

Aplicações Financeiras de Modelos ARMA/ARIMA com erros GARCH: evidências heteroscedásticas na projeção de valores em risco em preços de camarão no Brasil

Israel José dos Santos Felipe¹
Anderson Luiz Rezende Mól²

Resumo

O presente trabalho visa determinar a perda máxima de investimento aceitável para um produtor de camarão cinza do calibre 100/120kg. Para isso, o estudo apresentou como método os modelos auto-regressivos com médias móveis (ARMA/ARIMA) e o modelo auto-regressivo de heteroscedasticidade condicional (GARCH). A pesquisa é exploratória com amostra probabilística intencional. A prospecção dos dados foi feita através do contato com a ABCC (Associação Brasileira dos Criadores de Camarão), onde foi cedida para este trabalho a cotação de preços semanais de 17 empresas do ramo da carcinicultura. Os resultados desta pesquisa apontaram que a um nível de significância estatística de 1%, o produtor de camarão admite uma perda da ordem de \$ 3,77 e a 5%, uma perda de \$ 2,87. Em geral, estes dados revelam que a cada 100g de camarão comercializado, o produtor de camarão pode perder em seu investimento até \$ 2,87. Esta informação servirá de parâmetro para a formação de preços das commoditys comercializadas e também para controle de redução de custos produtivos, uma vez que todo investimento requer uma remuneração sobre o capital investido, de ordem superior ao desprendimento financeiro inicial. Num futuro próximo, esta informação também poderá contribuir para a formação de um *hedge*, ou cadeia de produtores que se unem e assumem o risco do investimento, diminuindo assim o impacto do mesmo sobre um ou poucos produtores apenas. Apesar de ser uma atividade que já esteve no auge produtivo há algum tempo atrás, a carcinicultura, a medida do tempo remunera bem os produtores que ingressam neste ramo, já que mesmo em períodos de variações climáticas, doenças e outras patologias a larva inicial pode ser vendida prematuramente. Por fim, o VaR é uma ferramenta estatística poderosa na mensuração pontual de valores históricos dispostos em séries. No caso deste trabalho, o VaR histórico foi escolhido pela praticidade de cálculo do método e pela consideração do VaR pontual em cada intervalo de tempo, ou *lag*, da série. Espera-se que este trabalho sirva de base para posteriores estudos sobre volatilidade de preços e estudo de perdas máximas aceitáveis nesta e até mesmo em outras commoditys.

Palavras-chave: VaR, modelos ARMA, Diferenciação Inteira, Modelos GARCH.

Abstract

This study aims to determine the maximum loss acceptable investment for a producer of gray shrimp caliber 100/120 kg. For this, the study showed as method the autoregressive models with moving averages (ARMA / ARIMA) and a model autoregressive the heteroscedastic conditional (GARCH). The research is exploratory random sample intentional. The prospection of data was done through contact with the ABCC (Brazilian Association of Shrimp Farmers), where was given for this work the quotation of weekly prices of 17 companies of the shrimp breeding. The results of this research show that the level of statistical significance of 1% of shrimp producer admits a loss of about \$ 3.77 and 5%, a loss of \$ 2.87. In general, these data show that each 100g of commercialized shrimp, the shrimp producer can lose in its investment until \$ 2.87. this information will also serve of parameter for the formation of commercialized prices of commodities and for control of reduction of productive costs, a time that all investment requires a remuneration on the

¹Aluno do curso de MBA em Administração Financeira da Faculdade Natalense para o Desenvolvimento.

²Orientador da Faculdade Natalense para o Desenvolvimento.

invested capital, and superior order to the initial financial unfastening. In a next future, this information also will be able to contribute for the one formation hedge, or chain of products that together take the risk of the investment, thus diminishing the impact of the same on one or few products only. Although to be an activity that already was in the productive height it has some time behind, the carcinicultura, the measure of the time remunerates the products well that enter this branch, since exactly in periods of climatic variations, illnesses and other pathology the initial larva can be sold prematurely. Finally, the Var is powerful statistical tool in the measurement point to the historical arranged in series. For this work, the historical Var was chosen by practicality of the method of calculation and consideration of the Var point in each interval time, or lag, in the series. Is expect for this work that it will serve as an example to help further studies on price volatility, and study of this maximum loss acceptable and even in to other commodities.

Keywords: Var, Arma Models, Entire Differentiation, Garch Models.

1. INTRODUÇÃO

Nos últimos anos, a economia mundial vem exibindo um intenso processo de globalização financeira, produtiva e comercial dos mercados. Portanto, conhecer o quadro de informações teóricas e estruturais que moldam o panorama e projetam os cenários do mercado de agronegócios, é essencial para compreender a dimensão e a dinâmica dos negócios deste mercado tão evidente no âmbito internacional.

A carcinicultura brasileira destacou-se pela rápida expansão da produção e inserção no comércio internacional, com recorde de exportação em 2004, de quase trinta mil toneladas, correspondente a 116 milhões de dólares. Apesar de redução da taxa de crescimento das exportações, os volume e valores foram da mesma ordem nos dois anos seguintes.

De acordo com a Associação Brasileira de Criadores de Camarão(2002, p.3), o rápido crescimento mundial do cultivo do camarão marinho nas últimas duas décadas, notadamente nos países costeiros tropicais emergentes da Ásia e das Américas, teve e continua tendo por base de sustentação a crescente demanda do produto no mercado internacional, o atrativo nível de rentabilidade do agronegócio e a sua capacidade de gerar renda, emprego e divisas para o desenvolvimento dos países produtores.

Além da geração de divisas, a atividade é importante criadora de emprego e renda. Segundo Costa e Sampaio (2004), a cadeia produtiva de camarão cultivado no Brasil, constituída por laboratórios de pós larvas, fazendas de engorda e centros de processamento, gera 1,89 empregos diretos e 1,86 empregos indiretos por hectare de viveiro em produção, totalizando 3,75 empregos por hectare e superando a geração de empregos de atividades tradicionais na região, como a fruticultura irrigada.

Nesta perspectiva de crescimento e da importância de geração de emprego e renda, o estudo de riscos de preços do camarão permite que as empresas carcinicultoras mensurem seu nível de competitividade em relação a concorrência, onde o desempenho produtivo e gerencial permite a sobrevivência delas num mercado onde há diversas imposições às decisões estratégicas tomadas pelos empresários produtores. A participação das exportações de um dado setor no mercado internacional pertinente pode ser considerada um indicador adequado de competitividade internacional. Desse modo, a competitividade de um setor produtivo pode ser descrita como o resultado da competitividade individual dos agentes pertencentes ao setor.

O cenário atual, de acordo com Ramos et al. (2005), requer empresas competitivas, com políticas e estratégias de preços levando em consideração os negócios globais, exigindo planejamento e gerência adequados para operarem com os altos custos e riscos inerentes ao processo de comercialização nacional e internacional.

O risco relacionado aos investimentos financeiros é definido por Toscano Júnior (2002, p. 53), como a “possibilidade de se obter um retorno abaixo do esperado ou, em casos extremos, a perda do capital investido”. Solomon e Pringle (apud Securato, 1996, p. 27-28), conceituam risco como “o grau de incerteza a respeito de um evento”.

Diante das reações diferentes e posturas variadas em relação ao risco, as pessoas criam uma atmosfera fértil para a realização de negócios, associando-se riscos maiores a maiores probabilidades de retorno.

O gerenciamento do risco abrange as vertentes da possibilidade e da incerteza, onde a ideia geral dos fracassos e sucessos nos investimentos financeiros encontram-se. Dessa forma a mensuração do risco de um investimento, segundo Assaf Neto (2003), processa-se através de critérios probabilísticos. A probabilidade objetiva pode ser considerada como a definição de séries históricas de dados e informações, frequências relativas e experiências acumuladas no passado.

