

Modelos de previsão de preços aplicados aos contratos futuros de boi gordo na BM&F

Aureliano Angel Bressan

Professor do Departamento de Ciências Administrativas
FACE/Universidade Federal de Minas Gerais

João Eustáquio de Lima

Professor Titular do Departamento de Economia Rural
Universidade Federal Viçosa

Palavras-Chave

Previsão de preços, tomada de decisão, mercados futuros, modelos de séries temporais.

Classificação JEL C32; C53; E37

Key Words

Price forecasting, decision making, futures markets, time series models.

JEL classification C32; C53; E37

Resumo

Este artigo trata da aplicabilidade de modelos de previsão de séries temporais como ferramenta de decisão de compra e venda de contratos futuros de boi gordo na BM&F, em datas próximas ao vencimento. Os modelos estudados são: ARIMA e Redes Neurais, Modelos Lineares Dinâmicos (MLD, nas abordagens clássica e bayesiana). Os dados correspondem às cotações semanais, nos mercados físico e futuro, entre 1996 e 1999. O objetivo consiste em calcular os retornos médios dos modelos em operações de compra/venda no mercado futuro de boi gordo, entre 1998 e 1999, de modo a indicar o potencial ou limitação de cada um destes. Os resultados apresentaram retornos financeiros positivos na maioria dos contratos analisados, indicando o potencial de utilização desses modelos como ferramenta de decisão em negociações de contratos para datas próximas ao vencimento, com destaque para operações fundamentadas nas previsões nos MLD (abordagem clássica) e ARIMA havendo, contudo, diferenças de desempenho preditivo.

Abstract

This paper studies the applicability of time series models as a decision tool of buy and sell orders of live cattle futures contracts in the Brazilian Futures Market (BM&F), on dates close to expiration. The models considered are: ARIMA, Neural Networks and Dynamic Linear Models – DLM (this in the classic and bayesian approach). Weekly data, of the spot and futures markets, from 1996 to 1999, are used to calculate the forecasts. The main purpose is to calculate the returns, in buy/sell orders of live cattle futures between 1998 and 1999, in order to show the potentials or limitations of each model. The results show positive returns in almost all contracts analyzed, indicating the potential of the models as a decision tool in operating with futures contracts close to expiration date, with distinction on the performance of the Classic DLM and ARIMA models, although some differences in forecasting accuracy.

1_ Introdução

A previsão sempre foi um dos objetivos das análises quantitativas em economia. Em conjunto com a teoria econômica, diversas técnicas de previsão auxiliam a tomada de decisões por parte dos agentes envolvidos em atividades que necessitam de planejamento, avaliação de políticas e redução da incerteza. Um dos objetivos das previsões econômicas, a redução da incerteza, é de especial importância dentro do setor agropecuário, constantemente sujeito a distúrbios irregulares.

Deste modo, a produção agropecuária necessita de instrumentos que minimizem o risco, e auxiliem no processo de tomada de decisão dos agentes participantes do agronegócio (produtores, compradores e investidores em geral). Este é o enfoque da presente pesquisa, que tem o objetivo básico de determinar a viabilidade de aplicação de modelos de previsão de preços na negociação de contratos futuros de boi gordo.

Com o intuito de administrar riscos de mercado (oscilação de preços), o mercado futuro permite a permuta destes riscos com especuladores, apresentando-se como importante instrumento de segurança e sinalização de preços para todos os participantes da cadeia agroindustrial. Hull (1996), sintetiza esta relação,

definindo os contratos futuros como compromissos de compra ou venda de um determinado ativo numa data pré-estabelecida e a um preço (cotação) que reflete as forças de oferta e demanda que atuam naquele momento.

No mercado futuro de boi gordo, os preços são influenciados por fatores de natureza sazonal, cíclica e irregular. A sazonalidade é caracterizada pelo período de “safra” de janeiro a junho, onde há fartura de pastagens; e “entressafra” de julho a dezembro. Já o ciclo (plurianual) é de aproximadamente seis anos, sendo um componente importante para a definição da evolução dos preços no longo prazo (Bacchi, 1995).

A principal característica do contrato futuro de boi gordo da BM&F é, conforme constatação de Teweles e Jones (1999), de que o produto pode ser entendido como “perecível” no sentido de que os animais devem ser abatidos em um curto espaço de tempo após o período de engorda, e eles não podem ser carregados de um contrato para outro. Por essa razão, os preços futuros de diferentes meses são relacionados apenas com as mudanças esperadas na relação oferta e demanda ao longo do tempo. Outra característica se refere à liquidação do contrato no vencimento através de uma

operação estritamente financeira, de reversão das posições ao preço definido pelo Indicador Esalq/BM&F (BM&F, 1997).

Uma das alternativas para reduzir a incerteza no processo de tomada de decisões econômicas é a utilização de modelos de previsão de séries temporais univariadas. Baseados na análise somente da variável em si, tais modelos são construídos a partir de processos estocásticos especiais, que buscam estimar o valor futuro da variável em questão com base somente em seus valores passados. Este tipo de análise se aplica nos casos em que há um padrão persistente ou sistemático no comportamento da variável, que é possível de captar através de uma representação paramétrica (Pindyck & Rubenfield, 1991).

2_ Definição do problema e objetivos

Nas transações envolvendo produtos agrícolas, a administração do risco relativo à volatilidade dos preços é um componente fundamental. Deste modo, a formação de previsões consistentes torna-se um importante instrumento na tomada de decisão dos participantes do mercado. O objetivo geral do trabalho é avaliar o

desempenho de modelos univariados, confrontando as cotações realizadas nos preços do mercado futuro com as previsões de modelos de previsão. Com isto pretende-se dar suporte a instrumentais mais adequados no processo de tomada de decisão de agentes ligados ao mercado de boi gordo.

O objetivo específico do presente estudo é comparar os retornos médios de cada modelo em operações de compra e venda nos mercados futuros de boi gordo, de modo a fornecer um indicativo do potencial ou limitação de cada um deles.

3_ Metodologia

A metodologia utilizada fundamenta-se na construção de modelos univariados de previsão de preços com base em dados de séries temporais. Há uma grande variedade de modelos aplicáveis a estudos desta natureza. Para os fins desta pesquisa, optou-se por selecionar os modelos ARIMA, Estruturais (abordagem clássica e Bayesiana) e de Redes Neurais.

