

MODELOS DE PREVISÃO APLICADO AO MERCADO DE CARNE SUÍNA

Alan Figueiredo de Aredes¹
Alessandro de Assis Santos Oliveira²

RESUMO

Dada a importância do nível de preço para o planejamento e tomada de decisão, o objetivo do artigo é analisar a viabilidade na utilização de modelos de séries temporais univariadas como instrumentos de apoio à tomada de decisão. Para isso, realizou-se uma análise empírica sobre o poder de previsão dos modelos SARIMA, GARCH e TARCH em relação ao preço recebido pelo produtor de suíno utilizando a série de preços no período de 06/1994 a 08/2007 no Estado do Paraná. Os resultados indicam que os modelos são viáveis por apresentarem baixo erro percentual de previsão médio, especialmente o modelo TARCH.

Palavras-chave: previsão, preços, suíno.

ABSTRACT

Given the importance of the price level for the planning and decision making, the objective of the paper is to analyze the viability applying time series models for decision making. The empiric analysis tries to forecast the price received by swine products in the period from 06/1994 to 08/2007 in the state of Paraná. Time series models such as SARIMA, GARCH and TARCH were evaluated as support instruments for decision making. The results target that all the models are viable for they present low error of medium forecast, especially the model TARCH.

Key-words: forecast, prices, swine.

JEL Classification: Q13, C22, C53.

1 INTRODUÇÃO

O Brasil é o quarto maior produtor de suínos, com 2.930 mil ton. de equivalente carcaça, ficando atrás apenas da China, com 54.352 mil ton., União Européia, com 21.450 mil tom. e Estados Unidos, com mil 9.795 ton.. No ano de 2006, o país exportou aproximadamente 523 mil ton. de carne, somando um total de US\$ 1.027.890, sendo a Rússia, o principal país de destino, tendo importado cerca de 270 mil toneladas (AGRIANUAL, 2007).

Inserido no agronegócio brasileiro, o setor suinícola é caracterizado pela forte dependência e sensibilidade a fatores naturais e de mercado interno e externo, como a de

¹ Professor na Universidade Federal Fluminense, doutorando em Economia Aplicada (UFV-MG).

² Professor do Centro Universitário de Sete Lagoas, MS em Economia Aplicada (UFV-MG).

produção e preço do suíno, milho e soja, da taxa de câmbio, do baixo consumo *per capita* interno, entre outros.

A instabilidade do setor ficou mais evidenciada em meados de 2002. Nesse período, o setor enfrentou uma de suas piores crises, provocada por uma combinação desfavorável entre o preço do suíno e dos seus principais insumos, em especial o preço do milho (ROCHA, 2006), o qual, juntamente com a soja, correspondem aproximadamente por 80% dos custos de produção da carne suína.

Com essa crise, destacaram-se mais intensamente os riscos inerentes à produção e comercialização de suínos, indicando a necessidade do desenvolvimento de mecanismos de proteção contra movimentos desfavoráveis desse mercado, como a utilização de modelos de previsão do preço da carne.

Nesse sentido, o presente artigo tem por objetivo analisar a eficácia da utilização de modelos de séries temporais como instrumentos de apoio à tomada de decisão na produção e comercialização de suínos pelos produtores paranaenses no período de 06/1994 a 08/2007. A série de preços do Estado do Paraná foi escolhida para análise por ser esse Estado um dos principais produtores de suínos do Brasil, concentrando muitas das empresas processadoras que fazem parte do sistema produtivo integrado suinícola.

2 REFERÊNCIAL TEÓRICO

A tomada de decisão é um processo contínuo, caracterizado por uma dinâmica de efeitos e causas, baseada nas relações de fluxo de entrada, saída e *feedback* de informações. Segundo Vale *et al.* (2002), a tomada de decisão é o centro do processo administrativo caracterizado por uma ordem lógica, que, embora não assegure a perfeição, assegura, no mínimo, a implementação de uma decisão lógica e bem ordenada.

De uma forma geral, o processo de tomada de decisão é formado por fases. Segundo De Maio *et al.* (1985), citado por Francischini (2001), existem seis fases, interligadas em uma ordem lógica, como a apresentada pela Figura 1.

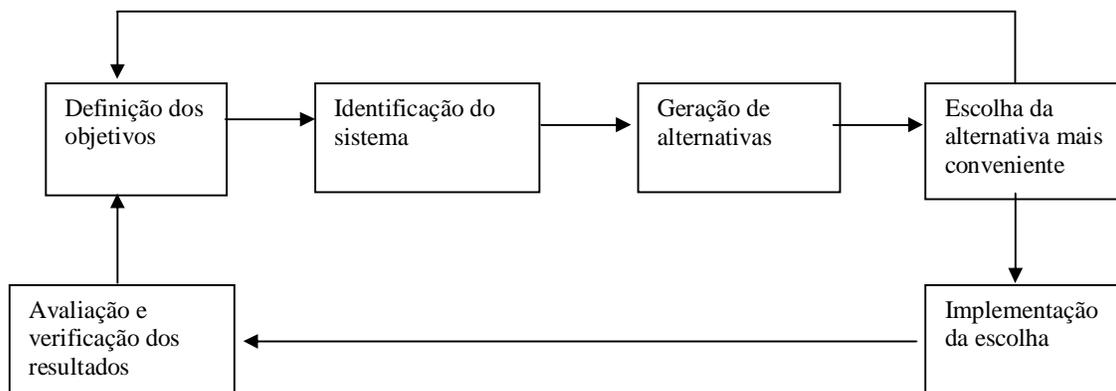


Figura 1: Fases do apoio a tomada de decisão
 Fonte: De Maio *et al.* (1985), citado por Francischini (2001)

Pelo diagrama, pode-se inferir a sequência lógica e dinâmica da informação na tomada de decisão, que consiste na definição dos objetivos, identificação do sistema, geração de alternativas, escolha da alternativa mais conveniente, implementação da escolha e avaliação e verificação dos resultados efetivos.

De uma forma geral, as decisões podem ser classificadas em organizacionais e operacionais, sendo a segunda mais frequente devido a própria natureza dessa decisão, que são rotineiras no ciclo de produção de uma empresa; o que não acontece com as decisões organizacionais que são geralmente de longo prazo. Além disso, as decisões possuem outras características peculiares, que podem classificá-las de acordo com sua importância, frequência, iminência, revogabilidade e número de alternativas disponíveis (VALE *et al.*, 2002).