O risco é inerente e está presente em todos os meios, quer seja aplicações financeiras, investimentos em móveis, imóveis e etc. Portanto os valores esperados podem sofrer desvios em função de variáveis controláveis ou não pela empresa. Um importante fator que interfere no risco isolado de um projeto é o horizonte temporal. Quanto maior o período de projeção, mais numerosas serão as variáveis envolvidas, aumentando o risco dos valores previstos (GITMAN, 1978) (WESTON; BRIGHAM, 2000).

De acordo com Mól (2002), “o risco pode ser definido como a volatilidade de resultados inesperados, normalmente relacionados ao valor de ativos ou passivos de interesse”. Em específico, o risco de mercado, objeto de estudo deste trabalho, surge de

mudanças nos preços (ou volatilidades) de ativos e passivos financeiros, sendo mensurados pelas mudanças no valor das posições em aberto ou nos ganhos.

A aplicação de métodos estatísticos e, principalmente, os modelos econométricos de séries temporais na modelagem e previsão de riscos podem levar à determinação da volatilidade inerente à formulação de estratégias para vendas e comercialização de produtos.

Diante da necessidade de se conhecer o futuro e minimizar perdas ou prejuízos, os criadores de camarão precisam se munir de ferramentas estatísticas para aumentar suas margens de lucros no ato da comercialização da commodity, deste modo, o presente artigo irá investigar: **“Qual o *Value-at-Risk*, a um nível de significância estatística de 5%, para o mercado físico de camarão?”**

2. REFERENCIAL TEÓRICO

2.1 Value-at-Risk (VaR)

O VaR, segundo Jorion (1999), é um método de mensuração de risco que utiliza técnicas estatísticas padrões, comumente usadas em outras áreas técnicas. Ele apresenta uma predição da perda potencial de um portfólio, com determinado nível de confiança, com base em um período específico de tempo devido a movimentos de preços adversos dos ativos.

Em linguagem formal, o VaR mede a pior perda esperada (variabilidade) ao longo de determinado intervalo de tempo, sob condições normais de mercado e dentro de determinado nível de confiança. A diretriz de risco de um portfólio está associada ao fato de que seu retorno num dado intervalo de tempo não será conhecido antecipadamente. Ao contrário, existe um conjunto de retornos possíveis. As probabilidades de ocorrência de cada um dos elementos deste conjunto irão determinar, em última instância, o potencial de perda da carteira.

Os modelos de análise de risco são, grosso modo, um conjunto de técnicas que tem como o objetivo gerar este tipo de informação. Para Ju e Pearson (1998), o VaR está sendo empregado por gestores de riscos como uma importante ferramenta no processo de gerenciamento de risco. O interesse primário no VaR, porém, originou-se de suas aplicações potenciais como uma ferramenta de controle. Na esteira dos sérios desastres financeiros envolvendo comercialização de produtos derivativos, tal como o colapso do *Barrings Bank* (vide Jorion, 1999), agências de controle de risco tal como a *Securities and Exchange Commission*, empregam o VaR como uma medida transparente de risco de mercado. Ele é útil por informar riscos associados com portfólios de mercados sensíveis, tais como os derivativos.

Segundo Linsmeier e Pearson (1996), para computar o VaR (ou alguma outra medida de risco de mercado), é necessário identificar as taxas básicas e preços que afetam o valor do ativo. Estas taxas básicas de mercado e preço são os fatores de mercado que constarão no modelo.

Para a mensuração do VaR é necessária a escolha de dois fatores quantitativos: o horizonte temporal e o nível de confiança. Ambos são, de certa forma, arbitrários. Todavia, para Souza (1999), a escolha do nível de significância é relevante para a verificação do modelo. O nível de confiança escolhido não deve ser demasiadamente elevado, pois proporcionará uma medida de perda que raramente seria excedida.

Outro fator muito relevante na análise é a determinação da linearidade dos parâmetros. Conforme as características dos mesmos, de acordo com Mól (2002), haverá abordagens e metodologias específicas para apuração do VaR. Basicamente, as abordagens sobre VaR podem ser baseadas na avaliação pelo método analítico (delta-normal), aproximações delta-gama (letras gregas), por meio de métodos como, simulação histórica, modelos de variância condicional e simulação de monte carlo.

Para Mól (2002), o fator comum entre as metodologias é que necessitam de um horizonte para cálculo do risco, um nível de significância e dos preços e taxas relacionadas ao ativo. Além disso, a metodologia analítica requer a estimação da matriz de correlações e de volatilidades, assim como a decomposição e mapeamento de ativos/passivos para fatores de mercado previamente selecionados. Na metodologia da simulação histórica, os dados são diretamente usados como cenários para o cálculo do risco, ao passo que na simulação de Monte Carlo os cenários são gerados aleatoriamente (de acordo com uma família paramétrica previamente selecionada como representativa das variações dos fatores de mercado).

Na Tabela 3 é possível visualizar as características das diferentes metodologias no que se refere a determinadas variáveis.

TABELA 01 – Quadro comparativo das metodologias para cálculo do VaR

	Analítica	Simulação Histórica	Variância Condicional	Simulação Monte Carlo
Facilidade p/ implementação	Média	Média	Média	Difícil
Facilidade p/ assimilação	Média	Média	Média	Difícil
Complexidade computacional	Média	Média	Média	Muita
Tempo de execução	Médio	Médio	Média	Alto
Hipóteses simplificadoras	Muitas	Poucas	Poucas	Algumas
Carteiras com não-lineares	Péssimo	Ótimo	Ótimo	Ótimo
Stress testing	Péssimo	Ótima	Ótimo	Ótimo
Análise de sensibilidade	Péssimo	Regular	Ótimo	Ótimo
Modularização e portabilidade	Pouca	Média	Média	Pouca

Fonte: Adaptado do modelo original de Falkenstien, 1997.

Pode ser dizer até que não existe muita uniformidade no cálculo de riscos. Em comum, as metodologias para estimação de risco requerem conhecimentos sobre a dinâmica dos mercados de interesse, alguma sofisticação matemática, e sistemas computacionais e de informações confiáveis. No caso de risco de mercado, algumas metodologias já se encontram em uso e são explicadas na literatura de finanças. Este trabalho aborda o risco de mercado por meio do modelo *Value-at-Risk* utilizando os modelos de variância condicional. A real determinação do modelo virá com a operacionalização dos dados.

Conforme Jorion (1999, *apud* GALDI E PEREIRA, 2007), o VaR pode ser definido em uma posição comprada em um ativo S num horizonte de tempo j, com probabilidade p, sendo $0 < p < 1$:

$$p = P(\Delta P_j \leq VaR) = F_j(VaR) \quad (1)$$

onde P_j representa o ganho ou a perda da posição P , dada por $\Delta P_j = P_{t+j} - P_t$; $F_j(.)$ é a função de distribuição acumulada (F.D.A) da variável aleatória ΔP_j .

De acordo com Moretin (2004, p.179) estima-se este quantil a partir da distribuição empírica dos retornos. O VaR calculado em (1) tem valor negativo, pois quem tem uma posição comprada sofre perda se $\Delta P_j < 0$. A quantia em unidades monetárias no cálculo do VaR pode ser obtida pela multiplicação do valor da posição financeira com o VaR do retorno.

O VaR poderá ser simplificado, se for possível pressupor uma distribuição normal dos retornos contínuos (y_t), ou log-retornos, dos ativos que compõem a carteira. Para Moretin (*apud* GALDI E PEREIRA, 2007), com base nas estimativas dos parâmetros da distribuição, como o desvio-padrão dos retornos, pode-se determinar a perda esperada carteira da seguinte maneira:

$$p = \int_{-\infty}^{y^*} f(y) dy, f(y) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(y^* - \mu)^2}{2\sigma^2}} \quad (2)$$

onde: y^* é valor de retorno crítico para o cálculo do VaR para o horizonte temporal j. De acordo ainda com os autores, deve-se tomar cuidado na conversão do log-retorno do VaR em uma variação percentual discreta i , do seguinte modo:

$$i = e^{y^*} - 1 \quad (3)$$

O *Value-at-Risk* absoluto sugerido pelo Riskmetrics, citado por Longerstaey e More (*apud* GALDI E PEREIRA, 2007), parte da premissa que a distribuição condicional dos retornos é normal e possui média zero e variância:

$$\sigma_{t+1}^2, \text{ sendo } y_{t+j} | I_t \sim N(0, (j-t)\sigma_{t+1}^2), \text{ onde } \sigma_{t+j}^2 = (j-t)\sigma_{t+1}^2 \quad (4)$$

Para a execução do cálculo do VaR é necessária uma estimativa da volatilidade dos log-retornos do ativo um posterior horizonte de análise. Este trabalho fará menção a quatro abordagens distintas de estimativa de volatilidade para o cálculo do VaR, onde serão pontuadas principais peculiaridades de cada uma delas.

