

ARTIGO:

***TOMADA DE DECISÃO EM FUTUROS
AGROPECUÁRIOS COM MODELOS
DE PREVISÃO DE SÉRIES TEMPORAIS***

REVISTA:

***RAE-eletrônica Revista de Administração de
Empresas
FGV EASP/SP, v. 3, n. 1, Art. 9, jan./jun. 2004***

1 - INTRODUÇÃO

Conceitos:

- *Commodities*
- Mercado Físico e Mercado Futuro BM&F
- Retornos

1 - INTRODUÇÃO

Modelos de Previsão e Tomada de Decisão

- Importância quanto ao Risco de Mercado – Oscilação de Preços
- Impactos no Agronegócio
- Tipos de Modelos
 - Puramente Subjetivos
 - Causais ou Explanatórios
 - Extrapolativos*
 - Composto – Combinação de mais de um Modelo

1 - INTRODUÇÃO

Autores	Aplicação	Objetivo
LEUTHOLD (1974)	Séries Temporais	Preços no Mercado Futuro de Boi Gordo - EUA
LEUTHOLD e HARTMAN (1979)	Econométricos e Passeio Aleatório	Preços no Mercado Futuro de Boi Gordo - EUA
JUST e RAUSSER (1981)	Comparação Mercado Real/Futuro	Preços no Mercado Futuro para trigo, soja, algodão, boi gordo e suínos - EUA
GARCIA (1988)	Econométricos e Modelos ARIMA	Preços no Mercado Futuro de Boi Gordo - EUA
TAYLOR (1988)	Interpretações de Tendência de Mercado e Modelos ARIMA	Regra de negociação em Mercados Futuros de TBonds - EUA
GRUDNITSKI e OSBURN (1993)	RNA	Preços no Mercado Futuro de Ouro e Preços das Ações S&P500 - EUA
KENYON (1993)	Regressão de Variâncias	Preços no Mercado Futuro de milho e soja - EUA
SILVA (1996)	Análise Técnica	Maximização de ganhos em diversos Contratos Futuros - Brasil
NTUNGO e BOYD (1998)	Modelos ARIMA e de Redes Neurais	Mercados Futuros de milho, prata e Marco Alemão - Alemanha

2 - OBJETIVOS

Construir previsões das cotações do mercado físico, sinalizando posições de compra e venda no mercado futuro.

Comparar os retornos médios de cada modelo em operações de compra e venda nos mercado futuro das *commodities* de boi gordo, café e soja na BM&F.

3 – METODOLOGIA

GRANGER e NEWBOLD (1986):

- a) Aplicação imediata a baixo custo;
- b) Informações externas à série em estudo são de difícil obtenção;
- c) As previsões obtidas podem ser utilizadas em combinação com outras de modo a produzir uma previsão otimizada;
- d) Previsão univariada tem a possibilidade de determinar em que medida a oscilação da variável é explicada por seu comportamento passado;
- e) Para a maioria das séries em economia, a informação contida nas mesmas é de grande importância;

3 – METODOLOGIA

3.1 ARIMA

Os Modelos ARIMA (Auto-regressivo – Integrado – Média móvel), inicialmente formulados por BOX e JENKINS (1976), baseiam-se na idéia de que uma série temporal não-estacionária pode ser modelada a partir de *d* diferenciações e da inclusão de um componente *auto-regressivo* e um componente *média móvel*.

$$z_t = \nabla^d y_t = (1 - B)^d y_t$$

Sendo z_t um processo estacionário, ele pode ser descrito através de uma modelagem ARMA (p, q), da seguinte forma:

$$\Phi_p(B)z_t = \theta_0 + \theta_q(B)a_t$$

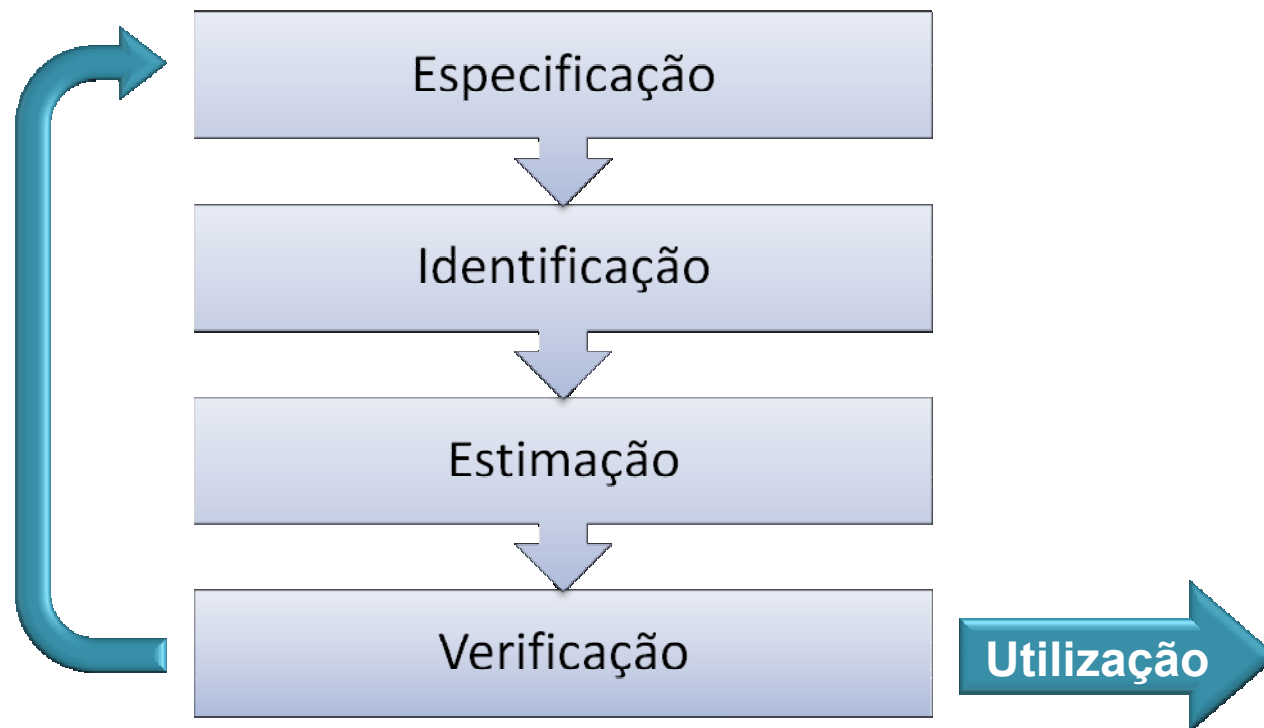
que, considerando a diferenciação (d) y_t , corresponderá a um Modelo ARIMA(p,d,q)

$$\Phi_p(B)(1 - B)^d y_t = \theta_0 + \theta_q(B)a_t$$

3 – METODOLOGIA

3.1 ARIMA

De acordo com BOX e JENKINS (1976), a modelagem ARIMA será baseada em um ciclo iterativo, no qual a escolha da estrutura do modelo é baseada nos próprios dados.



3 – METODOLOGIA

3.1 ARIMA

Observações:

GRANGER e NEWBOLD (1986) a metodologia Box & Jenkins deve ser aplicada em séries com mais de 50 observações.

FISCHER (1982) ressalta outro importante aspecto dos modelos ARIMA, relacionado ao limite do horizonte de previsão.

Segundo o autor, os ARIMA apresentam a característica geral de suas previsões reverterem à média quando o horizonte de previsão aumenta.

3 – METODOLOGIA

3.2 MLD

Modelos Lineares Dinâmicos ou Estruturais são formulados com a característica de incorporar mudanças nos parâmetros à medida que ocorrem evoluções na série temporal estudada.

Em tais modelos, a série y_t é decomposta em termos da tendência, do ciclo, da sazonalidade e de um componente irregular, respectivamente temos:

$$y_t = \mu_t + \gamma_t + \Psi_t + \varepsilon_t$$

A equação acima também é conhecida como equação das medidas ou equação das observações.

3 – METODOLOGIA

3.2 MLD

A operacionalização adotando-se o modelo de espaço de estados e utilizando-se o Filtro de Kalman para a atualização seqüencial dos componentes não observáveis.

O filtro de Kalman é utilizado para criar uma estimativa ótima do estado, a cada instante t .

3 – METODOLOGIA

3.2 MLD

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

$$Y_t = \underline{F}'_t \underline{\theta}_t + v_t$$

$$\underline{\theta}_t = \underline{G}_t \underline{\theta}_{t-1} + \underline{\omega}_t$$

Onde

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 $t = 1, 2, \dots, m$

v_t é a perturbação associada às observações, seguindo um processo ruído branco gaussiano com variância \mathbf{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 \mathbf{W}_t $m \times m$.

3 – METODOLOGIA

3.3 RNA

Os Modelos de Redes Neurais Artificiais (RNA) se diferenciam dos modelos tradicionais de previsão por serem modelos não-paramétricos, envolvendo algoritmos de aprendizado.

Buscam imitar a estrutura de interconexões do cérebro humano, com o intuito de incorporar o padrão de comportamento de uma série temporal (TURBAN, 1993).

Esses três aspectos (modelagem, transformações e interpretação) são fundamentais na utilização das RNA para previsão de preços.

3 – METODOLOGIA

3.3 RNA

A unidade básica de uma RNA é o neurônio artificial (Figura 1).

Sua estrutura busca reproduzir a estrutura do neurônio humano, tendo assim, três componentes básicos: um elemento somatório, uma função de ativação e as ponderações w_i .