Segundo Vale (1995), a eficácia do processo de tomada de decisão está intimamente determinada pelas funções exercidas pelo administrador, ao seu planejamento, organização, direção e controle e do sistema de informação. Nesse contexto, a informação, que é responsável pela interligação entre administrador, automação e o mundo, é afetada por fatores como disponibilidade, oportunidade, custo e nível de detalhamento.

Conforme Martin (1993), citado por Rezende (1998), a obtenção de dados reais e consistentes para criarem informações que subsidiem a tomada de decisão, não se tem demonstrado uma tarefa fácil. Rezende (1998) exalta que embora o produtor rural precise ter informações corretas e no tempo certo, a falta de informações eficientes e a precária habilidade interpretativa dos dados acabam comprometendo a administração. No entanto, conhecendo o tipo de informação desejada e seu uso, sabendo-se das restrições na disponibilidade de dados, é possível construir bons modelos (VALE, 1995). Informações

de qualidade disponíveis a profissionais que podem utilizá-las subsidiarão decisões mais precisas, possibilitando o alcance das metas administrativas e sustentando a organização (VALE, 1995). A análise da relevância da informação na tomada de decisão é apresentada de forma sucinta por Sanders (1974), citado por Vale (1995), na Figura 2.

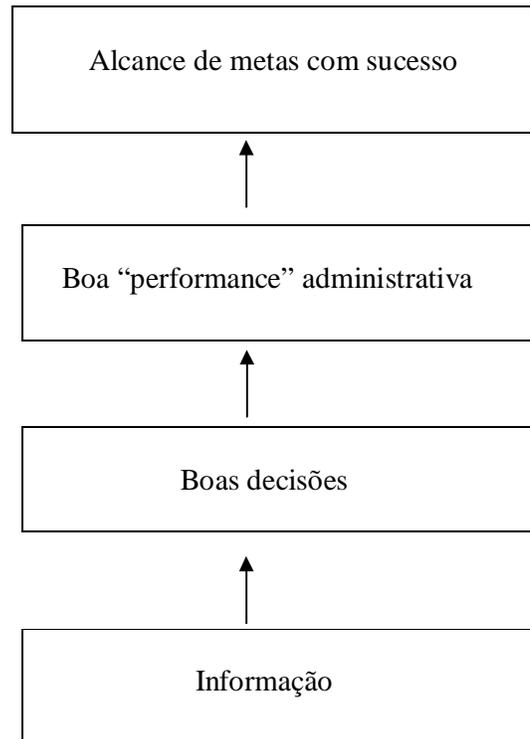


Figura 2: Importância da informação na tomada de decisão.
Fonte: Sanders (1974), citado por Vale (1995).

Nesse sentido, torna-se claro para o bom desempenho da empresa rural, que o administrador deve estar apoiado em um sistema de apoio à tomada de decisão que torne suas atitudes as melhores possíveis. Saber coletar dados, processar e interpretar as informações de maneira correta e na hora certa são alicerces fundamentais para a eficiência empresarial.

3 METODOLOGIA

3.1 MODELOS DE PREVISÃO

Foram utilizados três modelos de séries temporais univariadas para previsão dos preços, são eles: SARIMA, GARCH e TARCH ambos desenvolvidos a partir do modelo

ARMA apresentado por Box e Jenkins (1976), os quais apresentaram também uma metodologia para estimação desses modelos univariados autorregressivos e de médias móveis, realizada em quatro etapas. Conforme Gujarati (2000) o estudo seguiu os seguintes passos:

Etapa 1 (identificação): foram identificados os valores de p , d e q , ou seja, os valores das defasagens e do grau de diferenciação apropriados para a série de preços se tornar estacionária. Para isso, utilizou-se o correlograma (função de autocorrelação), o correlograma parcial (função de autocorrelação parcial), os testes estatísticos: *Akaike info criterion (AIC)* e *Schwarz criterion (SC)* e o teste de raiz unitária de *Dickey-Fuller*.

Etapa 2 (estimativa): foram estimados os parâmetros dos modelos utilizando o método de mínimos quadrado ordinário para obtenção do modelo SARIMA e o método de máxima verossimilhança para obtenção dos modelos GARCH e TARCH.

Etapa 3 (checagem): avaliaram-se os modelos estimados realizando-se o teste de raiz unitária na série de resíduos dos modelos. O teste mostrou que todos os resíduos foram estacionários e que os modelos tiveram bom ajuste.

Etapa 4 (previsão): por fim, verificou-se a potencialidade de previsão do modelo. Para isso, estimaram-se os modelos tendo preservado uma parte da série dos dados para verificação da potencialidade da previsão. Dessa forma, podem-se comparar os preços observados com os previstos.

Antes da apresentação dos modelos SARIMA, GARCH e TARCH, é necessário a apresentação do modelo ARIMA (*Autoregressive Integrated Moving Average*), introduzido por Box e Jenkins (1976).

a) Modelo ARIMA

Esse modelo é dado pela estimação da regressão da variável dependente y em função das defasagens da própria variável y , indicado por p termos auto-regressivos, e em função dos erros aleatórios, indicado por q termos média móvel. Como a maioria das séries temporais econômicas são naturalmente não estacionárias, a aplicação do modelo ARIMA (p,d,q) exige a transformação das mesmas, por d diferenças para torná-las estacionárias, ao passo que a ordem p e q pode ser obtida pelos correlogramas da função de autocorrelação (FAC) e função de autocorrelação parcial (FACP), sendo auxiliadas pela ordem que minimiza o critério de *Akaike (AIC)* ou o critério de *Schwarz (SC)*.

O modelo ARIMA pode ser apresentado como:

$$\Delta y_t = \phi + \sum_{i=1;p} \beta_i \Delta_{t-i} + u_t + \sum_{i=1;q} \alpha_i u_{t-i} \quad (1)$$

em que Δ_{t-1} é o operador de diferenças; y a série de preços; u o termo de erro; ϕ o termo intercepto; β e α são os parâmetros a serem estimados.

b) Modelo SARIMA

Como muitas séries temporais econômicas apresentam um componente sazonal em sua evolução, como é o caso das séries de preços de alguns produtos agropecuários, torna-se necessário incorporar o componente sazonal na estimativa ARIMA. O novo modelo estimado, denominado SARIMA, passa a ser composto pelos componentes sazonais autorregressivos SAR(P) e média móvel SMA(Q), apresentado como SARIMA (p,d,q) (P,D,Q), em que D é a ordem de diferenciação sazonal (FARIAS et al., 2005).