2.1.2 Metodologias utilizadas para o cômputo do VaR (*Value-at-Risk*)

2.1.2.1 Método Analítico (*Delta Normal*)

O VaR de uma carteira de investimento, pode ser definido como um valor estipulado da depreciação de determinada carteira num horizonte temporal. Uma definição mais formal (do ponto de vista probabilístico) do VaR é: se X_{Δ_t} é uma variável aleatória usada para sinalizar o ganho/perda de uma carteira de investimentos em um período de tempo Δ_t , e λ é um nível de significância escolhido (com $0 < \lambda < 0,5$), então o valor da solução ξ para a equação $\Pr \{X_{\Delta_t} \leq \xi\} = \lambda$ é o valor sob a óptica da análise.

A abordagem do Delta Normal é considerada como uma das mais simples, pois ela supõe que os retornos dos ativos sejam distribuídos normalmente e que, para posições em derivativos, seja possível encontrar uma posição equivalente no ativo subjacente por meio de uma linearização da função que liga seu preço ao preço do ativo objeto. Com a hipótese de normalidade, pode-se caracterizar a distribuição dos retornos dos ativos com apenas dois elementos, sua média e seu desvio padrão. Neste caso, o VaR de um portfólio de um único ativo cujos retornos (y) apresentam média 0 e Variância σ^2 ,

$y \sim N(0, \sigma^2)$ é dado por:

$$\text{VaR} = V_C \cdot \sigma \cdot P \quad (5)$$

em que, P é o valor de mercado do portfólio e V_C o valor crítico da normal, a um dado nível de significância. Partindo-se da fórmula apresentada acima, calcula-se o VaR para qualquer período de interesse apenas incluindo o tempo na equação proposta por Bollerslev (1986), onde ele mostrou de forma parcimoniosa a dependência temporal da variância condicional. Deste modo teríamos:

$$\sigma^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (6)$$

$$\text{VaR} = V_C \cdot \sigma \cdot P$$

(7)

Para Mól (2002) alguns dos benefícios da metodologia delta-normal são: a mensuração do risco; a sua facilidade de implementação e rapidez com a qual os resultados são obtidos, permitindo um cálculo instantâneo do VaR, até mesmo para portfólios maiores.

Este quesito, para Mollica (1999), não deve ser menosprezado, pois a agilidade na tomada de decisões é um componente essencial nos mercados atuais.

Ainda de acordo com Mollica (1999), outra facilidade obtida com a hipótese de normalidade é a fácil extensão do cálculo do VaR para uma carteira com várias ativos. Da teoria de probabilidade sabe-se que a distribuição marginal de um conjunto de variáveis aleatórias:

$$Y = (y_1, y_2, \dots, y_n)$$

é a normal com médias:

$$\mu = (\mu_1, \mu_2, \dots, \mu_n)$$

e matriz de variâncias e covariâncias:

$$\Sigma = \begin{bmatrix} \sigma_{11} & \cdots & \sigma_{1n} \\ \vdots & \ddots & \vdots \\ \sigma_{n1} & \cdots & \sigma_{nn} \end{bmatrix}$$

então a variável aleatória:

$$Y = w_1 \cdot y_1 + w_2 \cdot y_2 + \dots + w_n \cdot y_n$$

Também é normalmente distribuída com média:

$$M = w_1 \cdot \mu_1 + w_2 \cdot \mu_2 + \dots + w_n \cdot \mu_n = w' \mu \quad (8)$$

e variância:

$$V = \sum_i \sum_j w_i w_j \sigma_{ij} = w' \Sigma w, \quad (9)$$

onde Σ é a matriz de covariância da variável aleatória Y .

A expressão para o retorno de um portfólio de n ativos com participações relativas $w_1, w_2, \dots, w_n$ é idêntica a expressão Y acima. Logo assumindo média zero, a distribuição dos retornos deste portfólio é:

$$Y \sim N(0, w' \Sigma w)$$

Com tudo isso, o VaR deste portfólio é dado por:

$$\text{VaR} = V_c ((w' \Sigma w)^{1/2} P \quad (10)$$

onde P é o valor de mercado da carteira.

Em contrapartida, esta metodologia por não considerar algumas características importantes das séries financeiras, pode causar um certo tipo de imprecisão na execução do cálculo do risco de um portfólio qualquer.

No geral, uma característica existente na grande maioria das séries de retornos é a presença de excesso de curtose em relação à distribuição normal. Ou seja, a probabilidade de ocorrência de eventos extremos neste tipo de série tende a ser superior a uma série que tenha

distribuição normal. Deste modo, quando se assume normalidade para o cálculo do VaR, não é dado o devido apreço ao risco.

2.1.2.2 Método da Hipótese de Volatilidade Condicional (HVC)

A abordagem inicial é creditada a Bollerslev (1992), e vem sendo desenvolvida desde o início dos anos 1980, com inúmeras aplicações para séries financeiras e uma grande quantidade de extensões. De acordo com Mól (2002), o sucesso dessa classe de modelos se deve, em grande parte, ao fato de tratar diretamente duas das principais características recorrentemente observadas em dados financeiros: caudas pesadas e dependência temporal.

Este método é utilizado todas as vezes que a hipótese de normalidade não condicional não é validada, desta maneira uma possibilidade-resposta ao problema levantado, é modelagem da distribuição condicional dos retornos.

Para o cálculo do VaR, o que em geral se faz é estimar um modelo adequado da família ARCH (*Autoregressive Conditional Heteroskedasticity*) para prever a volatilidade condicional σ_{t-1}^2 . A partir daí, constrói-se o intervalo de confiança baseado na distribuição condicional dos retornos. A modelagem da volatilidade condicional ultrapassa vários dos problemas apontados nas abordagens anteriores, dando ênfase às observações mais recentes.

Porém, este modelo, necessita de hipóteses, tanto sobre a distribuição condicional dos retornos, em geral assumida como normal, como sobre a especificação dinâmica seguida pela Variância. Logo a seguir serão citadas, as especificações mais tradicionais identificadas em séries financeiras.

2.1.3 Método SMC (Simulação Monte Carlo)

Hammersley e Handscomb (1964, p. 3), definem o Método de Monte Carlo como sendo a parte da matemática experimental que está preocupada em experiências com números aleatórios. O Método de Monte Carlo é uma expressão muito geral, onde as formas de investigação estão baseadas no uso de números fortuitos e estatística de probabilidade.

Esse método consiste na substituição do estudo de um processo físico ou matemático por um modelo probabilístico que possa tratar problemas determinísticos por meio de amostras aleatórias ou por meio de números pseudo-aleatórios gerados por um computador (ESCUADERO, 1973).

Para resolver um problema através desse método, são utilizadas séries de tentativas aleatórias. A precisão do resultado final depende, em geral, do número de tentativas. O

equilíbrio entre a precisão do resultado e o tempo de computação é uma característica útil dos métodos de Monte Carlo (ESCUDERO, 1973).

Para executar o Método de Monte Carlo, existem algumas fases básicas que devem ser seguidas: definição das variáveis envolvidas com base em dados passados ou em estimativas subjetivas dos administradores; identificação das distribuições de probabilidades das variáveis aleatórias relevantes para o estudo; construção das distribuições de probabilidades acumuladas para cada uma das variáveis definidas; definição dos intervalos dos números aleatórios para cada variável; geração dos números aleatórios; e simulação dos experimentos (LUSTOSA; PONTE; DOMINAS, 2004).