3.1_ Modelos ARIMA

Os modelos ARIMA (Autorregressivo – Integrado – Média móvel), inicialmente formulados por Box & Jenkins (1976), baseiam-se na idéia de que uma série tem-

poral não-estacionária pode ser modelada a partir de d diferenciações e da inclusão de um componente autorregressivo e de um componente média móvel. Sendo $\{Y_t\}$ um processo que pode ser descrito através de uma modelagem ARIMA (p, d, q) da seguinte forma:

$$\phi_p(B)Z_t = \theta_0 + \theta_q(B)a_t \quad (1)$$

$$\text{onde: } Z_t = \begin{cases} Y_t \\ (1-B)^d \end{cases} \quad (2)$$

Y_t se o processo é estacionário, $d = 0$.

$(1-B)^d$ se o processo não é estacionário, $d > 1$.

que, ao se considerar a diferenciação de Y_t corresponderá a um modelo ARIMA (p, q, d) com:

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta_q(B)a_t \quad (3)$$

onde: $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ é o operador autorregressivo $AR(p)$, e $\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ é o operador média móvel $MA(q)$ e a_t é um processo ruído branco. Se $\theta_0 = (1 - \phi_1 - \phi_2 - \phi_3 - \dots - \phi_p)\mu$ for diferente de zero, a série integrada apresentará uma tendência determinística, ou seja, a série apresenta uma tendência crescen-

te ou decrescente que é independente dos distúrbios aleatórios (Pindyck & Rubenfield, 1991).

3.2_ Modelos Lineares Dinâmicos

Em contraposição à abordagem estática dos modelos ARIMA, os Modelos Lineares Dinâmicos são formulados com a característica de incorporar mudanças nos parâmetros, à medida que ocorrem evoluções na série temporal estudada.¹ O aumento no número de observações da série é interpretado, então, como informação adicional ao conjunto de informações atuais, fazendo com que os parâmetros apresentem uma evolução dinâmica, impedindo qualquer quantificação estática das relações subjacentes ao comportamento global da série (Pole *et. al.*, 1994).

Os Modelos Lineares Dinâmicos podem ser estimados sob duas abordagens alternativas: a abordagem clássica e a bayesiana. No primeiro caso, os modelos são também denominados de Modelos Estruturais de Séries Temporais (Harvey, 1991); enquanto que os MLD bayesianos podem ser também descritos como Modelos Bayesianos Univariados, ou Modelos Bayesianos (Mattos, 1998).

.....
¹ Vale observar que os MLD incorporam os modelos estáticos como casos especiais.

3.3 Modelos Estruturais

Os Modelos Estruturais surgiram como uma alternativa aos modelos Box & Jenkins (Vicente, 1992). Em tais modelos, a série Y_t é decomposta em termos da tendência (μ_t), do ciclo (Ψ_t), da sazonalidade (γ_t) e de um componente irregular (ε_t):

$$Y_t = \mu_t + \gamma_t + \Psi_t + \varepsilon_t \quad (4)$$

A especificação de cada um dos componentes dá o modelo completo. A equação (4) também é conhecida como *equação das medidas* ou *equação das observações*. Existem diversas variantes dessa equação básica, que divergem da mesma pela ausência de um dos componentes ou pela relação dos mesmos (que pode ser multiplicativa), em função da natureza dos dados analisados.²

A operacionalização do modelo é obtida adotando-se o modelo de *espaço de estados* e utilizando-se o *filtro de Kalman* para a atualização seqüencial dos componentes não observáveis.

A representação em espaço de estados é feita através de um sistema de duas equações dinâmicas que descrevem a maneira pela qual as observações são geradas em função do vetor de estados e a evolução dinâmica desse vetor.

Assim, a abordagem de espaço de estados serve para reformular o modelo, atualizando-o para novas observações da

série Y_t . O filtro de Kalman é então utilizado para criar uma estimativa ótima do estado, buscando estimativas dos componentes, através de um algoritmo específico. O filtro de Kalman consiste basicamente de um algoritmo que fornece estimativas atualizadas do vetor de estados a cada instante de tempo.

Souza (1989) descreve o modelo de espaço de estados a partir de um *modelo linear dinâmico* (MLD) da forma:

$$Y_t = \underline{F}_t' \underline{\theta}_t + v_t \quad (5)$$

$$\underline{\theta}_t = \underline{G}_t \underline{\theta}_{t-1} + \underline{\omega}_t \quad (6)$$

em que³: Y_t é o processo representando a observação do sistema no instante t ;

\underline{F}_t é um vetor $m \times 1$ conhecido para todo $t = 1, 2, \dots, m$;

$\underline{\theta}_t$ é o vetor $m \times 1$ representando o estado do sistema em t (*vetor de estado*);

\underline{G}_t é uma matriz $m \times m$ conhecida para todo $t = 1, 2, \dots, m$.

onde: v_t é a perturbação associada às observações, seguindo um processo ruído branco gaussiano com variância V_t ;

$\underline{\omega}_t$ é um vetor $m \times 1$ da perturbação associada ao estado, também um processo ruído branco gaussiano vetorial com matriz de covariância $W_t m \times m$.

² Para o desenvolvimento completo do modelo, ver Souza (1989).

³ Os termos sublinhados em itálico correspondem a matrizes.

Assume-se ainda que

$$E[v_t, \omega_{t-k}] = 0 \text{ para todo } k = 0, 1, 2, \dots$$

A equação (5) descreve a forma pela qual as observações do processo são geradas em função do vetor de estado e é correspondente à *equação das medidas ou das observações* (4). A equação (6) representa a evolução dinâmica do vetor de estado não observado e é conhecida como *equação do sistema ou de transição*.

A construção dos Modelos Estruturais seguem os passos propostos por Souza (1989) com o diferencial de, inicialmente, logaritimizarmos a série e de se modelar apenas a tendência, de acordo com Andrews (1994). A análise é feita com intervenções, quando o modelo indicar um ajustamento pobre em determinado período.

3.4 Modelos bayesianos

A idéia básica da modelagem estrutural univariada, qual seja de que existem componentes básicos não observáveis de tendência, sazonalidade, ciclo e erro aleatório na série em estudo, bem como a atualização seqüencial via filtro de Kalman, é aplicável à modelagem bayesiana proposta por Harrison & Stevens (1976).