Em forma de equação:

$$\Delta y_t = \varphi + \sum_{i=1;p} \beta_i \Delta_{t-i}^d + \sum_{i=1;p} \Lambda_i^P \Delta_{t-i}^D + u_t + \sum_{i=1;q} \alpha_i u_{t-i} + \sum_{i=1,p} \lambda_i^Q u_{t-i} \quad (2)$$

em que Δ_{t-i}^d é o operador de diferenças normal; Δ_{t-1}^D o operador de diferenças sazonal; ϕ o termo intercepto; β o componente AR; Λ e λ são os parâmetros a serem estimados. O diagnóstico da verificação do componente de sazonalidade e das ordens de defasagens podem ser feitas a partir da análise da FAC e FACP e pelos critérios de AIC e de SC.

c) Modelo GARCH

Dada às restrições do modelo ARIMA e SARIMA em manterem a variância do erro constante ao longo do tempo, Engle (1982) sugeriu-se um modelo alternativo para previsões, denominado ARCH (*Autoregressive Conditional Heteroskedasticity*) que introduz a variância condicional do erro determinada pela defasagem ao quadrado dos erros. O modelo ARCH (q), em que q é o número de defasagens ao quadrado dos erros, pode ser representa como:

$$\sigma_t^2 = \Phi + \sum_{i=1:q} \omega_i u_{t-i}^2 \quad (3)$$

em que σ é a variância condicionada e Φ e ω são parâmetros a serem estimados.

Porém, devido ao grande número de defasagens q freqüentemente encontrados no modelo ARCH, Bollerslev (1986) sugeriu um modelo geral e simplificado denominado GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*). Tal modelo apresenta a vantagem operacional ao incorporar a própria variância condicional passada como fator determinante da variância condicional do erro. Dessa forma, o modelo GARCH (q, p), onde p é o número de defasagens ao quadrado dos erros e q o número de defasagens ao quadrado da própria variância condicional, é dado como:

$$\sigma_t^2 = \Phi + \sum_{i=1:q} \omega_i u_{t-i}^2 + \sum_{j=1:p} \phi_j \sigma_{t-j}^2 \quad (4)$$

em que Φ , ω e ϕ são parâmetros a serem estimados. Além disso, o somatório dos parâmetros estimados dos termos u_{t-i}^2 e σ_{t-j}^2 , ou seja, $\omega + \phi$ mede a persistência de choques sobre a volatilidade ao longo do tempo.

d) Modelo TARARCH

Entretanto, dado a existência de movimentos assimétricos, onde períodos de quedas dos preços são seguidos por volatilidades mais intensas que nos períodos de alta dos preços, e tendo o modelo GARCH não capturado esse efeito alavancagem, Zakoian (1994) desenvolveu o modelo TARARCH (*Threshold Autoregressive Conditional Heteroskedasticity*) e Nelson (1991) o modelo EGARCH (*Exponential Autoregressive Conditional Heteroskedasticity*) que capturam esse efeito assimétrico.

No modelo TARARCH (1,1), a volatilidade condicional é dada por:

$$\sigma_t^2 = \Phi + \omega u_{t-1}^2 + \phi \sigma_{t-1}^2 + \gamma d_{t-1} u_{t-1}^2 \quad (5)$$

em que Φ , ω , ϕ e γ são parâmetros a serem estimados e em que a variável *dummy* será igual a $d_{t-1} = 1$ quando $u_{t-1} < 0$ e $d_{t-1} = 0$ quando $u_{t-1} > 0$. Caso $\gamma = 0$, estatisticamente, não ocorre o efeito assimetria, não existindo diferença entre os choques positivos ou negativos de preços sobre a volatilidade. Caso contrário, $\gamma \neq 0$, existe assimetria na

variância, tendo $\omega + \gamma$ captado a ocorrência de choques negativos de mercado, $u_{t-1} < 0$, baixista dos preços e ω captado os efeitos de choques positivos, $u_{t-1} > 0$, alta dos preços. Caso $\gamma > 0$ ocorre o efeito alavancagem, em que choques negativos levam a maior volatilidade que choques positivos.

3.2 AUTOCORRELAÇÃO

Para analisar a autocorrelação das séries de preços foram obtidos os coeficientes de autocorrelação e autocorrelação parcial e construídas os correlogramas das funções de autocorrelação (FAC) e autocorrelação parcial (FACP), intervalos de confiança e empregados testes estatísticos, como o de *Box e Pierce* e *Ljung-Box*.

A hipótese a ser testada é a de que os coeficientes de autocorrelação individuais são iguais à zero, ou seja:

$$\begin{aligned} H_0 : \rho_k &= 0 \\ H_1 : \rho_k &\neq 0 \end{aligned} \tag{6}$$

em que ρ é o coeficiente de autocorrelação, dado como:

$$\rho_k = \frac{\sum (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum (Y_t - \bar{Y})^2} \tag{7}$$

ou seja, é o quociente entre a covariância na defasagem k e a variância da série.

Para verificar a hipótese nula de estacionariedade individual dos coeficientes foi construída a função de autocorrelação (FAC), dada pela representação gráfica entre as defasagens e os coeficientes de autocorrelação, e construído o intervalo de confiança na forma:

$$IC(95\%) = 0 \pm 1,96 \left(\frac{1}{\sqrt{n}} \right) \tag{8}$$

em que IC(95%) é o intervalo de confiança com 95% de significância e n o tamanho da amostra. Caso pelos menos um dos coeficientes de autocorrelação esteja fora desse intervalo, este será estatisticamente diferente de zero.

Para o caso de hipótese conjunta de estacionariedade, o teste é representado por:

$$\begin{aligned} H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \\ H_1 : \rho_1 = \rho_2 = \dots = \rho_k \neq 0 \end{aligned} \quad (9)$$

Para esse teste, podem ser utilizadas as estatísticas de *Box e Pierce* e *Ljung-Box*, dadas por:

$$Q = n \sum_{k=1}^m \rho_k^2 \sim \chi_m^2 \quad (10)$$

$$LB = n(n+2) \sum_{k=1}^m \left(\frac{\rho_k^2}{n-k} \right) \sim \chi_m^2 \quad (11)$$

em que Q é a estatística de *Box e Pierce* e LB a estatística de *Ljung-Box*; n o tamanho da amostra; m a duração da defasagem; χ_m^2 a distribuição qui-quadrado com m graus de liberdade; k a defasagem e ρ o coeficiente de autocorrelação.

Caso as estatísticas Q e LB sejam maiores que o valor crítico da estatística χ_m^2 , rejeita-se a hipótese nula conjunta de nulidade das autocorrelações, sendo alguns coeficientes diferentes de zero.