Ressalta-se que as populações analisadas devem ter certos parâmetros, como média e desvio padrão, e podem apresentar vários comportamentos como Normal, Exponencial e Uniforme. As amostras obtidas devem ser aleatórias. Para isso, é preciso obter uma sequência de números aleatórios. Computacionalmente, esta sequência é facilmente obtida, utilizando um gerador de números aleatórios. Os números gerados são pseudo-aleatórios, mas, geralmente, são suficientes para obter aproximações razoáveis de números aleatórios inteiros e podem ser utilizados para obter amostras aleatórias de alguma população de interesse.

A distribuição de frequência estatística de interesse é frequentemente chamada de distribuição aleatória empírica, e pode ser comparada com a distribuição aleatória teórica apropriada. Para isso, é preciso confrontar o comportamento da distribuição aleatória empírica com a distribuição aleatória teórica da estatística (BARROS; MAZUCHELI, 2005).

2.1.4 Método de Simulação Histórica (HS)

Conforme Mollica (1999), o método de simulação histórica é uma abordagem mais direta e intuitiva para o cálculo do *Value-at-Risk* de uma carteira de ativos. A técnica consiste em aplicar os pesos atuais de cada ativo na carteira às respectivas séries históricas dos retornos destes ativos para obter uma série histórica dos retornos da carteira.

Numa carteira de n ativos, sendo r_{it} o retorno do i -ésimo ativo no instante t e w_i o peso atual deste ativo, então, a série histórica dos retornos da carteira para a qual se deseja calcular o VaR seria dada por:

$$Y = \sum_{i=1}^n w_i r_{it}, \text{ com } t = 1, \dots, T. \quad (11)$$

em que, T é o número de observações na série histórica dos retornos. Em seguida, constrói-se a distribuição empírica destes retornos, da qual se obtém o VaR no nível de significância desejado, achando o percentil equivalente. Este método tem uma série de atrativos. Em primeiro lugar, trata-se de uma técnica não paramétrica o que implica dizer que

não é necessária a estimação de nenhum parâmetro, como volatilidades e correlações, para obtenção do VaR. Com isso, evitam-se problemas de modelagem e erros de estimações destes parâmetros.

De acordo com Mól (2002, p. 35), outra vantagem do método HS é que ele dispensa qualquer hipótese a priori sobre a distribuição dos retornos dos ativos. Em tese, sendo possível captar, implicitamente, características específicas a cada série como, por exemplo, excesso de curtose e assimetrias das distribuições que, como mencionado, são negligenciadas pelo modelo delta-normal. Além disso, como o retorno da commodity está sendo calculado em cada instante do tempo, também consideram-se de forma implícita os efeitos de não linearidades, tais como o risco Gama. Por último, os recursos computacionais atualmente disponíveis tornam extremamente simples sua implementação.

Importante ressaltar de acordo com Mollica (1999), que o método apresenta também algumas limitações. A hipótese que está implícita neste modelo é que a distribuição empírica dos retornos é capaz de refletir a verdadeira distribuição dos retornos. Desta maneira, o VaR estimado é sensível à janela utilizada para a construção da distribuição empírica do portfólio e a inclusão ou não de períodos em que ocorreram grandes outliers ou de longos períodos de pouca oscilação nos retornos produz grandes diferenças nos resultados. Este efeito é mais pronunciado quando o objetivo é estimar o VaR para níveis de significância muito baixos (menores que 1%).

Outro percalço é a falta de adaptabilidade das estimativas, ou seja, incapacidade de perceber rapidamente mudanças estruturais no ambiente financeiro, como mudanças de regimes cambiais ou aumento de instabilidade decorrente da desregulamentação de um determinado mercado. Isto acontece por que o método aplica pesos idênticos a todas observações da série histórica.

Assim, eventos ocorridos num passado distante continuam tendo o mesmo peso nas estimativas que os eventos mais recentes. Este fato é pouco intuitivo, uma vez que as expectativas dos agentes econômicos atuantes no mercado financeiro tendem a ser muito mais influenciadas pelo ambiente atual. Por último, fato notado por Danielsson e Vries (1997), o método de simulação histórica é bastante eficaz para estimação da distribuição dos retornos num intervalo concentrado ao redor da média, região na qual a distribuição empírica tende a ser bastante densa. No entanto, devido à característica discreta dos retornos extremos, o método produz uma estimativa bastante pobre das caudas, região de interesse para o cálculo do VaR, o que tende a gerar alta Variabilidade nas estimativas do VaR.

É tarefa árdua e difícil chegar a uma conclusão definitiva sobre a robustez do método. Sua eficiência acaba se faz uma questão empírica. De acordo com Mól et al. (2002), os resultados encontrados na literatura de *Value-at-Risk* são controversos. Trabalhos como os de Danielsson e Vries (1997) e Kupiec (1995) chegam a resultados que apontam para uma inferioridade do método em relação a outros como o delta-normal e o VaR de valores extremos. Já, artigos como os de Mahoney (1996) e Jackson et al. (1997) indicam superioridade da técnica de HS.

2.2 Séries Temporais: modelos ARIMA/GARCH com Diferenciações Inteira

Ultimamente tem crescido o interesse pela utilização de modelos não lineares de séries de tempo financeiras e econômicas (ver Granger, 1998; Thavaneswaran et al., 2005a). Muitas destas séries tais como retornos de ações e taxas de juros, exibem leptocurtose e volatilidade na variância. Estes dois fatores tem sido alvo de extensivo estudo desde Nicholls e Quinn (1982), Engle (1982), Engle e González-Rivera (1991). Modelos de coeficientes auto-regressivos estocásticos - RCA - (Nicholls e Quinn, 1982), o Modelo auto-regressivo condicional heterocedástico (ARCH), Engle (1982) e Engle e Gonzáles-Rivera (1991) e suas generalizações, os modelos GARCH, Bollerslev (1986), EGARCH de Nelson (1991) e TARCH de Zakoian (1994) propõem uma conveniente estrutura para estudo de volatilidade estocástica em mercados financeiros. Os modelos de séries de tempo financeiras apresentam um típico exemplo de aplicação dos modelos da família ARCH-GARCH (mais conhecido por GARCH).

De acordo com Easton e McColl (1997), uma série temporal é uma sequência de observações que são ordenadas no tempo ou no espaço. Mesmo parecendo muito simples a definição destes autores, o conceito abrange e transmite o essencial para entendimento do assunto. Partindo do princípio que o universo não é estacionário, muitas variáveis alteram os seus valores através do tempo. Essa variação é transmitida através de uma série temporal onde graficamente a conhecemos pela interpolação dos eixos das abscissas, que representam o tempo, e das ordenadas, que por sua vez, representam a variação do que se representa.

Anderson e Hendry (1971), relataram que a natureza de uma série temporal e a estrutura de seu mecanismo gerador estão relacionadas com o intervalo de ocorrência das observações no tempo. Caso o levantamento das observações da série possa ser feito a qualquer momento do tempo, a série temporal é dita contínua, sendo denotada por $X^{(t)}$ (GRANGER, 1977). Entretanto, de acordo com Granger (1977) e Nelson (1973), na maioria das séries, as observações são tomadas em intervalos de tempo discretos e equidistantes.

A série temporal discreta pode ser representada por $X^T = \{x_1, x_2, x_3, x_T, \dots\}$ sendo que cada observação discreta X_T está associada a um instante de tempo distinto, existindo uma relação de dependência serial entre essas observações (SOUZA, 1989).

De acordo com o mesmo autor a série temporal é uma classe de fenômenos cujo processo observacional e conseqüente quantificação numérica gera uma seqüência de dados distribuídos no tempo.

Quando se estuda séries temporais é importante identificar as suas tendências (crescimento ou decrescimento); os ciclos (padrões ou não); estações (espaço de um ano); as irregularidades (normais ou anomalia) e as relações (se existem ou não).