A diferença essencial entre as duas abordagens reside na natureza das estatísticas em que elas se baseiam fazendo com que, na abordagem clássica (Estrutural), a

estimação dos parâmetros é feita via maximização da função de verossimilhança, demandando séries longas para bons resultados. Já na abordagem bayesiana, a estimação é feita de modo iterativo, o que permite a intervenção do analista na determinação dos hiperparâmetros.

O modelo bayesiano de previsão é estruturado a partir do Modelo Linear Dinâmico (MLD) e do Filtro de Kalman, definidos nas equações (5) e (6).

No caso da análise bayesiana, Y_t é a série observada no período t , F_t é o vetor ($m \times 1$) de constantes conhecidas da regressão; θ_t é o vetor ($m \times 1$) dos parâmetros de estado do modelo, v_t é o erro aleatório com $\sim N(0, V_t)$; G_t é uma matriz ($m \times m$) de coeficientes que define a evolução do vetor de estados no tempo,⁴ além de v_t como ruído observacional em t e ω_t um termo de erro estocástico seguindo distribuição normal com média zero e matriz de covariância W_t . Assume-se que as séries v_t e ω_t são independentes e mutuamente independentes, ou seja, que as $Cov[v_t, v_s]$; $Cov[\omega_t, \omega_s]$ para $t \neq s$ e $Cov[v_t, \omega_s]$ para todo t e s são zero (Pole *et al.*, 1994).

Dada a série temporal Y_t que se pretende modelar, a solução para o problema de estimação do vetor de estados θ_t em cada instante de tempo é obtido através do seguinte filtro:

.....
⁴ Neste caso, assumindo como fixa ou seja, $G_t = G$.

$$a_t = G_t m_{t-1} \quad (7)$$

$$R_t = B G_t C_{t-1} G_t' B \quad (8)$$

$$f_t = F_t' a_t \quad (9)$$

$$Q_t = F_t' R_t F_t + S_{t-1} f_t^b \quad (10)$$

$$n_t = \beta_v n_{t-1} + 1 \quad (11)$$

$$d_t = \beta_v d_{t-1} + \frac{S_{t-1} e_t^2}{Q_t} \quad (12)$$

$$S_t = \frac{d_t}{n_t} \quad (13)$$

$$m_t = a_t + \frac{R_t F_t e_t}{Q_t} \quad (14)$$

$$C_t = \frac{(R_t F_t F_t' R_t') S_t}{S_{t-1}} \quad (15)$$

em que: $a_t = E[\theta_{t/t-1}]$,

$$R_t = Var[\theta_{t/t-1}],$$

$$m_t = E[\theta_{t/t}],$$

$$C_t = Var[\theta_{t/t}],$$

$$f_t = E[Y_{t/t-1}] \text{ (previsão um passo à frente),}$$

$$e_t = Y_t - f_t \text{ (erro de previsão um passo à frente),}$$

$$Q_t = Var[Y_{t/t-1}],$$

B = matriz de descontos,

b = expoente da lei de variância,

β_v = fator de desconto da lei de variância e

$$S_t = E[V_{t/t-1}].^5$$

.....
⁵ Extraído de Mattos (1998).

Na formulação bayesiana, as recursões com o filtro descrito são representadas em termos de distribuições *a priori* (ou anterior) e *a posteriori* (ou posterior), para o vetor de estado θ_t com

a. posterior em $t - 1$:

$$(\theta_{t-1/t-1}) \sim N(m_{t-1}, C_{t-1});$$

b. anterior em t : $(\theta_{t/t-1}) \sim N(a_t, R_t)$;

c. posterior em t : $(\theta_{t/t}) \sim N(m_t, C_t)$.

Na operacionalização do modelo, além de F_t e G_t , é necessário determinar *a priori* V_t e W_t . Para V_t , utiliza-se uma *lei de variância* para modelar o aspecto de que a variância do componente irregular tende a variar de acordo com o nível das séries, captando um eventual comportamento heterocedástico (típico de séries econômicas) e dando origem às equações (11), (12) e (13). Na matriz W_t são utilizados fatores de desconto para caracterizar sua evolução temporal, dando origem à equação (8).

O modelo segue uma seqüência lógica estruturada a partir do algoritmo do Filtro de Kalman, da seguinte forma:

- a. determinação da função de densidade anterior;
- b. observação de Y_{t+1} ou, se for o caso, cálculo da previsão de Y_t ;
- c. determinação da função de densidade posterior;
- d. se necessário, nova função de densidade anterior para se proceder à previsão da série Y_t .

Além disso, também é necessário estipular alguns parâmetros *pré-definidos* antes de se iniciar o processo de estimação:

- as condições iniciais para os componentes do modelo (m_0) e respectivas variâncias (R_0) ou, em outras palavras, a distribuição *a priori* inicial;
- os fatores de desconto para cada componente β_i ($i = 1, \dots, k$) e para a lei de variância β_v ;
- o expoente da lei de variância observacional b .

No caso (a), quando não se tem informação sobre a distribuição *a priori* (ou anterior) inicial, inicializa o filtro adotando-se uma “*priori* de referência”, para a qual se tem $m_0 = 0$ e $R_0 = \eta I$, em que η é um número grande e I é a matriz identidade. Isso equivale a supor ignorância total *a priori* quanto ao vetor de estados θ (Mattos, 1998).

A função de densidade anterior para um vetor de estados em t é representada por uma distribuição normal com média (a_t) e co-variância (R_t), ou seja:

$$\underline{\theta}_t | D_{t-1} \sim N[a_t, R_t] \quad (16)$$

em que (D_t) denota o estado de conhecimento no instante t . Definida a função de densidade anterior, a previsão do modelo

é obtida, usando-se a equação de observações expressa na equação (5).