3.3 TESTE DE RAIZ UNITÁRIA

Um dos testes mais utilizados para verificar a ocorrência de raiz unitária em séries temporais é o teste de raiz unitária *Dickey-Fuller* Aumentado (ADF), o qual testa a significância nula do parâmetro δ estimado na equação de teste. Caso a hipótese nula não seja rejeitada, a estatística τ (*tau*) calculada seja menor em valor absoluto que a tabelada ou crítica τ a um dado nível de significância estabelecido, a série possui pelo menos uma raiz unitária, sendo não estacionária. O teste ADF na sua forma completa é representado por:

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \alpha_i \sum_{i=1}^m \Delta Y_{t-i} + \varepsilon_t \quad (12)$$

em que Δ é o operador de diferença; Y_t a série; β_1 e β_2 os parâmetros intercepto e tendência, respectivamente; δ a hipótese de teste a ser testada; $\alpha_i \sum_{i=1}^m \Delta Y_{t-i}$ o termo de

diferenças defasadas para evitar e retirar autocorrelações existentes, cujas defasagens podem ser indicadas pelos critérios estatísticos de *Akaike info criterion* (AIC) e *Schwarz criterion* (SC); e ε_t o erro aleatório.

Caso a hipótese nula não seja rejeitada, não se deve aceitar de imediato a existência de raiz unitária na série, visto que o teste é muito sensível à existência de tendência e intercepto na equação do teste e vice-versa, sendo necessários novos testes com a equação para verificar a significância do intercepto e tendência na equação de teste. Para isso, Enders (1995) desenvolveu uma estratégia de teste seqüencial para a verificação da existência de raiz unitária.

Confirmada a hipótese da existência de raiz unitária na série, esta deve ser diferenciada e testada novamente a presença de raiz, sendo praticada d diferenciações até que o teste de raiz unitária seja rejeitado, sendo a ordem de integração da série I(d). Caso a primeira diferença seja estacionária, então se trabalha com a série em primeira diferença, sendo seu grau de integração igual a 1, ou seja, I(1).

3.4 CRITÉRIO DE AVALIAÇÃO DE PREVISÃO DOS MODELOS

Na avaliação de previsão dos modelos foi utilizado o critério denominando erro percentual de previsão (EPP) definido por Armstrong e Fidels (1995) e citado por Bressan e Lima (2005), para avaliar o poder de previsão pontual dos modelos. O método é apresentado como:

$$EPP_t = VP_{t+1} - VO_{t+1} / VO_{t+1} \quad (13)$$

em que EPP_t é o erro percentual de previsão do modelo; VP_{t+1} o preço previsto e VO_{t+1} o preço real ou observado. O Erro Percentual de Previsão Médio (EPPM) é dado pela média dos percentuais individuais no período de tempo escolhido.

3.5 FONTE DE DADOS E ESTIMAÇÃO DOS MODELOS

Os dados utilizados referem-se à série de preços médio mensal do quilo do suíno de corte recebido pelos produtores do Estado do Paraná no período 06/1994 a 08/2007. Os

modelos foram estimados utilizando a série no período de 06/1994 a 08/2006 e as previsões foram realizadas para o período de 09/2006 a 08/2007. A série de dados foi obtida junto ao IPEA (2007) e os *softwares* utilizados foram o *Eviews 5.0* e *JMulti 4.21*, sendo o primeiro utilizado nas estimações e previsões e o segundo nos testes de raiz unitária.

4 RESULTADOS

Para aplicação de modelos de previsão como: SARIMA, GARCH e TARCH é necessário que a série temporal de preços do suíno (Figura 3) seja estacionária. Para verificar esse requisito, aplicou-se o teste de raiz unitária ADF.

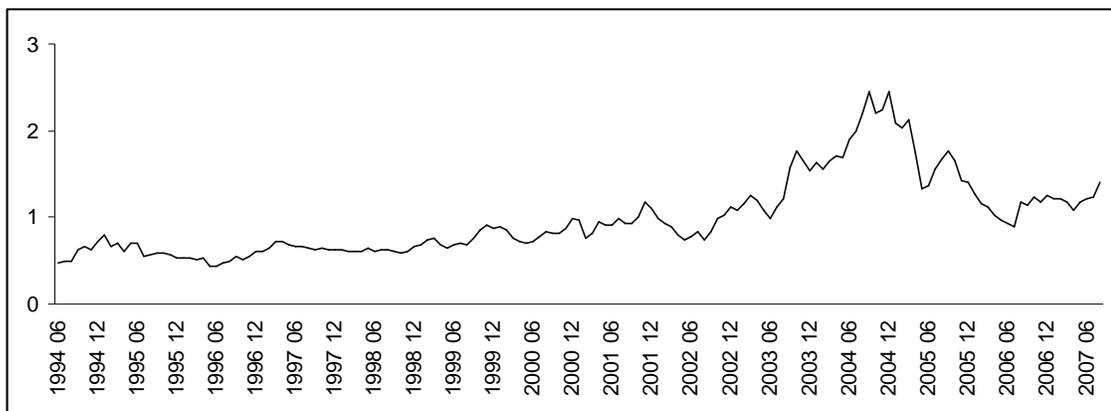


Figura 3: Série de preços em reais recebido pelo produtor de suínos no período de 06/1994 a 08/2007, no Estado do Paraná

Fonte: IPEA (2007)

De acordo com o teste de raiz unitária ADF, detectou-se a presença de raiz unitária na série de preços em nível, pois o valor do teste calculado de -3.42 é menor em valor absoluto que os valores críticos a 5%, sendo a série não estacionária em nível. No teste, aplicou-se o procedimento sequencial de Enders (1995), sendo constatada a significância estatística do componente tendência a 5% pelo teste *t de student* na equação de teste ADF, o que sugere a presença de raiz unitária na série conforme tabela 1.

Aplicando os testes de raiz ADF com o componente sazonal e com quebra estrutural (em setembro de 2004) identificou-se pelos dois primeiros testes a presença de

uma raiz unitária, uma vez que as estatísticas calculadas dos testes são menores em valores absolutos que as tabeladas a 5% de significância (tabela 1).

Pela análise das funções de autocorrelação (FAC) e função de autocorrelação parcial (FACP) da série em nível, percebe-se que as autocorrelações na FAC até a defasagem 36 estão fora do intervalo de confiança de 95%, sendo os coeficientes estatisticamente diferentes de zero. Conforme a figura 4 da FACP, quatro defasagens estiveram fora do intervalo de confiança.