A análise séries temporais consiste na aplicação de modelos matemáticos e estatísticos nos dados das mesmas, com o objetivo de quantificar e compreender a incidência do fenômeno da variação temporal. Esta técnica é utilizada para analisar o passado, tentando retirar conhecimento útil do mesmo e prever o futuro, por meio da análise dos dados elaborar um modelo que permita antever uma evolução futura da série temporal.

Empiricamente, existe uma pressuposição aplicada aos modelos de séries financeiras GARCH, onde os retornos apresentam-se, condicionalmente em distribuições normais. Reportamos a estes casos, em específico, como modelos GARCH normais ($GARCH \sim N$), que são mais conhecidos por modelos de tratamento de conglomerado de volatilidades tipicamente exibidas em séries financeiras e econômicas. Entretanto, a curtose considerada em modelos GARCH gaussianos ($GARCH \sim N$) tende a ser consideravelmente menor do que a curtose observada na maioria das séries de retorno.

No geral, existe uma alta persistência na volatilidade das séries de retornos. Isso faz com que o valor de q no modelo ARCH seja elevado, implicando a necessidade de estimação de um grande número de parâmetros. O modelo GARCH, proposto por Bollerslev (apud MÓL, 2002, p.25), constitui uma tentativa de expressar, de forma mais parcimoniosa, a dependência temporal da variância condicional. Nesse modelo a variância condicional além de depender do quadrado dos retornos passados como no modelo ARCH, depende também dos passados das próprias variâncias condicionais como mostrado na equação (19).

De acordo com Castro e Romaniello (apud MÓL, 2002) a variância condicional é sistematizada por:

$$\alpha_t^2 = \alpha_0 + \sum_{i=1}^n \alpha \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta \sigma_{t-j}^2 \quad (12)$$

O modelo acima é denominado GARCH (p,q) (“*Generalized Autoregressive Conditional Heteroskedasticity*”) em que q representa a ordem do componente ARCH e p a ordem do componente GARCH. Neste sentido, o modelo GARCH (p,q) descreve a

volatilidade (variância condicional) de uma série de retornos como dependendo de uma constante, de informações defasadas da volatilidade (os termos ε_{t-l^2}) e de variâncias previstas passadas (os termos $\sigma^2_{\tau-\varphi}$). De acordo com Swaray (2002), a inclusão de variâncias condicionais defasadas pode capturar a “aprendizagem adaptativa” que caracteriza o processo.

A grande vantagem desta especificação é que ela contém poucas restrições nos parâmetros adotados. As condições da variância do processo para a positividade e fraqueza estacionária são: $\alpha_0, \alpha_1 > 0$; $\beta_1 > 0$ e $\alpha_1 + \beta_1 < 0$. A persistência de choques na volatilidade da série de retornos gerada por uma commodity é medida pela soma de α_1 e β_1 . Quanto mais próxima de um for o somatório dos coeficientes, maior será o efeito daquela informação (choque) no decorrer do tempo, levando assim mais dias para dissipar-se totalmente.

Uma apresentação didática dos modelos GARCH e de outros modelos mais simples, para tratamento da variância condicional, é apresentada por Engle (2001). Andersen et al. (2003) examinou aprimoramentos existentes para essa classe de modelos, considerando generalizações multivariadas, métodos alternativos de estimação e outros casos de interesse. A combinação dos modelos ARIMA e GARCH é uma dessas possibilidades que dá acesso a um amplo espectro de modelos para representação do comportamento de séries de preços.

Este estudo irá investigar as propriedades estatísticas da série de preços de camarão cinza. A série utilizada corresponde a preços semanais de camarão, negociados para exportação. Alguns autores, como Taylor (1986) sugere a possibilidade de ocorrência de autocorrelação da volatilidade e heteroscedasticidade da maioria das séries financeiras. Deste modo, é necessário realizar testes estatísticos para examinar a ocorrência de heteroscedasticidade condicional e modelar os termos aleatórios com uma estrutura da família ARCH/GARCH.

3. ESTRATÉGIA EMPÍRICA

3.1 Caracterização da Pesquisa, População e Amostra

Este trabalho apresenta-se como uma pesquisa exploratória de natureza aplicada com abordagem quantitativa, técnicas estatísticas (desvio-padrão e variância) e procedimentos técnicos bibliográficos.

A amostra da presente pesquisa são 17 empresas do ramo da carcinicultura, associadas à ABCC (Associação Brasileira de Criadores de Camarão).

3.2 Base de Dados

Para o presente trabalho foram utilizadas séries de preços de camarão tipo *Litopenaeus Vannamei* (calibre 100/120kg - que significa que uma embalagem de 1Kg de camarões nesta classificação contém 100 a 120 peças de camarões inteiros) por configurarem como os ativos mais líquidos do ponto de vista das exportações do pescado. Os dados correspondem à média de preços pagos aos produtores de camarão, no Brasil. A série compreende os preços médios semanais de janeiro de 2004 a janeiro de 2008.

3.3 Modelo ARIMA (p,d,q)

A metodologia de Box-Jenkins (1976) estima modelos de séries temporais da forma:

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad (13)$$

Nesta equação o termo α_0 representa uma constante no modelo estimado, α_1 até α_p são parâmetros que ajustam os valores passados de y_t do instante imediatamente anterior até o mais distante representado por p . Os valores de ε representam uma seqüência de choques aleatórios e independentes uns dos outros, ε_t é uma porção não-controlável do modelo é chamado comumente de ruído branco. Os parâmetros β_1 até β_q possibilitam escrever a série em função dos choques passados. No geral cada ε_t é considerado como tendo distribuição normal, média zero, variância constante e não-correlação. Em termos estatísticos, considerando-se que $E[x]$ denota a média teórica do valor de x , a seqüência ε_t é considerada um processo ruído branco se para cada período de tempo t tivermos: (i) $E[\varepsilon_t] = E[\varepsilon_{t-1}] = \dots = 0$, Média zero; (ii) $E[\varepsilon_t^2] = E[\varepsilon_{t-1}^2] = \dots = \sigma^2$, variância constante; (iii) $E[\varepsilon_t \cdot \varepsilon_{t-s}] = E[\varepsilon_{t-j} \cdot \varepsilon_{t-j-s}] = \dots = 0$, covariância nula para todo valor de s .

A equação (1) representa um modelo denominado como Auto-regressivo integrado de média móvel, ou simplesmente ARIMA. Sua equação pode ser escrita também no seguinte formato: $y_t = \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \sum_{i=0}^q \beta_i \varepsilon_{t-i}$, sendo $\beta_0 = 1$. O termo modelo auto-regressivo é utilizado quando se pode escrever uma série temporal na forma $y_t = \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \varepsilon_t$, ou seja, a série y_t é escrita a partir dos seus valores passados. Transcrevendo a série em termos de choques aleatórios tem-se o modelo de média móvel, ou seja, $y_t = \sum_{i=0}^q \beta_i \varepsilon_{t-i}$, onde $\beta_0 = 1$.

Se considerarmos a série, $y_t = \alpha_0 + \alpha_1 y_{t-1} + \varepsilon_t$, quando $\alpha_0 = 0$ e $\alpha_1 = 1$, o modelo será conhecido como passeio aleatório ou random walk, uma das características desse modelo é violar a condição de estacionariedade.

Um modelo é estacionário se para todo t e $t-s$ tivermos: (i) $E[y_t] = E[y_{t-s}] = \mu$, média constante; (ii) $E[(y_t - \mu)^2] = E[(y_{t-s} - \mu)^2] = \sigma_y^2$, variância constante; (iii) $E[(y_t - \mu)(y_{t-s} - \mu)] = E[(y_{t-s} - \mu)(y_{t-j-s} - \mu)] = \gamma_s$, covariância constante.