A previsão y_{t+1} é, então, uma combinação das variáveis $\underline{\theta}_{t+1} | D_t$ e v_{t+1} distribuídas normalmente, sendo a média e a variância dadas por:

$$\begin{aligned} E[y_{t+1} | D_t] &= E[F' \underline{\theta}_{t+1} + v_{t+1} | D_t] = \\ &E[F' \underline{\theta}_{t+1} | D_t] + E[v_{t+1} | D_t] = \\ &F' E[\underline{\theta}_{t+1} | D_t] + E[v_{t+1}] = F' {}_{t+1} a_{t+1} = f_{t+1} \end{aligned} \quad (17)$$

$$\begin{aligned} V[y_{t+1} | D_t] &= V[F' {}_{t+1} \underline{\theta}_{t+1} + v_{t+1} | D_t] = \\ &V[F' {}_{t+1} \underline{\theta}_{t+1} | D_t] + V[v_{t+1} | D_t] = \\ &F' {}_{t+1} V[\underline{\theta}_{t+1} | D_t] + F' {}_{t+1} V[v_{t+1}] = \\ &F' {}_{t+1} R_{t+1} F' {}_{t+1} + V_{t+1} = Q_{t+1} \end{aligned} \quad (18)$$

A distribuição da previsão para um passo à frente segue a forma normal, $y_{t+1} | D_t \sim N[f_{t+1}, Q_{t+1}]$, observando-se que $Cov[v_{t+1}, \theta_{t+1}] = 0$

A função de densidade anterior, quando combinada com os dados via Lei de Bayes, produz a função de densidade posterior, que também segue distribuição normal da forma

$$\theta_t | D_t \sim N[m_t, C_t] \quad (19)$$

em que os momentos dessas duas distribuições (anterior e posterior) são definidos pelas equações (7) e (8) para a anterior e (13) e (14) para a posterior.

Nesse sentido, a média m_t da distribuição posterior é ajustada do valor precedente por um múltiplo do erro de previsão em $t(e_t)$. O montante desse ajustamento é determinado pelo valor F_t , que corresponde à matriz de regressão do vetor de estados θ_t da observação Y_t , condicionado a D_{t-1} . A matriz F_t ou *fator adaptativo*, é determinada pelo tamanho relativo da variância do anterior do estado e da variância da observação, uma vez que a variância da previsão Q_t é função dessas variâncias. Isso significa que, quanto maior a variância da observação em relação à variância anterior do estado, menor será o fator adaptativo F_t . Se, ao contrário, a variância anterior do estado é maior que a variância da observação, então a observação possui informação relevante para o modelo, e o ajustamento da distribuição anterior para distribuição posterior deve ser conduzido (Pole *et al.*, 1994).

Os Modelos Bayesianos, assim como os Modelos Estruturais, podem incorporar componentes relativos à sazonalidade e ao ciclo. Porém, sua característica principal consiste em adaptar o modelo estimado a choques estocásticos na série, através do monitoramento do desempenho preditivo do modelo em cada observação da série (West, 1986).

Esse monitoramento possibilita a incorporação da informação relativa a mudanças bruscas na média e variância da série, através da função de distribuição anterior.⁶ Essa informação, ao ser incorporada, é traduzida para os parâmetros via Filtro de Kalman, resultando em estimativas mais consistentes, expressas na função de distribuição posterior (West *et al.*, 1985). Deve-se ressaltar que, assim como nos Modelos ARIMA, a utilização de modelos parcimoniosos é recomendada, uma vez que estes se adaptam mais rapidamente à evolução da série (Phillips, 1995).

A operacionalização dos MLD Bayesianos é conduzida de forma semelhante àquela definida para os MLD Estruturais. Assim, as séries também são logaritimizadas de modo a se reduzir a variância e o ajuste do modelo é em termos da tendência. Também são verificados os resíduos para posterior realização das previsões. A diferença está nos passos da modelagem bayesiana, a qual segue o procedimento apresentado em Mattos (1998).

.....
⁶ A esse respeito, ver West (1986) e Mattos (1998).

3.5_ Modelos de Redes Neurais

Os Modelos de Redes Neurais Artificiais (RNA) diferenciam-se 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 (Turban, 1993).

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

O algoritmo mais estudado e bem sucedido no processo de aprendizagem de uma RNA é o algoritmo de *backpropagation*. Este algoritmo 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.

Para o aprendizado, a amostra é dividida em duas faixas. Na primeira, denominada faixa-treino, a rede capta o padrão

de comportamento da série para, na faixa teste, testar se o erro é minimizado. A faixa treino deve ser suficientemente grande para captar o padrão de comportamento da série, e deve ser representativa das condições futuras que a rede vai tentar captar para a realização da previsão.

O algoritmo de *backpropagation* ajusta então as ponderações, de modo a minimizar os erros de previsão dentro da faixa teste. Baseado nesse erro entre observado e estimado, os pesos são ajustados de modo a obter um erro mínimo. O algoritmo de *backpropagation* é formalizado nas seguintes equações, de acordo com Corrêa & Portugal (1998):

$$\Delta w_{ij,k}^n = \eta \cdot \delta_{j,k} \cdot y_{i,k-1} \quad (20)$$

$$w_{ij,k}^{n+1} = w_{ij,k}^n + \Delta w_{ij,k}^n \quad (21)$$

$$\delta_{j,k} = \left(\frac{dy}{dz} \right)_{i,k} \cdot (y_{i,k} - y_{i,k}^T) \quad (22)$$

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

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 .

Ao contrário dos demais modelos abordados nesse trabalho, os Modelos de Redes Neurais Artificiais não têm um procedimento universal de modelagem ou construção (Chatfield, 1996). No presente estudo, as redes são construídas seguindo critério sugerido por Raposo (1992) baseado na abordagem Box & Jenkins, utilizando as funções de autocorrelação e autocorrelação parcial na determinação do número de entradas do modelo.

4_ Critérios para a avaliação do desempenho dos modelos

O desempenho de cada modelo nos diferentes mercados será avaliado a partir de dois critérios, um estatístico e outro operacional. O critério estatístico utilizado será o Erro Percentual de Previsão (EPP), derivado do Erro Médio Percentual de Previsão conforme definido em Armstrong & Fildes (1995). A estatística é definida como sendo:

$$EPP_t = \frac{(VP_{t+1} - VO_{t+1})}{VO_{t+1}} \quad (23)$$

O segundo critério consiste em aplicar as previsões dos modelos em simulações da operação de compra e venda de contratos futuros, conforme definido em Garcia *et al.* (1988). O processo de si-

mulação com as previsões dos modelos é construído de modo que são tomadas posições compradas no mercado futuro, se o valor previsto excede o preço futuro, e vendem-se contratos futuros, se a previsão é abaixo da cotação da BM&F, seguindo as regras de comercialização e considerando os custos de realização das operações.

Por si, o retorno financeiro é uma medida sem muito valor para julgar o desempenho de um sistema de negociação. A medida adequada para a comparação entre sistemas de negociação deve considerar a relação retorno-risco dos modelos.