Figura 1 – Modelo de neurônio artificial





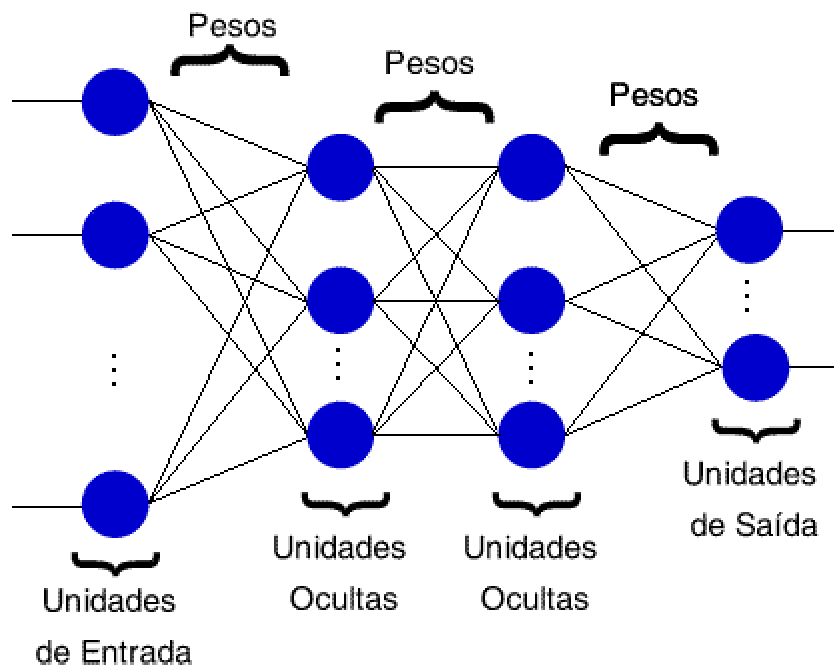
Figura 2 – Modelo de rede neural



3 – METODOLOGIA

3.3 RNA

O algoritmo mais estudado e bem-sucedido no processo de aprendizagem de uma RNA é o algoritmo de *backpropagation*, que tem apresentado os melhores resultados em diversos estudos (FITZPATRICK, 1999).




3 – METODOLOGIA

3.3 RNA

Para 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.

O algoritmo de *backpropagation* ajusta, então, as ponderações de modo a minimizar os erros de previsão dentro da faixa-teste.

Figura 3 – Esquema de uma RNA para previsão de preços



3 – METODOLOGIA

3.4 ÍNDICE DE SHARPE

CrITÉrios Para Avaliação do Desempenho Operacional dos Modelos

O desempenho de cada modelo nos diferentes mercados é avaliado aplicando as previsões em simulações de compra e venda de contratos futuros, GARCIA (1988).

A medida adequada para a comparação entre sistemas de negociação deve considerar a relação retorno-risco dos modelos.

Uma medida clássica de retorno-risco, o Índice Sharpe (IS):

$$IS = \frac{\mu_R}{\sigma_R}$$

4 – AVALIAÇÃO DOS RESULTADOS

Quadro 1 - Estatísticas e Índice Sharpe dos Retornos Financeiros das simulações: contratos de boi gordo da BM&F (1998/1999).

	ARIMA	RNA	MLD
Média (US\$)	936,56	892,56	1.015,52
Desvio Padrão (US\$)	2.331,45	2.349,40	2.296,69
Índice Sharpe	0,402	0,380	0,442

Quadro 2 - Estatísticas e Índice Sharpe dos Retornos Financeiros das simulações: contratos de café da BM&F (1998/1999).

	ARIMA	RNA	MLD
Média (US\$)	1.380,59	(351,41)	1.380,59
Desvio Padrão (US\$)	8.753,06	8.865,81	8.753,06
Índice Sharpe	0,158	(0,040)	0,158

Quadro 3 - Estatísticas e Índice Sharpe dos Retornos Financeiros das simulações: contratos de soja da BM&F (1998/1999).

	ARIMA	RNA	MLD
Média (US\$)	1.034,79	1.019,79	967,29
Desvio Padrão (US\$)	1.154,80	1.169,26	1.216,97
Índice Sharpe	0,896	0,872	0,795

4 – AVALIAÇÃO DOS RESULTADOS

CONCLUSÕES

- **Boi gordo:** todos os modelos apresentam valores positivos do Índice Sharpe, indicando aplicações no mercado futuro;
- **Café:** Alta volatilidade nos retornos observados para os três modelos decorre da alta volatilidade dos preços. Assim, temos uma contra-indicação de aplicação do modelo RNA;
- **Soja:** os modelos ARIMA e de Redes Neurais apresentam as maiores médias de retornos financeiros.

O modelo com melhor desempenho simulado nos três mercados é o ARIMA:

- Em função de sua rápida adaptabilidade e estrutura parcimoniosa, produz as previsões positivas nas simulações de compra e venda de contratos futuros das três *commodities*.

OBRIGADO