Na maioria das vezes para transformar uma série estacionária precisa-se utilizar um recurso chamado de diferenciação, através do uso do operador Δ , sendo que $\Delta_j^d = (1 - L^j)^d$ e $L^j y_t \equiv y_{t-j}$. Quando y_t é uma série temporal $I(d)$ e depois de diferenciar d vezes ela pode ser modelada usando um modelo $AR(p)$, este modelo para y_t pode ser escrito como (Franses, 1998):

$$\Delta_1^d y_t - \phi_1 \Delta_1^d y_{t-1} - \dots - \phi_p \Delta_1^d y_{t-p} = \varepsilon_t, \quad t=p+d, p+d+1, \dots, n. \quad (14)$$

O modelo representado por (2) normalmente é abreviado por $AR(p,d)$, ou seja, Auto-regressivo de ordem p e integrado de ordem d . Quando uma série temporal apresenta uma tendência provavelmente ela poderá ser representada por um modelo integrado AR , $ARMA$ ou MA .

Vale a pena destacar que os modelos $ARMA$ não apresentam especificidade gráfica, somente plotando a série temporal não é possível identificar qual o modelo que a representa.

De acordo com Yim (2001), a sequência para a determinação do modelo da família $ARIMA$ que melhor representa a série que poderá ser utilizado para fazer as previsões é:




Figura 3 – Modelo para fazer previsões. Adaptado de Yim 2001.

Os modelos de séries temporais do tipo Auto-regressivo Integrado de Média Móvel, $ARMA(p,d,q)$, são utilizados para realizar previsões de séries homogêneas nos casos em que se supõem um grau de diferenciação inteira, de acordo com a seguinte formulação: $\phi(L)(1 - L)^d(y_t - \mu) = \Theta(L)\varepsilon_t$, $\varepsilon_t \sim i. i. d. (0; \sigma_\varepsilon^2)$ (3) onde y_t é a série temporal, μ é a média da série ε_t é o termo aleatório, $\Phi(L) = (1 - \phi_1 L - \dots - \phi_p L^p)$. As raízes da equação característica $\phi(L)$ estão sobre ou fora do círculo unitário. Se todas as raízes de $\phi(L)$ estiverem fora do círculo unitário, ou seja, $d = 0$, o modelo $ARIMA(p,d,q)$ passa a ser um $ARMA(p,q)$. Caso contrário, $\phi(L)$ tem d raízes fora do círculo unitário. Empiricamente,

assume-se que o nível de integração d nos modelos do tipo Auto-regressivo Integrado de Média Móvel é igual a 1 ou 2 (PINDYCK e RUBINFELD, 1981).

3.3.1 Processo de Estimação dos modelos ARMA/ARIMA

A construção dos modelos do tipo ARMA/ARIMA requer o conhecimento prévio da ocorrência de raízes unitárias no processo estocástico. Portanto, deve-se primeiro realizar um teste estatístico para examinar a estacionariedade da série. O teste recomendado é o Dickey-Fuller Aumentado (ADF) e Philip-Peron (PP), que pode ser representado como segue:

$$\Delta y_t = a_0 + \gamma y_{t-1} + a_2 t + \sum_{i=2}^p \beta_i \Delta y_{t-i+1} + \varepsilon_t \quad (15)$$

onde a , γ e β são parâmetros, e t é a tendência. A escolha do modelo de melhor ajuste para a realização do teste ADF baseia-se em testes de hipótese para a_0 , a_2 , e β_i . O teste de raiz unitária é realizado no parâmetro γ e tem a seguinte regra de decisão:

H_0 : não-estacionariedade;

H_1 : estacionariedade.

A distribuição do teste ADF é a τ , construída através de experimento de Monte Carlo realizado por Dickey e Fuller (Enders, 1995). O teste ADF é usado para definir o nível de diferenciação inteira (d) do modelo de séries temporais. Se $d = 0$ o modelo será estimado como um ARMA(p, q). Se a série for não-estacionária homogênea (d igual a 1 ou 2), então o modelo será estimado como um ARIMA(p, d, q).

O passo seguinte será a identificação do modelo. Ou seja, definir qual a memória auto-regressiva (p) e de média móvel (q) do modelo. Na prática, selecionam-se os modelos de melhor ajuste usando-se estatísticas como o Critério de Informação de Akaike (AIC), Critério Bayesiano de Schwartz (SBC) e Máximo da Log-verossimilhança Max [Log L]. Ao fim, tem-se que quanto menor o valor de AIC, SBC e Max [Log L], melhor o ajuste do modelo.

3.4 Modelagem da Volatilidade do Erro

As séries financeiras assim como as demais séries de retorno e econômicas são, em sua grande maioria, não estacionárias. Ainda, as séries financeiras não-estacionárias assemelham-se a um caminho aleatório (*random walk*), o que sugere alto grau de persistência a choques e uma volatilidade não condicional variante no tempo. Tais efeitos podem ser atribuídos às características de heteroscedasticidade.

No caso de não ser válida a hipótese de normalidade não condicional, uma possibilidade é modelar a distribuição condicional dos retornos. A abordagem inicial se deve a Bollerslev e Wooldridge (1992). Este procedimento vem sendo desenvolvido desde o início dos anos 1980 com inúmeras aplicações para séries financeiras em uma grande quantidade de extensões. O sucesso dessa classe de modelos se deve, em grande parte, ao fato de tratar diretamente três das principais características (fatos estilizados) recorrentemente observadas em dados financeiros: caudas pesadas, dependência temporal e conglomerados de volatilidades.

Neste sentido, uma classe de modelos instrumentais foi introduzida por Engle (1982), o “*Autoregressive Conditional Heteroskedasticity*” (ARCH). O modelo ARCH expressa a variância condicional como uma defasagem distribuída do quadrado dos retornos passados.

Em geral existe uma alta persistência na volatilidade das séries em diferenças. Isso faz com que a dimensionalidade do modelo ARCH seja elevada, implicando a necessidade de estimação de um grande número de parâmetros.

O modelo generalizado da família ARCH (GARCH – Generalized ARCH), proposto por Bollerslev (1986), constitui uma tentativa de expressar, de forma mais parcimoniosa, a dependência temporal da variância condicional. Neste sentido, o modelo é descrito por:

$$\varepsilon_t/\psi_{t-1} \sim N(0, h_t) \quad (16)$$

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} = \alpha_0 + A(L)\varepsilon_t^2 + B(L)h_t \quad (17)$$

$$\varepsilon_t = R_t - x_t b$$

onde as restrições são dadas por: $q > 0$, $p \geq 0$, $\alpha_0 \geq 0$, $\alpha_i \geq 0$, ($i=1, \dots, q$) e $\beta^i \geq 0$, ($i=1, \dots, p$). Se $p=0$ o modelo se reduz a um ARCH (q) e, então ε_t é um ruído branco. Para que o processo seja bem definido, é requerido também que $h = \frac{\alpha(L)\varepsilon_t^2}{1-\beta(L)}$, seja não negativo e que as raízes do polinômio $\beta(\lambda) = 1$ estejam fora do círculo unitário.

Nesse sentido, o modelo GARCH (p, q) descreve a volatilidade (variância condicional) de uma série de retornos dependente de uma constante de informações defasadas da volatilidade (os termos ε_{t-i}^2) e de variâncias previstas passadas (os termos h_{t-i}). De acordo com Swaray (2002), a inclusão de variâncias condicionais defasadas pode capturar a “aprendizagem adaptativa” que caracteriza o processo.

Engle (1982), afirma que a especificação mais robusta verificada nas aplicações financeiras é a do modelo GARCH (1,1). Nesse modelo, a variância condicional além de

dependem do quadrado dos preços em diferença passados como no modelo ARCH, depende também do passado das próprias variâncias condicionais.

Caso os parâmetros $\alpha_1 + \beta_1 = 1$ pode-se dizer, então, que existe persistência dos choques de informação na volatilidade dos retornos de maneira que se passa a ter um modelo GARCH integrado ou IGARCH.