Pode-se utilizar então uma medida clássica de retorno-risco, o Índice Sharpe (IS), que é definido na sua forma reduzida, por Schwager (1984), como sendo:

$$IS = \frac{R}{\sigma_R} \quad (24)$$

onde R é a média dos retornos do sistema de negociação e σ_R é o desvio padrão dos retornos.

A premissa básica do IS é de que o desvio padrão é uma medida de risco. Ou seja, quanto maior o desvio padrão, maior o risco do sistema de negociação. Se o desvio padrão é baixo, é razoável assumir que o retorno atual estará perto do retorno esperado. Por outro lado, se o desvio padrão

é alto, isto sugere que há uma alta probabilidade de que o retorno atual deve variar significativamente. Quanto maior o IS, melhor é o desempenho do modelo nas operações de compra/venda de contratos.


5_ Fonte de dados

A comparação dos quatro modelos será feita a partir de uma base de dados secundária proveniente da Bolsa de Mercadorias e Futuros (BM&F).⁷ Tal base corresponde ao indicador de preço Esalq/BM&F para toda quarta-feira útil⁸ entre 9 de setembro de 1996 e 31 de dezembro de 1999 para os contratos futuros de boi gordo. As previsões são construídas a partir da penúltima semana do mês de janeiro de 1998, e atualizado seqüencial-

mente nos meses seguintes, de modo a proceder com a previsão para os contratos no biênio 1998/1999.

O indicador utilizado atende às especificações do Contrato Futuro de Boi Gordo negociado na BM&F, ou seja, trata-se de bovinos machos, castrados, bem acabados (carcaça convexa), em pasto ou confinamento, com peso vivo entre o mínimo de 450kg e o máximo de 550kg e idade máxima de 42 meses. O indicador é uma média ponderada dos preços da arroba do boi gordo pagos pelos frigoríficos nas principais regiões produtoras do Estado de São Paulo. O comportamento do indicador ao longo do período analisado pode ser visualizado na Figura 1.

Figura 1_ Indicador do preço do boi gordo (US\$/@) – Esalq/BM&F



⁷ Tais informações podem ser obtidas junto ao endereço eletrônico da BM&F: www.bmf.com.br

⁸ Quando tal informação não está disponível, utiliza-se a data imediatamente posterior.

Este indicador pode servir como referencial no direcionamento de operações de compra e venda no mercado futuro no mês de vencimento dos contratos, na liquidação por diferença ou financeira (Marques & Mello, 1999).

O comportamento da série, em relação à dependência temporal, pode ser melhor visualizado com a apresentação tabular da função de autocorrelação e autocorrelação parcial dos dados (Tabela 1).

Observa-se que a série não é estacionária, dada a dependência temporal observada na função de autocorrelação. É necessária então uma diferenciação da série para viabilizar a estimação dos modelos ARIMA e de Redes Neurais. A representação tabular da série diferenciada é apresentada a seguir (Tabela 2).

Tabela 1_ Função de Autocorrelação (AC) e Autocorrelação Parcial (PAC) do indicador de preços de boi gordo (R\$/@) Esalq-BM&F

Autocorrelação	Autocorrelação parcial	K	AC	PAC	Q-Stat	Prob
. *****	. *****	1	0,976	0,976	167,83	0,000
. *****	* .	2	0,945	-0,172	326,10	0,000
. *****	. .	3	0,912	-0,043	474,26	0,000
. *****	* .	4	0,874	-0,103	611,21	0,000
. *****	. *	5	0,842	0,140	739,10	0,000
. *****	** .	6	0,803	-0,237	855,90	0,000
. *****	. *	7	0,764	0,077	962,33	0,000
. *****	. *	8	0,733	0,110	1060,8	0,000
. *****	. *	9	0,705	0,068	1152,5	0,000
. *****	. .	10	0,683	0,021	1239,2	0,000
. *****	. .	11	0,661	-0,032	1321,0	0,000
. *****	. *	12	0,645	0,143	1399,3	0,000

. *****		* .	13	0,630	-0,113	1474,3	0,000
. *****		* .	14	0,609	-0,113	1544,9	0,000
. *****		* .	15	0,586	-0,079	1610,6	0,000
. *****		. .	16	0,559	0,027	1670,9	0,000
. *****		* .	17	0,529	-0,127	1725,2	0,000
. *****		. .	18	0,498	0,013	1773,7	0,000
. *****		. .	19	0,468	0,057	1816,7	0,000
. ***		. .	20	0,434	-0,055	1854,0	0,000
. ***		. .	21	0,405	0,044	1886,6	0,000
. ***		. .	22	0,378	0,022	1915,3	0,000
. ***		. .	23	0,352	-0,016	1940,2	0,000
. ***		. .	24	0,330	-0,009	1962,4	0,000
. **		. .	25	0,310	0,006	1982,1	0,000
. **		* .	26	0,289	-0,113	1999,2	0,000
. **		. .	27	0,266	-0,048	2013,9	0,000
. **		. .	28	0,245	0,065	2026,4	0,000
. **		. .	29	0,223	-0,046	2036,9	0,000
. **		* .	30	0,197	-0,106	2045,1	0,000
. *		. *	31	0,172	0,072	2051,4	0,000
. *		. .	32	0,144	-0,006	2055,8	0,000
. *		. .	33	0,119	0,023	2058,9	0,000
. *		. .	34	0,099	0,061	2061,0	0,000
. *		. .	35	0,079	-0,043	2062,4	0,000
. .		. .	36	0,061	0,032	2063,2	0,000

Fonte: Dados da pesquisa.

K = número de defasagens;

Q-stat = Estatística Q de Ljung-Box;

Prob =Valor Probabilístico.