Tabela 1: Teste de raiz unitária da série de preços em nível

ADF			
Nível de Significância	Valores críticos	Estatística t	P-valor
1%	-4.02	-3.42	0.052
5%	-3.44		
10%	-3.14		
ADF com sazonalidade			
Nível de Significância	Valores críticos	Estatística t	P-valor
1%	-3.96	-2.21	0.000
5%	-3.41		
10%	-3.13		
Teste ADF com quebra estrutural com sazonalidade			
Nível de Significância	Valores críticos	Estatística t	P-valor
1%	-3.55	-2.21	0.000
5%	-3.03		
10%	-2.76		

Fonte: Dados da pesquisa.

Pela análise das funções de autocorrelação (FAC) e função de autocorrelação parcial (FACP) da série em nível percebe-se que as autocorrelações na FAC até a defasagem 36 estão fora do intervalo de confiança de 95%, sendo os coeficientes estatisticamente diferentes de zero. Conforme a figura 4 da FACP quatro defasagens estiveram fora do intervalo de confiança.

Além disso, as estatísticas Q e LB calculadas, 1790.69 e 2343.90, respectivamente, indicam a rejeição da hipótese de nulidade conjunta das autocorrelações da série, uma vez que os valores dessas estatísticas são maiores que a estatística qui-quadrado tabelada de 55.76 a 5% de probabilidade e 40 graus de liberdade.

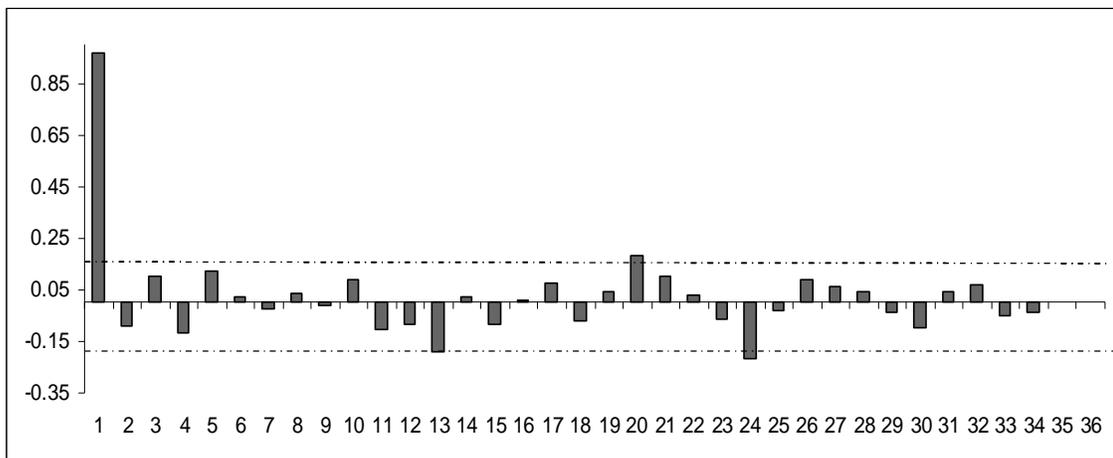
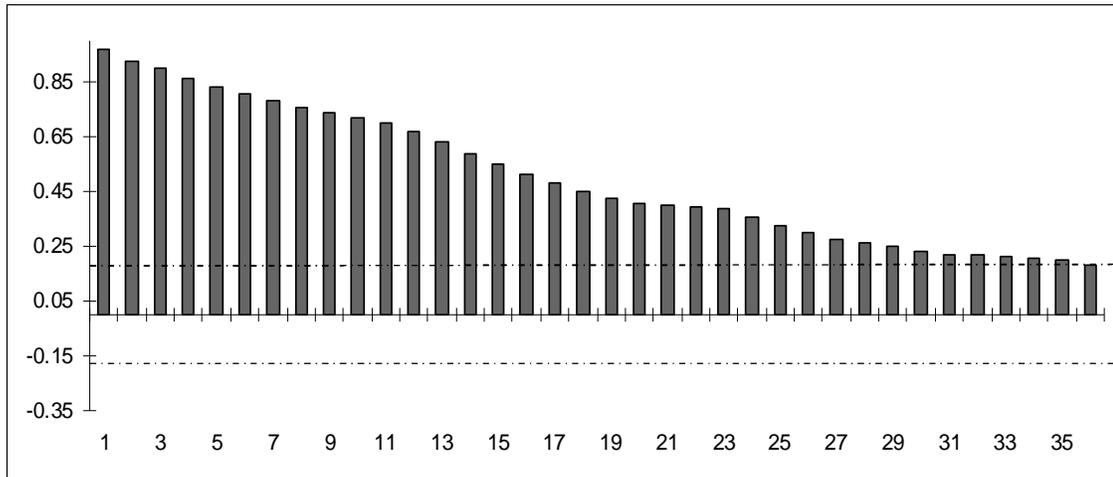


Figura 4 (a) e (b): Funções de autocorrelação (FAC) e de autocorrelação parcial (FACP) da série em nível com 36 defasagens

Fonte: Dados de Pesquisa

Diante da não estacionariedade da série de preços em nível, trabalhou-se com a sua primeira diferença, eliminando-se o problema da não estacionariedade dessa. Como observado na tabela 5, a primeira diferença da série de preços não apresenta raiz unitária pelo teste ADF, uma vez que o coeficiente estimado de -6.63 é superior em módulo ao valor crítico a 5%. Da mesma forma, o teste de raiz unitária ADF com o componente

sazonal e com quebra estrutural em setembro de 2004 também constatam a não presença de raiz unitária, pois o valor dos testes calculados são maiores que os tabelados a 5% (tabela 2).

Tabela 2: Testes de raiz unitária da série de preços na primeira diferença

ADF			
Nível de Significância	Valores críticos	Estatística t	P-valor
1%	-4.02	-6.63	0.000
5%	-3.44		
10%	-3.14		
ADF com sazonalidade			
Nível de Significância	Valores críticos	Estatística t	P-valor
1%	-3.96	-9.61	0.000
5%	-3.41		
10%	-3.13		
Teste com quebra estrutural com sazonalidade			
Nível de Significância	Valores críticos	Estatística t	P-valor
1%	-3.55	-8.74	0.000
5%	-3.03		
10%	-2.76		

Fonte: Dados de Pesquisa

As funções de autocorrelação (FAC) e de autocorrelação parcial (FACP) da primeira diferença mostram que a série na primeira diferença possui algumas autocorrelações diferentes de zero. No caso da FAC, as defasagem 16, 19, 23 e 31 não pertencem ao intervalo de confiança de 95%, sendo estatisticamente diferentes de zero. Já na FACP as defasagens fora do intervalo de confiança são as: 3, 4 e 19 (figura 5).

