redes Neurais Diretas; Preço de Ovos pagos ao produtor.

1. INTRODUÇÃO

A partir da década de setenta, tem sido grande a proliferação de modelos univariados de previsão de séries de tempo, com aplicação em economia. Esses modelos tem como objetivo principal, a realização de previsão, com base apenas nos valores presentes e passados da própria série que se deseja prever. Em algumas extensões, outras séries podem ser utilizadas mas, de forma geral, não é necessário a especificação de um modelo econométrico completo. Experiência prática tem mostrado que, com apenas uma série de tempo, é possível se ter uma previsão de curto prazo satisfatória (Corrêa & Portugal, 1997).

A renovação e o aperfeiçoamento dos modelos tem sido constantes (MAKRIDAKIS, et al., 1998). Os modelos ARIMA, que foram largamente utilizados nas décadas de setenta e oitenta, foram rapidamente substituídos pelos modelos estruturais de séries de tempo, e estes, já começam a ser questionados quanto à sua eficiência em gerar previsões de curto prazo, pelos modelos conexionistas, também chamados Redes Neurais Artificiais - RNAs.

Este artigo, tem como objetivo, discutir e avaliar a habilidade dos modelos conexionistas em realizar previsões acuradas para um horizonte de tempo longo, de uma série de preços de ovos pagos ao produtor. Os resultados alcançados com a RNA são comparados com os obtidos pela aplicação do modelo ARIMA. Aspectos como a qualidade das previsões, facilidade de implementação e utilização, também são abordados.

Além desta introdução, este trabalho apresenta mais 3 seções. A segunda tese as motivações que nos levaram a explorar a habilidade das RNA na previsão de preços de ovos, em especial. A seção seguinte apresenta os materiais e métodos utilizados. Por fim, na última seção, são apresentadas as conclusões obtidas.

2. MOTIVAÇÃO

A indústria avícola, como qualquer outra atividade agrícola, é caracterizada pelo alto grau de incerteza associado a seus processos decisórios.

No processo de comercialização de ovos, por exemplo, o tipo e o tamanho dos ovos devem ser selecionados de acordo com as exigências do mercado. Além disso, os custos de produção e os preços do mercado apresentam grandes flutuações durante o ano, dificultando na organização, programação e comercialização da produção.

Além do investimento extra que se tem na formação das poedeiras, cuja formação demora quase cinco meses, deve-se ter em mente que o produto é perecível e a produção se dá em fluxo constante, não podendo ser ajustada rapidamente às eventuais tendências de saturação do mercado, sob pena de queima de capital (Martins, 1996).

Como o ovo é consumido, predominantemente, in natura e a ração é geralmente feita pelos próprios criadores, nesta atividade, é o próprio criador que administra e toma as

decisões de ampliação ou redução da produção (Martins, 1999). Não existindo diferenciação de produto, a competição entre os produtores se dá em torno de preços, não de marcas. O sistema de preços atua então, como um sinalizador das principais tendências dos produtores e consumidores.

Desse modo, uma estimativa do preço futuro como informação no processo de tomada de decisão, poderia auxiliar o produtor a decidir o melhor momento para se iniciar, ou interromper a produção de ovos, maximizando o lucro e diminuindo os riscos.

Esse artigo, busca nas RNA, uma previsão mais longa e acurada para a série de preço de ovos pagos ao produtor, que as obtidas com os métodos de previsão tradicionais.

3. MATERIAIS E MÉTODOS

Os dados utilizados neste estudo provêm de levantamentos efetivados pelo Instituto de Economia Agrícola - IEA, referindo-se a médias mensais para os preços reais (deflacionados pelo IGP - DI) do preço do ovo branco (tipo grande) pagos ao produtor.




Figura 1 - Preços Reais do Ovo Branco (tipo grande) Pagos ao Produtor de São Paulo: Jan/85 a Dez/99

A figura 1 deixa claro que a série em estudo apresenta tendência decrescente, sazonalidade e ciclo como características marcantes.

O fator sazonal mostra três períodos de pico anual no preço de ovos ao produtor durante os meses de junho/agosto, em função do outono e inverno (o preço do ovo aumenta devido a produção menor, característica do ciclo biológico das aves). Além disso, podemos perceber um período de redução sazonal entre os meses de janeiro e abril, onde a produção é maior, aumentando a disponibilidade do produto e ocasionando a queda nos preços.

A componente tendência-ciclo, apresentada nas figuras 2 e 3, aponta para um declínio não linear da série, indicando, portanto, uma redução do preço do ovo ao longo do período analisado.




Figura 2 - Componente Sazonal




Figura 3 - Componente Tendência

De acordo com (MAKRIDAKIS, et al., 1998) o preço, excluindo a inflação, da maioria dos produtos e serviços padronizados diminui com o tempo. Segundo o autor, isso é normal devido ao aumento da oferta sobre a demanda e, com a revolução da informação, o declínio tende a acelerar ainda mais.