A especificação dos modelos é frequentemente interpretada dentro de um contexto econômico, onde um agente exportador prevê a variância do período pela formulação de um termo médio de longo prazo (a constante), a previsão de variância dos últimos períodos (termo GARCH), e a informação sobre a volatilidade nos últimos períodos (ARCH). Se o preço em diferença do ativo tiver expectativa de grandes variações, tanto para cima, como para baixo, então o produtor irá aumentar sua estimativa de variância para o próximo período. Seja um modelo ARCH, pode-se testar a hipótese de que a variância dos erros é constante $\sigma^2 = \alpha_0$, contra a hipótese alternativa de erros seguindo um processo ARCH, de ordem a determinar. Segue, portanto, as hipóteses:

$$H_0: \alpha_0 = \alpha_1 = \dots = \alpha_q = 0$$

$$H_1: \alpha_i \neq 0, \text{ para pelo menos algum } i = 1, \dots, q$$

O teste é fundamentado pelo procedimento clássico de Fisher, ou pelo teste do multiplicador de Lagrange (LM). Neste trabalho optou-se pela formalização do teste de LM.

Uma observação importante foi feita por Bourbonnais e Terraza (1998) é que um processo ARCH só é justificado até a ordem $q = 3$, a partir da ordem 3 usam-se os modelos da família GARCH, que apresentam resultados pelo menos tão bons quanto, porém mais parcimoniosos.

Supondo-se que o modelo em análise seja um caso de heteroscedasticidade condicional, pode-se testar a especificação ARCH contra o GARCH. A hipótese nula é que os erros são do tipo ARCH, já a hipótese alternativa é que os erros são GARCH.

$$H_0: \delta_0 = \delta_1 = \dots = \delta_p = 0$$

$$H_1: \delta_i \neq 0, \text{ para pelo menos algum } i = 1, \dots, p$$

O teste é realizado segundo a metodologia do Q-teste de Ljung-Box (ENDERS, 1995).

3.5 Teste da Raiz Unitária (Estacionaridade)

3.5.1 Teste Dickey-Fuller

O teste de Dickey-Fuller (ADF) é implementado pela realização da estimação da seguinte equação por mínimos quadrados ordinários (MQO):

$$Y_t = \rho Y_{t-1} + \varepsilon_t \quad (18)$$

no qual:

$$\begin{aligned} H_0 &= \rho = 1 \\ H_a &= \rho < 1 \end{aligned}$$

A hipótese nula é a de que existe uma raiz unitária, ou seja, que $\rho = 1$. Entretanto, a representação mais comum é dada pela subtração de y_{t-1} em ambos os lados da equação (18).

Assim:

$$\Delta y_t = \theta Y_{t-1} + \varepsilon_t$$

em que:

$$\Delta y_t = Y_t - Y_{t-1}$$

$$\theta = \rho - 1$$

ε_t = ruído branco

Com a hipótese nula dada por:

$$\begin{aligned} H_0 &= \theta = 0 \\ H_a &= \theta < 0 \end{aligned}$$

Entretanto, não se podem usar os tradicionais testes t e F para avaliar a hipótese de existência de raiz unitária. Assim, Dickey & Fuller (1979), por meio de experimentos de Monte Carlo, obtiveram os valores críticos que nos permitem testar esta hipótese. Dessa forma, o procedimento adequado é comparar a estatística t referente a θ sob a hipótese nula com os valores críticos tabulados por Dickey e Fuller. A não-rejeição da hipótese nula indica a presença de uma raiz unitária, ou seja, a série é integrada de ordem 1 [$I(1)$].

A especificação correta de (18) também é suma importância para a realização do teste ADF. A omissão de termos determinísticos como constante e tendência leva o poder do teste a zero, causando a não-rejeição de uma hipótese nula falsa. Assim, conclui-se pela existência de uma raiz unitária, mesmo quando ela não existir. Dessa forma, é necessário testar as especificações com constante e com tendência e decidir qual a mais adequada para a realização dos testes de raiz unitária. Então, além de (18), é possível distinguir mais duas especificações:

$$\text{Com constante: } \Delta Y_t = \alpha + \theta Y_{t-1} + \varepsilon_t \quad (19)$$

$$\text{Com constante e tendência: } \Delta Y_t = \alpha + \beta_t + \theta Y_{t-1} + \varepsilon_t \quad (20)$$

A decisão sobre qual especificação deve ser utilizada pode ser feita diretamente, por meio de testes sobre a significância do termo da tendência e da constante nas equações (17) e (18) ou por testes conjuntos de significância dos termos determinísticos e de raiz unitária. No primeiro caso, também se usam tabelas construídas por Dickey & Fuller (1981): em (17), utiliza-se a tabela $\tau_{\alpha\mu}$ para testar se $\alpha = 0$, dado $\theta = 0$. Em (18), usa-se a tabela $\tau_{\alpha\tau}$ para saber se $\alpha = 0$, dado $\theta = 0$ e $\tau_{\beta\tau}$, para testar se $\beta = 0$, dado $\theta = 0$. No caso dos testes conjuntos, é necessário construir uma espécie de estatística F , denominada por Dickey & Fuller (1981), de Φ_1, Φ_2, Φ_3 . Estas estatísticas são formuladas do mesmo modo que os testes F tradicionais:

$$\Phi_i = \frac{[SQR_i(restrito) - SQR_i(irrestrito)] / r}{SQR_i(irrestrito) / (T-K)} \quad (21)$$

em que:

SQR_i = soma dos quadrados dos resíduos

r = número de restrições

T = número de observações


K = número de parâmetros estimados no modelo irrestrito

Comparando-se o valor calculado em Φ_i com o valor apropriado que está em Dickey & Fuller (1981), pode-se determinar a validade da restrição ou não. No caso da equação (18), pode-se testar as hipóteses conjuntas $\alpha = \beta = \theta = 0$, com estatística Φ_2 e $\beta = \theta = 0$ com estatística Φ_3 .

4. RESULTADOS E ANÁLISE DOS DADOS

4.1 Gráfico da tendência dos preços (*Shrimp*)


GRÁFICO 01- Gráfico da tendência de preços (*Shrimp*)



Fonte: Dados da pesquisa

Ao se fazer uma rápida inspeção visual no gráfico acima, percebe-se que a série de preços do camarão de calibre 100/120kg deixa evidente uma enorme volatilidade desta commodity no mercado físico de compra e venda. Fica também evidente através deste cenário, o comportamento cíclico ou sazonal dos preços, o que indica uma imperfeição na formação temporal. Outro ponto a ser destacado neste gráfico é que algumas vezes, a base apresenta-se negativa, o que se traduz em uma grande dificuldade para os produtores em conseguir a fixação adequada de preços dos seus produtos no mercado, impondo-lhes a redução de custos de produção. Numa última análise deste gráfico, percebe-se a necessidade da realização do teste da raiz unitária, onde irá se verificar a condição de estacionaridade da série.

4.2 Correlograma da série sem diferenciação (*Shrimp*)



Fonte: Dados da pesquisa

Observando o correlograma acima, que se refere a série não diferenciada do camarão cinza calibre 100/120kg, pode-se evidenciar fortes sinais de ciclos e conglomerados de volatilidades na série de preços, podemos entender também que tal fenômeno pode estar sendo gerado pela presença de autocorrelação serial derivada da dependência temporal das observações. Isso sugere uma forte relação entre as observações no tempo t com as observações ou defasagens de tempo $T-t$ ($t=1,2,3,4,\dots$), ou seja, que a série de preços de hoje é parcialmente afetada pelas bases dos dias passados (anteriores).

A este fenômeno dá-se o nome de autocorrelação serial o que indica que esses mercados não sejam eficientes e há, portanto, um padrão (comportamento) previsível na formação de preços para o camarão cinza.

Os coeficientes de autocorrelação estimados (gráfico 02) confirmam um padrão previsível para a média de preços do camarão. Esta formação de preço pode estar ligada ao fato de que os agentes no mercado futuro e principalmente no mercado físico, não incorporam totalmente as informações de mercado no dia em que foram divulgadas. Isso indica a persistência nos choques de uma informação levada ao mercado por vários dias, o que vem explicar as tendências primárias na série (curto prazo).