Além disso, as estatísticas Q e LB calculadas, 84.52 e 110.63, indicam autocorrelações conjuntas diferentes de zero após a primeira diferença, pois os valores dessas estatísticas são maiores que a estatística qui-quadrado tabelado, que é de 55.76 ao nível de 5% e 40 graus de liberdade. Assim, pelo menos alguns coeficientes de autocorrelação devem ser diferentes de zero.

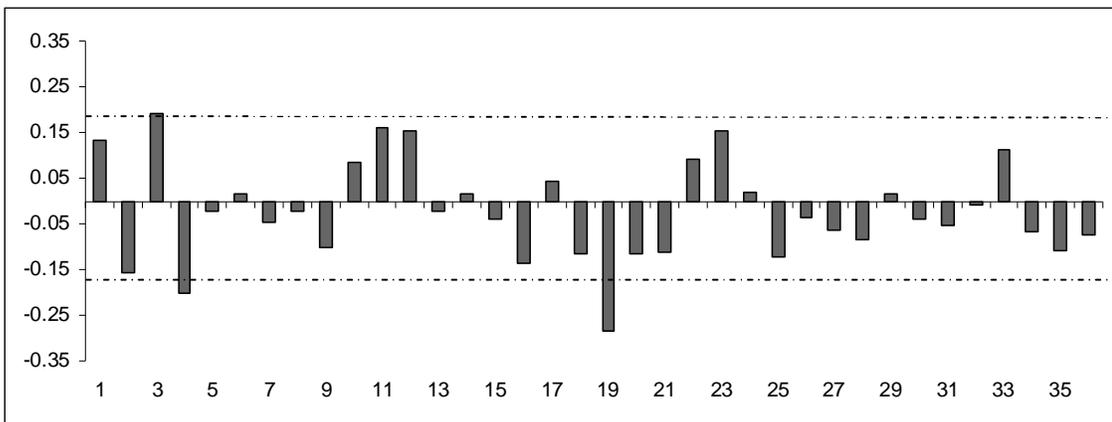
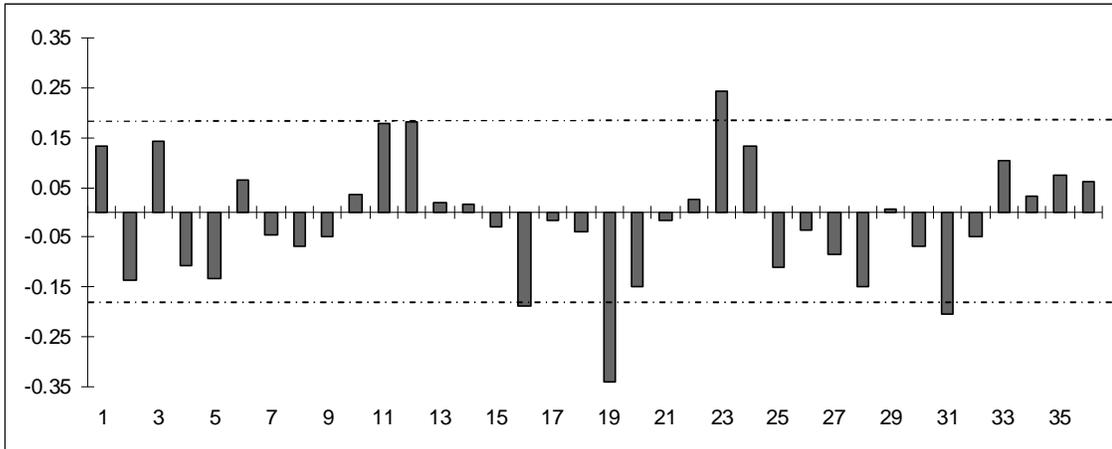


Figura 5 (a) e (b): Funções de autocorrelação (FAC) e de autocorrelação parcial (FACP) da série de preços em primeira diferença com 36 defasagens

Fonte: Dados de Pesquisa

Embora o fato de algumas autocorrelações terem sido diferentes de zero na série em primeira diferença, os testes de raiz unitária rejeitaram a existência de ocorrência de raiz na série diferenciada, sendo assim utilizada nas análises a série em primeira diferença.

Assim sendo, utilizou-se a metodologia de Box e Jenkins (1976) para as modelagens. O primeiro modelo avaliado foi o SARIMA, sendo o modelo estimado um SARIMA (1,1,2) (1,0,0) que teve bom ajustamento com todas as defasagens estatisticamente significativas a 1%, com exceção para o intercepto. Além disso, como pode ser visto mais adiante, comparando-se esse modelo com os de heterocedasticidade condicional, GARCH e TARCH, o modelo SARIMA apresentou boa performance nas previsões (tabela 3).

Tabela 3: Resultados da aplicação do modelo SARIMA (1,1,2) (1,0,0)

Variáveis	Coefficiente	Desvio padrão	Estatística t	P-valor
Constante	0.0041	0.0083	0.4980	0.6193
AR(1)	-0.4000	0.1540	-2.5970	0.0104
SAR(1)	0.7433	0.1319	5.6323	0.0000
MA(2)	-0.6551	0.1375	-4.7616	0.0000
<i>Akaike info criterion (AIC)</i>	-1.7213		Estatística F	0.0000
<i>Schwarz criterion (SC)</i>	-1.6388		R ²	0.1482

Fonte: Dados de Pesquisa

O modelo GARCH (1,1) também teve bom ajustamento, sendo todas as defasagens estatisticamente significativas a 1%, com exceção para os interceptos. Além disso, como o somatório dos parâmetros estimados dos termos u_{t-i}^2 e σ_{t-j}^2 foi de 1.047167, existe uma alta persistência de choques sobre a volatilidade do preço (tabela 4).

Tabela 4: Resultados da aplicação do modelo GARCH (1,1)

Variáveis	Coefficiente	Desvio padrão	Estatística t	P-valor
Constante	0.0020	0.0048	0.4172	0.6765
AR(1)	-0.6979	0.1009	-6.9130	0.0000
MA(1)	0.9146	0.0610	14.973	0.0000
<i>Akaike info criterion (AIC)</i>	-2.2145		Estatística F	0.0050
<i>Schwarz criterion (SC)</i>	-2.0914		R ²	0.1122
Variância Condicional				
θ	2.3E-05	6.2E-05	0.3680	0.7129
$u_{t\equiv i}^2$	0.2241	0.0571	3.9246	0.0001
$\sigma_{t\equiv j}^2$	0.8229	0.0396	20.735	0.0000

Fonte: Dados de Pesquisa

O modelo TARARCH (1,1) estimado é apresentado na tabela 5. Todas as defasagens do modelo TARARCH são estatisticamente significativas a 1%, com exceção para os interceptos. Como a variável defasada do termo $d_{t-1}u_{t-1}^2$ é significativa a 1%, o modelo estimado TARARCH (1,1) evidencia a existência de movimentos assimétricos na série de preços.