**Tabela 2_ Função de Autocorrelação (AC) e Autocorrelação Parcial (PAC)
da primeira diferença do indicador de preços de boi gordo (R\$/@) Esalq-BM&F**

Autocorrelação	Autocorrelação parcial	K	AC	PAC	Q-Stat	Prob
. *	. *	1	0,156	0,156	4,2450	0,039
. .	. .	2	0,050	0,026	4,6788	0,096
. *	. *	3	0,089	0,080	6,0960	0,107
* .	* .	4	-0,124	-0,156	8,8535	0,065
. *	. **	5	0,172	0,222	14,164	0,015
. .	* .	6	-0,023	-0,102	14,259	0,027
* .	* .	7	-0,161	-0,131	18,958	0,008
* .	* .	8	-0,062	-0,072	19,658	0,012
* .	. .	9	-0,123	-0,025	22,439	0,008
. .	. .	10	0,007	0,011	22,447	0,013
* .	* .	11	-0,121	-0,158	25,158	0,009
. .	. *	12	-0,014	0,104	25,193	0,014
. *	. *	13	0,107	0,095	27,347	0,011
. .	. *	14	0,060	0,067	28,031	0,014
. *	. .	15	0,073	-0,043	29,048	0,016
. *	. *	16	0,085	0,120	30,450	0,016
. .	. .	17	0,004	-0,035	30,454	0,023
. .	* .	18	0,008	-0,076	30,467	0,033
. .	. .	19	0,046	0,030	30,877	0,042
* .	* .	20	-0,072	-0,061	31,891	0,044
* .	. .	21	-0,073	-0,048	32,960	0,047

.	22	-0,013	-0,003	32,995	0,062
*	23	-0,093	-0,006	34,750	0,055
.	24	-0,046	-0,026	35,186	0,066
. ..	. *.	25	0,047	0,103	35,629	0,077
.	26	0,014	0,025	35,667	0,098
. ..	* ..	27	-0,034	-0,082	35,909	0,117
.	28	0,024	0,018	36,024	0,142
. *.	. *.	29	0,085	0,088	37,537	0,133
. ..	* ..	30	-0,018	-0,103	37,606	0,160
.	31	0,043	-0,014	37,998	0,181
.	32	-0,041	-0,045	38,351	0,204
* ..	* ..	33	-0,134	-0,077	42,200	0,131
.	34	0,033	0,022	42,438	0,152
*	35	-0,058	-0,039	43,166	0,162
*	36	-0,072	0,009	44,299	0,161

Fonte: Dados da pesquisa.

K = número de defasagens;

Q-stat = Estatística Q de Ljung-Box;

Prob = Valor Probabilístico.

6_ Análise e discussão dos resultados

Para a construção das previsões de cada modelo, foram utilizados *softwares* específicos. Assim, para o modelo ARIMA, utilizou-se o *software* Eviews 3.0, ao passo que, para o modelo Estrutural, o *software* adotado foi o Stamp 5.0. Ambos apresentam facilidade de operacionalização e verificação das estimativas, fatores que os diferenciam do *software* adotado para os modelos bayesianos (BATS 2.07) e os modelos de Redes Neurais, os quais foram estimados a partir do *software* Braincel 3.0.

Os modelos estimados para a construção das previsões apresentaram as configurações da Tabela 3.

As estimativas envolvendo dados semanais impedem, de acordo com Andrews (1994), a modelagem dos componentes de ciclo e sazonalidade. Isto porque a modelagem de dados de frequência semanal deve obedecer à característica observável da série, que, nesse caso, é a tendência, uma vez que componentes como sazonalidade e ciclo são características de séries de menor frequência (mensais, trimestrais, semestrais ou anuais) e de tamanho suficientemente grande, com cerca de 240 observações, para captar esses efeitos.

Assim, a estimação dos modelos ARIMA e Lineares Dinâmicos (Estruturais e Bayesianos), envolveu estimativas que buscaram captar o comportamento da tendência da série de preços, com o objetivo de realizar previsões um passo à frente.

Para a verificação dos resultados, são analisados meses em que existem contratos futuros negociados entre 1998 e 1999. Os valores previstos correspondem à cotação em R\$, convertida para US\$ pela taxa de câmbio comercial, da arroba de boi gordo na semana anterior ao vencimento do contrato futuro. Os resultados, em termos de Erro Percentual de Previsão (EPP), são apresentados na Tabela 4.

As melhores previsões para cada contrato analisado estão destacadas em negrito. Os resultados indicam que os Modelos Bayesianos prevêm melhor em sete contratos, seguidos dos modelos Estruturais, com seis, dos ARIMA, com cinco, cabendo aos Modelos de Redes Neurais e às cotações da BM&F as melhores previsões em apenas 3 contratos dos 24 analisados.

Todos os modelos apresentam bom desempenho preditivo, com erros abaixo de 1%, à exceção do Modelo Estrutural e da cotação na BM&F que, para o contrato de maio/98, apresentam erros acima de 2% nas previsões.

Tabela 3_ Configuração dos modelos estimados

Modelo	ARIMA (especificação)	Renda Neural (entradas)	Estrutural (componentes)	Bayesiano (tendência linear)			
				E.L.V	E.D.T.	F.D.L.V.	Monit. auto.
Jan./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Fev./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Mar./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Abr./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Mai./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Jun./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Jul./98	ARIMA (2,1,0)	3	T+FS+I	2	0,8	0,85	Sim
Ago./98	ARIMA (2,1,0)	3	T+FS+I	2	0,8	0,85	Sim
Set./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Out./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Nov./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Dez./98	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Jan./99	ARIMA (0,1,1)	2	T+FS+I	2	0,8	0,85	Sim
Fev./99	ARIMA (0,1,1)	2	T+FS+I+interv.	2	0,88	0,85	Sim
Mar./99	ARIMA (0,1,7)	8	T+FS+I+interv.	2	0,88	0,85	Sim
Abr./99	ARIMA (0,1,1)	2	T+FS+I+interv.	2	0,88	0,85	Sim
Mai./99	ARIMA (0,1,1)	2	T+FS+I+interv.	2	0,88	0,85	Sim
Jun./99	ARIMA (0,1,15)	16	T+FS+I+interv.	2	0,88	0,85	Sim
Jul./99	ARIMA (7,1,15)	23	T+FS+I+interv.	2	0,88	0,85	Sim
Ago./99	ARIMA (7,1,15)	23	T+FS+I+interv.	2	0,88	0,85	Sim
Set./99	ARIMA (0,1,15)	16	T+FS+I+interv.	2	0,88	0,85	Sim
Out./99	ARIMA (3,1,1)	4	T+FS+I+interv.	2	0,88	0,85	Sim
Nov./99	ARIMA (1,1,7)	8	T+FS+I+interv.	2	0,88	0,85	Sim
Dez./99	ARIMA (0,1,1)	2	T+FS+I+interv.	2	0,88	0,85	Sim