Figura 4 - Componente Irregular

Por último, é apresentado na figura 4, o componente irregular da série. Como podemos observar, há uma redução na variância do componente irregular para o período após 1991.

O conjunto de observações entre 1985 e 1997 será utilizado como conjunto de ajuste dos modelos (fase de aprendizado), ficando os dois anos restantes, 1998 e 1999, para serem utilizados na realização das previsões (validação dos modelos).

Os dados foram pré-processados aplicando-se a transformação logarítmica e ajustando-se conforme o número de dias de cada mês.

3.1 - METODOLOGIA BOX-JENKINS

Optou-se, neste trabalho, pelo uso do modelo de Box & Jenkins, empregando especificamente o modelo auto-regressivo, integrado, de média móvel sazonal¹ $SARIMA(p, d, p).(P, D, Q)_s$, por se tratar do preço de um produto agrícola que recebe a influência de fatores sazonais. A estimação de modelos $SARIMA(p, d, p).(P, D, Q)_s$ segue as etapas de identificação, estimação dos parâmetros, verificação e previsão, respectivamente (MAKRIDAKIS, et al., 1998).

¹ Segundo (MAKRIDAKIS, et al., 1998), quando uma série temporal apresenta autocorrelação nos resíduos, ou correlação significativa em 'lags' de baixa ordem, o ajustamento é feito através do modelo ARIMA. Porém, quando se observam correlações entre 'lags' múltiplos de um determinado período s , devemos ajustar aos dados um modelo ARIMA sazonal (SARIMA).

Neste sentido, considerando um comportamento sazonal com período igual a s , pode-se escrever o modelo $SARIMA(p, d, p).(P, D, Q)_s$ da seguinte forma (FAVA, 2000):

$$\phi(B)\Phi(B^s)(1-B^s)^D(1-B)^dY_t=\theta(B)\Theta(B^s)e_t \quad (1)$$

Onde:

$$\Phi(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps} \quad (2)$$

É o operador auto-regressivo sazonal de ordem P , estacionário;

$$\Theta(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs} \quad (3)$$

É o operador de médias móveis sazonal de ordem Q , invertível, e,

$$(1 - B^s)^D = \Delta^D \quad (4)$$

É o operador de diferença sazonal, onde D representa o número de "diferenças sazonais".

No presente ensaio, utilizando-se do pacote estatístico "*Statistica*", realizou-se o processo de identificação (através das funções de autocorrelação e autocorrelação parcial), selecionando-se uma série de modelos possíveis a serem testados.² O modelo que apresentou melhor desempenho foi o modelo $SARIMA(5,1,0)(0,0,2)^{12}$.

3.1 - MODELO CONEXIONISTA

De acordo com (Mozier, 1993) qualquer arquitetura para processar padrões que variam no tempo, requer de forma conceptiva dois componentes distintos: uma memória de curto-tempo, que guarda eventos passados relevantes, e um associador, que usa o conteúdo da memória para classificar ou prever novos dados.

Seguindo esta metodologia, a arquitetura que obteve os melhores resultados na realização dos prognósticos da série de preço de ovos é mostrada na figura 5.




Figura 5 - Arquitetura da RNA para Previsão do Preço de Ovos

² Para efeito de simplificação, foi retratado, neste trabalho, apenas o modelo que apresentou o melhor resultado de uma série de tentativas implementadas.

Ela é composta por uma memória de curto-tempo tipo "*delay-line*" e uma rede neural direta multicamadas completamente conectada, como associador. A rede apresenta 13 neurônios na camada de entrada, 10 na intermediária e 1 na camada de saída, ou seja, $RNA(13,10,1)$.

Esta RNA foi então treinada utilizando-se o algoritmo de retropropagação do erro (*Backpropagation*), a partir dos seguintes parâmetros:

- O conjunto de observações foi apresentado 200 000 vezes para a rede;
- Constante de aprendizado (α) = 0,05;
- Termo de momento (β) = 0,4 durante todo o treinamento;
- Função de transferência igual para todos os neurônios (tangente hiperbólica).

4. RESULTADOS E CONCLUSÕES

As previsões obtidas pelas RNAs, foram comparadas com as provenientes do modelo ARIMA, através dos seguintes indicadores: Erro Médio (*ME*), Erro Absoluto Médio (*MAE*), Erro Quadrado Médio (*MSE*), Erro Percentual Absoluto Médio (*MAPE*) e o coeficiente de desigualdade (U_2) de Theil (1966). Esse último indicador tem a fórmula:

$$U_2 = \sqrt{\frac{\sum_{t=1}^T (\Delta P_t - \Delta A_t)^2}{\sum_{t=1}^T \Delta A_t^2}} \quad (5)$$

Onde P_t é a variação prevista em relação à observação anterior, e A_t é a variação efetivamente realizada. A interpretação de U_2 é simples: se for igual a zero, as variações previstas são iguais às observadas (previsões perfeitas); quanto menor for o valor de U_2 , melhor o procedimento de previsão.