Tabela 5: Resultados da aplicação do modelo TAR(1,1)

Variáveis	Coefficiente	Desvio padrão	Estatística t	P-valor
Constante	0.0100	0.0049	2.0563	0.0397
AR(1)	-0.8200	0.0691	-11.866	0.0000
MA(1)	0.9766	0.0195	50.012	0.0000
<i>Akaike info criterion (AIC)</i>	-2.2674		Estatística F	0.1414
<i>Schwarz criterion (SC)</i>	-2.1237		R ²	0.0664

Variância Condicional				
ϕ	2.1E-05	4.7E-05	0.4359	0.6628
$u_{t\equiv i}^2$	0.3890	0.1004	3.8742	0.0001
$d_{t\equiv i}u_{t\equiv i}^2$	-0.4211	0.1102	-3.8184	0.0001
$\sigma_{t\equiv j}^2$	0.8870	0.0464	19.112	0.0000

Fonte: Dados de Pesquisa

Além disso, como o parâmetro estimado do termo $d_{t-1}u_{t-1}^2$ é menor que zero, não ocorrendo o efeito alavancagem na série, em que o preço não possui maior volatilidade durante a queda do preço do que na alta.

Para avaliação dos modelos, utilizou-se o teste de raiz unitária ADF sem tendência e sem intercepto, uma vez que esses termos não foram significativamente diferentes de zero na equação de teste ADF, nos resíduos para verificação da hipótese de sua estacionariedade. Os testes de raiz unitária dos modelos SARIMA (1,1,2) (1,0,0), GARCH (1,1) e TAR(1,1) rejeitaram a hipótese de raiz unitária na série dos resíduos, sugerindo estacionariedade e bom ajustamento dos modelos, uma vez que as estatísticas calculadas do teste são maiores em valores absolutos que os críticos a 5% de significância (tabela 6).

Tabela 6: Testes de raiz unitária ADF da série de resíduos dos modelos estimados para o preço do suíno no período de 06/1994 a 08/2007.

Significância	Estatística	SARIMA	GARCH	TAR(1,1)
1%	-2.58	-4.64	-2.63	-2.59
5%	-1.94			
10%	-1.62			

Fonte: Dados de pesquisa

Realizando a quarta e última etapa da metodologia de BOX e JENKINS (1976), para utilização dos modelos de séries temporais univariados, considerando a série de preços no período de 06/1994 a 08/2006 para estimação dos modelos e a série de 09/2006 a 08/2007 para verificação da potencialidade de previsão destes. De acordo com os resultados, o modelo com melhor nível de previsão pontual foi o TARCH (1,1), seguido pelo GARCH (1,1) e SARIMA (1,1,2) (1,0,0) (tabela 7).

De uma forma geral, todos os modelos possuem alto poder de previsão, uma vez que os erros percentuais de previsão médios (EPPM)³ foram significamente baixos, menores que 12%, tendo-se o modelo TARCH (1,1) o menor EPPM, 8,21%, seguido pelo GARCH (1,1), 9,92%, e pelo SARIMA (1,1,2) (1,0,0), 11,47%. Além disso, os modelos GARCH e TARCH tiveram os menores erros percentuais de previsão individual (EPPI), tendo previstos oito melhores níveis de preço que o modelo SARIMA, que foi melhor em apenas quatro previsões individuais.

Tabela 7: Valores dos preços previstos pelos modelos

MÊS	REAL	SARIMA	GARCH	TARCH
set/06	1,15	1,31	1,25	1,22
out/06	1,24	1,04	1,08	1,12
nov/06	1,18	1,36	1,32	1,29
dez/06	1,26	1,06	1,09	1,14
jan/07	1,22	1,39	1,36	1,33
fev/07	1,22	1,10	1,12	1,16
mar/07	1,18	1,33	1,32	1,30
abr/07	1,08	1,09	1,09	1,12
mai/07	1,17	1,13	1,15	1,15
jun/07	1,21	1,17	1,13	1,14
jul/07	1,23	1,23	1,26	1,27
ago/07	1,40	1,22	1,19	1,19

Fonte: Dados de Pesquisa

Já comparando o modelo GARCH com o modelo TARCH, o primeiro obteve melhor desempenho individual apenas em duas previsões (tabela 8).

³ Como ocorreram EPPI positivos e negativos, para obtenção de um indicador (EPPM) que permiti-se a comparação entre os modelos, elevou-se ao quadrado os EPPI de cada modelo e obteve-se a raiz quadrada da média desses valores.

Tabela 8: Resultados do poder de previsão dos preços dos modelos em termos de erro percentual de previsão individual e médio em porcentagem

MÊS/EPP	SARIMA	GARCH	TARCH
set/06	13,94	9,13	6,14
out/06	-16,09	-12,90	-9,19
nov/06	15,41	11,98	9,37
dez/06	-15,81	-13,18	-9,77
jan/07	14,25	11,74	9,58
fev/07	-10,44	-8,62	-5,61
mar/07	12,33	11,43	10,12
abr/07	0,57	0,76	3,22
mai/07	-2,95	-1,65	-1,60
jun/07	-3,01	-6,59	-6,17
jul/07	0,12	2,48	3,28
ago/07	-12,50	-14,79	-14,69
EPPM	11,47	9,92	8,21

Fonte: Dados de Pesquisa

Outra forma de verificação da potencialidade de previsão dos modelos é pela demonstração gráfica da tabela 7. Observa-se que todos os modelos utilizados para previsão possuem bom desempenho, como pode ser visto pela proximidade entre os preços reais observados no mercado e os preços previstos ao longo dos meses pelos modelos (figura 6).