Componentes: T = Tendência

E.L.V. = Expoente da Lei de Variância

FS = Sazonal Fixo

I = Irregular

F.D.L.V. = Fator de Desc. da Lei de Variância

Interv. = intervenção

Monit. auto. = Monitoramento Automático

Tabela 4_ Erro percentual das previsões para os contratos futuros de boi gordo

Contrato	Modelo				BM&F
	ARIMA	Rede Neural	Estrutural	Bayesiano	
Jan./98	0,773	0,478	0,303	-0,428	0,561
Fev./98	-0,091	0,017	0,500	0,134	-0,255
Mar./98	-0,103	-0,269	0,213	-0,191	0,085
Abr./98	0,097	-0,091	0,093	0,435	0,982
Mai./98	-0,272	0,278	2,205	-0,256	2,823
Jun./98	0,290	0,249	0,831	-0,019	0,352
Jul./98	-0,612	-0,959	-0,336	-0,097	-0,540
Ago./98	-2,234	-2,663	-1,711	-1,655	-1,732
Set./98	0,093	-0,842	1,064	1,406	1,248
Out./98	-1,177	-0,835	-1,968	-1,578	0,043
Nov./98	-0,883	-1,364	0,253	-0,598	-0,464
Dez./98	0,135	-1,079	0,198	-0,967	-0,683
Jan./99	-5,862	-7,345	-6,121	-5,578	14,084
Fev./99	1,779	-2,576	0,489	-0,570	5,061
Mar./99	1,664	1,528	1,375	0,920	-8,096
Abr./99	-0,285	-0,619	-0,790	-0,967	-0,946
Mai./99	0,678	1,862	2,564	-1,825	2,258
Jun./99	-2,704	-2,557	-2,446	-2,800	-3,015
Jul./99	-0,009	0,438	-0,386	0,310	-1,854
Ago./99	-2,251	-1,188	-0,613	-1,940	2,251
Set./99	-8,362	-9,224	-7,713	-7,224	-7,243
Out./99	-2,569	-3,282	-2,064	-0,793	-0,098
Nov./99	3,689	1,278	3,293	4,981	3,751
Dez./99	0,327	-0,828	0,017	-0,109	-0,582
Média	-0,745	-1,233	-0,448	-0,809	0,333


Fonte: Resultados da pesquisa.

A verificação desse padrão relativamente uniforme no desempenho dos modelos no primeiro semestre, quando há maior oferta de animais para abate, também é verificada no segundo semestre de 1998, com destaque para o bom desempenho dos modelos ARIMA e Bayesianos, além das cotações na BM&F, que apresentam baixos valores de EPP no período, à exceção do mês de agosto. Entre janeiro e junho de 1998, o valor médio do indicador foi de R\$ 26,55/@, com uma variabilidade de R\$ 0,42/@, indicando a relativa estabili-

dade da série, fator crucial na determinação do bom desempenho preditivo dos modelos no período (Figura 2).

Entre julho e dezembro de 1998, período que caracteriza a menor disponibilidade de animais para abate e consequente tendência de elevação dos preços, a série do indicador de preços da arroba de boi gordo passa a oscilar com um pouco mais de intensidade, fazendo com que a média da cotação semanal suba para a R\$ 27,78/@, com uma variabilidade de R\$ 0,65/@ no período.

Figura 2_ Volatilidade do indicador do preço do boi gordo Esalq/BM&F



Essa maior variabilidade compromete em especial o desempenho dos Modelos de Redes Neurais, que não captam, no período, a oscilação dos preços na velocidade necessária. Já os Modelos ARIMA mostram uma melhor adaptabilidade, captando de modo mais eficiente as variações no indicador. O mesmo pode ser dito com relação às previsões dos Modelos Bayesianos e Estruturais e das cotações na BM&F, que produzem boas previsões, principalmente nos meses de novembro e dezembro de 1998.

Todavia, é o mês de janeiro de 1999 que apresenta os resultados mais interessantes, com erros de previsão expressivos para todos os modelos. Esse fato decorre da desvalorização cambial do R\$ em 13/01/99, que corresponde à introdução de um choque aleatório nas séries de preços de bois gordos, fazendo com que os preços subissem de R\$28,19/@, em 06/01/99, para R\$ 31,51/@, em 03/02/99.

Conseqüentemente, no primeiro semestre de 1999, a média sobe para R\$ 30,35/@ e o desvio padrão salta para R\$ 1,11/@. Essa mudança no padrão de evolução da série fez com que o desempenho dos modelos fosse distinto no período.

No período de maior volatilidade do indicador, entre outubro e dezembro de 1999, os Modelos Bayesianos e as cotações na BM&F forneceram as melhores previsões, com os Modelos Estruturais também apresentando um bom desempenho. Já os Modelos ARIMA e de Redes Neurais não previram com a mesma acurácia, indicando a baixa adaptabilidade dos mesmos em períodos de alta oscilação no indicador de boi gordo, se comparadas às suas previsões com aquelas obtidas pelos Modelos Bayesianos e as cotações na BM&F, inicialmente destacados.

Portanto, pode-se inferir, a partir dos resultados obtidos, que os Modelos ARIMA, Estruturais e Bayesianos fornecem melhores previsões quando à série apresenta alta variabilidade, ao passo que há um equilíbrio entre o desempenho dos modelos e das cotações na BM&F para períodos de relativa estabilidade dos preços do boi gordo.

Com relação ao desempenho operacional, são analisados os retornos financeiros da aplicação das previsões obtidas de cada modelo. A média e o desvio padrão são a base para o cálculo do Índice Sharpe, o qual permite que se compare estratégias entre diferentes modelos.

Tomando por base o fato de que cada modelo sinaliza para diferentes estratégias de mercado nos vinte e quatro contratos analisados, são calculados os retornos médios, desvios-padrão, e o Índice Sharpe associado. Essa diversidade é determinante nos resultados da simulação, em que cada estratégia apresenta médias distintas de retorno, como pode ser observado na Tabela 5.

As simulações de compra e venda de contratos de boi gordo apontam para um melhor desempenho dos Modelos Estruturais, seguida dos Modelos ARIMA, ambos com boas médias de retorno financeiro.

Todos os modelos apresentam valores positivos do Índices Sharpe, indi-

cando o potencial dos mesmos em aplicações no mercado futuro de boi gordo. Os altos valores dos desvios-padrão nos modelos são decorrentes da alta volatilidade dos preços da arroba do boi gordo entre fevereiro e dezembro de 1999, determinando assim uma variabilidade significativa nos retornos verificados em cada contrato negociado.