Os resultados obtidos, podem ser visualizados na tabela 1.

Medida de Exatidão	NF1	RNA	SARIMA
ME	0,141	-0,135	0,337
MAE	1,482	0,981	1,441
MSE	3,269	1,718	2,947
MAPE (%)	7,412	4,836	7,149
U_2	1,000	0,675	0,898

Tabela 1: Comparação dos Resultados Obtidos

Como pode-se perceber, o MAPE obtido pela aplicação das RNAs, ficou abaixo de 5%, enquanto que para o modelo ARIMA, o erro ficou em torno de 7%. O teste U_2 de Theil, comprova os resultados.




Figura 6 - Comparação dos Resultados Obtidos

O fato do modelo de RNA ter conseguido resultados tão expressivos confirma sua capacidade de realizar prognósticos precisos. Os resultados obtidos pelas duas formas de previsão, ilustrados na figura 6, mostram que tanto para previsões a curto prazo, quanto para horizontes mais longos, a RNA está prevendo melhor.

Conforme (MAKRIDAKIS, et al., 1998) e (WEIGEND & GERSHENFLD, 1994) citam, a qualidade da previsão obtida, depende muito da natureza da série em estudo. Sendo assim, este trabalho não tem a pretensão de estabelecer que as RNA, mais especificamente o modelo Perceptron Multi-camadas com aprendizado por retropropagação de erros, apresenta-se como o melhor método de previsão de valores futuros de séries de tempo. Porém, em face dos resultados apresentados, pode-se dizer com segurança que as RNAs são uma ferramenta poderosa para a realização de previsão de séries tempo. Na verdade, este artigo soma-se a uma literatura empírica, que já está se tornando volumosa, onde as RNA aparecem como o melhor método de previsão.

Em termos de facilidade de aplicação e utilização, a maior parte do tempo necessário para construção de uma RNA é gasta no processo de treinamento. Experimentos também podem ser necessários na determinação da arquitetura ótima da rede.

Se comparado ao modelo ARIMA, o campo das RNA não está ainda completamente maduro. Ao contrário dos modelos ARIMA, os modelos de RNAs não possuem um procedimento sistemático para sua construção. Frequentemente, procedimentos *ad hoc* ou até mesmo estruturas de RNA, e métodos de aprendizado arbitrários são usados. Porém, devido à robustez do modelo, na maioria das vezes, ainda assim, é possível se conseguir um bom desempenho.

Escolher uma RNA adequada é relativamente fácil se comparada a construção do modelo ARIMA. O processo de Identificação e Validação do modelo ARIMA necessita de conhecimento especialista. Além disso, não é fácil de entender o mecanismo estatístico usado no procedimento de identificação do modelo. No sentido de que menos conhecimento estatístico e participação do usuário são requeridos, modelos de RNAs são relativamente mais fáceis de usar do que os modelos ARIMA.

5. REFERÊNCIAS

- CORRÊA, W.R.; PORTUGAL, M.S. Previsão de Séries de Tempo na Presença de Mudança Estrutural: Redes Neurais Artificiais e Modelos Estruturais.

Trabalho apresentado ao XVIII International Symposium on Forecasting, Edinburgh, Escócia, 1997.

- FAVA, V. L. Metodologia de Box-Jenkins para modelos univariados. In: VASCONCELLOS, M.A.S.; ALVES, D. Manual de Econometria. São Paulo: Ed. Atlas, 2000. P.205-231.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; HYNDMAN, R.J. Forecasting - Methods and applications. Ed. 3. New York: John Wiley & Sons, Inc., 1998.
- MARTINS, S.S. Cadeias produtivas do frango e do ovo: avanços tecnológicos e sua apropriação. Tese (Doutorado em Economia) - Economia de Empresas, Escola de Administração de Empresas de São Paulo da Fundação Getúlio Vargas, São Paulo, 1996.
- MARTINS, S.S. Mecanismos de coordenação nas cadeias produtivas do frango e do ovo. Informações Econômicas, v.29, n. 6. IEA, São Paulo, 1999
- MOZER, M.C. Neural Net Architectures for Temporal Sequence Processing. In: MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; HYNDMAN, R.J. Forecasting - Methods and applications. Ed. 3. New York: John Wiley & Sons, Inc., 1998.
- WEIGEND, A.S.; GERSHENFELD, N. A. Time series prediction - Forecasting the future and understanding the past. Massachusetts: Perseus Books Publishing, 1994.