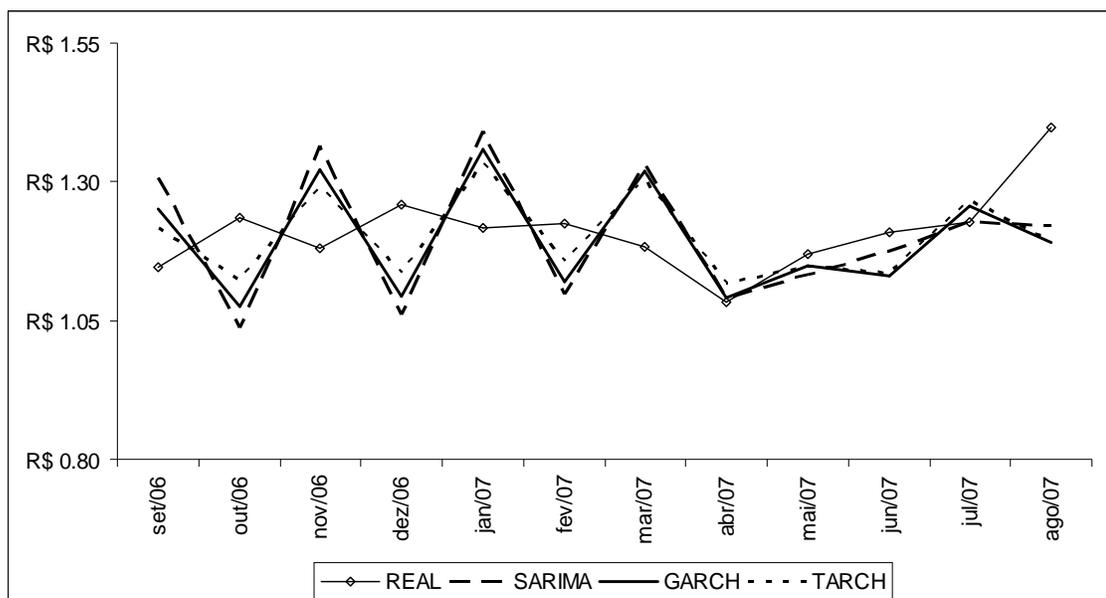


Figura 6: Preços previstos pelos modelos

Fonte: Dados de Pesquisa

5 CONCLUSÃO

Dada a necessidade de ferramentas eficientes para o apoio a tomada de decisão para o melhor planejamento da atividade agrícola, o presente artigo tem como objetivo analisar a viabilidade da utilização de modelos de séries temporais univariadas como instrumentos de apoio à tomada de decisão na produção e comercialização de suínos.

Os resultados evidenciam que os modelos utilizados são capazes de prever os preços do suíno com pequena margem de erro, não existindo diferença significativa entre os modelos, tendo os modelos TARCH e GARCH as melhores previsões individuais, com menores EPPI, e as melhores previsões médias (EPPM).

De uma forma geral, a eficácia dos modelos TARCH e GARCH devem a capacidade desses modelos modelarem a volatilidade da série de preços de forma a não manter a variância do erro constante ao longo do tempo, e ainda, no caso do modelo TARCH, incorporar uma variável *dummy* para estimação de componente assimétrico na série.

Já o modelo SARIMA foi capaz de modelar a componente sazonal na série, proporcionando boas previsões, mesmo tendo esse modelo a característica de manter a variância do erro da série constante.

Dessa forma, conclui-se que os modelos analisados podem ser utilizados como instrumentos mais seguros na tomada de decisão no curto prazo para os agentes, uma vez que os modelos são capazes de realizarem previsões mensais com pequena margem de erro. Assim, os agentes podem alocar melhor seus recursos, elevando suas margens de retorno e diminuindo os riscos da atividade.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ANUÁRIO DA AGRICULTURA BRASILEIRA (AGRIANUAL). CONSULTORIA E AGROINFORMSTIVOS (FNP). São Paulo: 2007. 520p.

BOLLERSLEV, T. Generalized Autoregressive Conditional Heteroskedasticity. **Journal of Econometrics**, v.31, p.307-327, 1986.

BOX, G. P.; JENKINS, G. M. **Time series analysis: forecasting and Control** .New York: Holden Day, p.575, 1976.

BRESSAN, A. A.; LIMA, J. E. **Modelos de previsão de preços aplicados aos contratos futuros de boi gordo na BM&F.** (Disponível em: <http://www.face.ufmg.br/novaeconomia/sumarios/v12n1/v12n1bressan.pdf> - Acesso em: 17 nov. 2005).

ENDERS, W. **Applied econometric time series.** New York: John Wiley, 1995. 433p.

ENGLE, R.F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of UK Inflation. **Econometrica** v.50, n.4, p.987–1008, 1982.

FARIAS, E. R., ROCHA, F. J. S., LIMA, R. C. **Critérios de seleção de modelos sazonais de série temporais: uma aplicação usando a taxa de desemprego da região metropolitana de Recife.** (Disponível em: <http://www.race.nuca.ie.ufrj.br/abet/3reg/39.DOC> - Acesso em: 15 nov. 2005).

FRANCISCHINI, R. **Uso de tecnologia da informação por produtores de café Associados à Cooperativa Regional de Cafeicultores em Guaxupé – Cooxupé.** 136 f. Dissertação (Mestrado em Economia Aplicada) - Universidade Federal de Viçosa, Viçosa, MG, 2001.

GUJARATI, D. N. **Econometria básica.** São Paulo: Makron books, 2000. 846 p.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA – IPEA. **Ipeadata – série histórica.** Disponível em: <http://www.ipeadata.gov.br>. Acesso em 03 nov. 2007.

NELSON, D. B. Conditional heteroskedasticity in asset return: a new approach. **Econometrica**, v. 59, n. 2, p. 347-370, 1991.

REZENDE, M. L. **O uso da informática na agropecuária: o caso dos suinocultores da zona da mata de Minas Gerais.** 97 f. Dissertação (Mestrado em Economia rural) - Universidade Federal de Viçosa, Viçosa, MG, 1998.

ROCHA, D. T. **Competitividade entre os sistemas integrado e independente de produção de suínos.** 108 f. Dissertação (Mestrado em Economia Aplicada). Universidade Federal de Viçosa, Viçosa, MG, 2006.

VALE, S. M. L. R. **Avaliação de sistema de informação para produtores rurais: metodologias e um estudo de caso.** 139 f. Tese (Doutorado em Economia Rural) - Universidade Federal de Viçosa, Viçosa, MG, 1995.

VALE, S. M. L. R., SILVA JÚNIOR, A. G., COSTA, F. A. ERU 430: **Administração rural.** Viçosa: Universidade Federal de Viçosa, 2002. 143 p. (Apostila).

ZAKOIAN, J. M. Threshold Heteroskedastic Models. **Journal of Economics Dynamics and Control**, 18, 931-944, 1994.