A diferença no desempenho financeiro dos modelos está centrada na capacidade de identificar de modo preciso as tendências de mercado nas datas próximas ao vencimento dos contratos. Tal habilidade deve ser capaz de proporcionar ganhos significativos em comparação com modelos que não conseguem captar as mesmas no momento certo.

Tabela 5_ Estatísticas e Índice Sharpe dos retornos financeiros das simulações: contratos de boi gordo 1998/1999

	ARIMA	R. Neural	Estrutural	Bayesiano
Média (US\$)	936,56	892,56	1.015,52	729,53
Desvio padrão (US\$)	2.331,45	2.349,40	2.296,69	2.407,43
Índice Sharpe	0,402	0,380	0,442	0,303

Fonte: Resultados da pesquisa.

7_ Conclusões

O presente estudo foi elaborado com o objetivo de testar a aplicabilidade de modelos de previsão de séries temporais em negociações de contratos futuros de boi gordo, em operações de compra e venda de contratos na BM&F. Os modelos estudados são os ARIMA, de Redes Neurais, e Modelos Lineares Dinâmicos (estes sob os enfoques clássico e bayesiano).

Com base nos resultados obtidos, pode-se concluir que, para o período analisado, o modelo com melhor desempenho preditivo e operacional é o Modelo Linear Dinâmico Clássico ou Estrutural que, graças à capacidade de adaptação à evolução da série, consegue captar o padrão de comportamento observado e, em função disto, fornecer sinalizações corretas das tendências de mercado, produzindo as melhores previsões em termos agregados, com médias positivas nas simulações de compra/venda dos contratos futuros. Os demais modelos também apresentam desempenho satisfatório, com uma baixa média de EPP e valores positivos do Índice Sharpe.

Deve-se destacar que os resultados obtidos nesta pesquisa fornecem um indicativo do potencial de aplicação dos modelos estudados em operações nos mercados futuros agropecuários, deven-

do os resultados aqui obtidos serem complementados por outros estudos envolvendo a aplicação de modelos de previsão em negociações de contratos futuros agropecuários ou financeiros.

Referências bibliográficas

- ANDREWS, R. L. Forecasting performance of structural time series models. *Journal of Business & Economic Statistics*, v. 12, n. 1, p. 129-133, 1994.
- ARMSTRONG, J. S.; FILDES, R. On the selection of error measures for comparison among forecasting methods. *Journal of Forecasting*, v. 14, p. 67-71, 1995.
- BACCHI, M. R. P. *Previsão de preços de bovino e frango com modelos de séries temporais*. 1995, 172 f. Tese (Doutorado em Economia Agrícola) – Escola Superior de Agricultura Luis de Queiroz, USP, Piracicaba.
- BM&F. *Agropecuários: açúcar, algodão, boi gordo, café, milho e soja*. Viçosa: [s. l.], 1997. (Curso de Introdução aos Mercados Futuros Agropecuários).
- BOX, G. E. P.; JENKINS, G. M. *Time series analysis: forecasting and control*. San Francisco, Holden Day, 1976.
- CHATFIELD, C. Model uncertainty and forecast accuracy. *Journal of Forecasting*, v. 15, p. 495-508, 1996.
- CORRÊA, W. R.; PORTUGAL, M. S. Previsão de séries de tempo na presença de mudança estrutural: redes neurais artificiais e modelos estruturais. *Economia Aplicada*, v. 2, n. 3, p. 487-514, 1998.
- GARCIA, P.; LEUTHOLD, R. M.; FORTENBERY, T. R.; SARASSORO, G. F. Pricing efficiency in the live cattle futures market: further interpretation and measurement. *American Journal of Agricultural Economics*, p. 162-169, Feb. 1988.
- HARRISON, P. J.; STEVENS, C. F. Bayesian forecasting. *Journal of the Royal Statistical Society*, v. 38, n. 3, p. 81-135, 1976. (series B).
- HARVEY, A. C. *Forecasting structural time series models and the Kalman filter*. Cambridge: Cambridge University Press, 1991.
- HULL, J. *Introdução aos mercados futuros e de opções*. 2. ed. São Paulo: BM&F/Cultura, 1996.
- MARQUES, P. V.; MELLO, P. C. *Mercados futuros de commodities agropecuárias: exemplos e aplicações aos mercados brasileiros*. São Paulo: Bolsa de Mercadorias & Futuros, 1999.
- MATTOS, R. S. *A dinâmica industrial de curto prazo em Minas Gerais: uma análise com modelos bayesianos de previsão*. Juiz de Fora: NUPE-FEA/UFJF, 1998. Mimeogr.
- PHILLIPS, P. C. B. Bayesian model selection and prediction with empirical applications. *Journal of Econometrics*, v. 69, p. 289-331, 1995.
- PINDYCK, R. S.; RUBENFIELD, D. L. *Econometric models and economic forecasts*. 3rd ed. New York: McGrawHill, 1991.
- POLE, A., WEST, M., HARRISON, J. *Applied bayesian forecasting and time series analysis*. New York: Chapman & Hall, 1994. (Texts in Statistical Science).
- RAPOSO, C. M. *Redes neuronais na previsão de séries temporais*. [s. d.]. Dissertação (Mestrado) – COPPE, UFRJ, Rio de Janeiro.
- SCHWAGER, J. D. *A complete guide to the futures markets: fundamental analysis, technical analysis, trading, spreads and options*. New York: Wiley, 1984.
- SOUZA, R. C. *Modelos estruturais para previsão de séries temporais: abordagens clássica e bayesiana*. Rio de Janeiro: IMPA, 1989.
- TEWELES, R. J.; JONES, F. J. *The futures game: who wins? Who loses? And why?*. New York: McGraw-Hill, 1999.
- TURBAN, E. *Decision support and expert systems: management support systems*. New York: MacMillan, 1993.
- VICENTE, J. R. Modelos estruturais para previsão das produções brasileiras de carne de frango e ovos. *Revista de Economia e Sociologia Rural*, Brasília, v. 30, n. 4, p. 305-319, out./dez. 1992.
- WEST, M. Bayesian model monitoring. *Journal of The Royal Statistical Society*, v. 48, n. 1, p. 70-78, 1986. (serie B).
- WEST, M.; HARRISON, P. J.; MIGON, H. S. Dynamic generalized linear models and bayesian forecasting. *Journal of The American Statistical Association*, v. 80, n. 389, p. 73-83, mar. 1985.

.....
 • E-mail de contato dos autores

• bressan@face.ufmg.br

• jelima@mail.ufrj.br

.....