4.3 Teste da Raiz Unitária para a série de preços do camarão

TABELA 02- Teste da Raiz unitária para a série *Shrimp* sem diferenciação

Null Hypothesis: SHRIMP has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 1 (Automatic based on SIC, MAXLAG=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.325679	0.4178
Test critical values:		
1% level	-4.002142	
5% level	-3.431265	
10% level	-3.139292	


*MacKinnon (1996) one-sided p-values.

Fonte: Dados da pesquisa

Após a realização do teste ADF, o valor probabilístico da existência de uma raiz unitária foi de 41,78%, ou seja, assumir-se-á a hipótese nula(h_0) de haver pelo menos uma raiz unitária. Sabendo que a raiz unitária fere os princípios da estimação em Séries Temporais, há necessidade de promover uma diferenciação na série de preços.

Evidência confirmada, portanto, aplicou-se uma diferença de um *lag* na série de preços para contornar os efeitos indesejados de autocorrelação e ciclos como foi mostrado no gráfico 02.

4.4 Gráfico da série diferenciada (*Shrimpd*)




Fonte: Dados da pesquisa

O gráfico acima reflete a série diferenciada (com 1 *level* - defasagem), que agora é estacionária, portanto não apresenta tendência, padrão ou nenhum comportamento cíclico. Pode-se perceber também uma alta volatilidade na série defasada com a presença de grandes “*out liers*”. Deste modo, a expectativa presente da série de preços para a commodity camarão difere-se da expectativa da mesma commodity para o futuro. Este fato, provavelmente, se deve às questões de oferta de produtos em termos de micro e macro análises, questões climáticas e outros fatores.

Ao se analisar as funções de autocorrelação e autocorrelação parcial para a série diferenciada no gráfico 04, percebe-se que o processo da defasagem contorna a grande parte da autocorrelação apresentada, a tornando um ruído branco, melhorando, portanto substancialmente as características principais da série. Isto posto, ainda é preciso modelá-la por algum método auto-regressivo e/ou de médias móveis.

4.5 Correlograma da série diferenciada (*Shrimpd*)



Fonte: Dados da pesquisa

A série neste momento assemelha-se a um ruído branco, ou seja, uma série puramente aleatória, diante disto, deve-se implementar os modelos temporais. Neste trabalho foram utilizados os modelos ARIMA (p,d,q) ou ARMA (p,q) e o modelo GARCH, para modelar a variância.

4.6 Estatística Descritiva das séries *Shrimp* e *Shrimpd* (1 defasagem)

TABELA 03 – Estatística descritiva das séries *Shrimp* e *Shrimpd*

Estatísticas	<i>Shrimp</i>	<i>Shrimpd</i>
Média	3,260000	0,000000
Assimetria	0,531356	0,560721
Curtose	2,716285	25,08156
Desvio Padrão não condicional	0,370622	0,128008
Jarque & Bera	11,90116	4318,200
p-valor J & B	0,002604	0,000000

Fonte: Dados da pesquisa

Por meio do teste de normalidade proposto por Jarque & Bera (1980) pode-se verificar que a assimetria e curtose são fortemente significativas e indicam que a série de preços do camarão apresenta uma distribuição leptocúrtica (cauda pesada) em relação a distribuição normal. O coeficiente de assimetria e excesso de curtose quantifica os desvios da distribuição normal e é apresentado em Zhou (1999). De acordo com a Tabela 4 podemos identificar que a série de preços defasada é estacionária e não contém raízes unitárias.

4.7 Teste de Estacionaridade para série defasada de camarão (*Shrimpd*)

TABELA 04- Teste de Estacionaridade para série defasada de camarão (*Shrimpd*)

Teste para a Raiz Unitária	<i>Shrimpd</i> (1 defasagem)
Dickey e Fuller (ADF)	-19,67
Phillips-Perron (PP)	-19,26

Fonte: Dados da pesquisa

Nota: O valor crítico a 1% de significância é -3,46.

Os testes foram realizados através dos critérios Dickey-Fuller Aumentado (ADF) e Phillips-Perron (PP), propostos respectivamente por Dickey & Fuller (1979) e Phillips & Perron (1988). Por todas as evidências descobertas no trabalho, propôs-se um modelo auto-regressivo e de médias móveis ARMA (2,2) incompleto para captar os efeitos temporais na série no que se refere à sua média. Para tanto, a série modelada apresentou grande evidência de heteroscedasticidade na variância dos resíduos através da inspeção nas funções de

autocorrelação e autocorrelação parcial dos resíduos quadráticos da série defasada da série *Shrimpd*, como pode ser visto no gráfico 05.

4.8 Correlograma da série defasada por meio de um modelo ARMA (2,2)

GRÁFICO 05- Correlograma da série defasada por meio de um modelo ARMA (2,2)
Included observations: 211 / Date: 06/26/10 / Time: 11:40 / Sample: 3 213
Q-statistic probabilities adjusted for 1 ARMA term(s) / Residuals Squared

Statistics probabilities adjusted for 17 dummy terms (7) Residuals Squared					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.465	0.465	46.279	
		2 0.160	-0.071	51.800	0.000
		3 -0.002	-0.063	51.801	0.000
		4 -0.015	0.028	51.848	0.000
		5 -0.038	-0.040	52.157	0.000
		6 -0.042	-0.017	52.549	0.000
		7 -0.033	-0.002	52.788	0.000
		8 -0.032	-0.021	53.015	0.000
		9 -0.025	-0.006	53.157	0.000
		10 -0.031	-0.021	53.366	0.000
		11 -0.027	-0.009	53.527	0.000
		12 -0.039	-0.030	53.877	0.000
		13 -0.015	0.017	53.927	0.000
		14 -0.011	-0.013	53.954	0.000
		15 -0.028	-0.033	54.139	0.000
		16 -0.043	-0.021	54.561	0.000
		17 -0.039	-0.012	54.915	0.000
		18 -0.034	-0.017	55.187	0.000
		19 -0.027	-0.010	55.364	0.000
		20 -0.026	-0.016	55.526	0.000
		21 -0.003	0.014	55.529	0.000
		22 -0.004	-0.016	55.532	0.000
		23 -0.019	-0.024	55.615	0.000
		24 -0.015	0.001	55.672	0.000
		25 -0.005	0.001	55.678	0.000
		26 0.007	0.004	55.690	0.000
		27 -0.020	-0.039	55.790	0.001
		28 0.010	0.038	55.814	0.001
		29 -0.018	-0.047	55.895	0.001
		30 -0.035	-0.026	56.202	0.002
		31 -0.031	0.001	56.444	0.002
		32 -0.016	-0.008	56.509	0.003
		33 -0.028	-0.031	56.707	0.005
		34 -0.034	-0.017	57.002	0.006
		35 -0.030	-0.014	57.230	0.008
		36 -0.024	-0.013	57.380	0.010

Fonte: Dados da pesquisa

O modelo ARMA(2,2) resolveu parcialmente de diferenciação e estacionariedade da série, entretanto, percebe-se através do gráfico acima, um indicativo de instabilidade na variância, deste modo será proposta uma modelagem através do processo GARCH, para tanto deve-se fazer primeiramente o teste ARCH, que está disposto logo a seguir.

4.9 Teste ARCH para a série defasada pelo modelo ARMA (2,2)

TABELA 05 – Teste de Heteroscedasticidade para a série *Shrimpd* – Multiplicador de Lagrange

Resíduos ARMA (2,2) incompleto para a série defasada		Resíduos GARCH (1,1) para ARMA (2,2) incompleto	
Lag	p-valor	Lag	p-valor
1	0,0000	1	0,9171
5	0,6920	5	0,9296
10	0,2308	10	0,9951
15	0,1295	15	0,1536
25	0,2011	25	0,0003

Fonte: Dados da pesquisa

Conforme os p -valores, o teste para efeitos GARCH de Engle (1982) fornece fortes evidências contra a hipótese nula de não haver heteroscedasticidade condicional na volatilidade dos modelos para a série estudada. Deste modo, a série defasada foi modelada levando em consideração o padrão heteroscedástico da volatilidade para a média condicional dos resíduos através dos métodos constituintes da família ARCH. Ao adotar a hipótese de normalidade dos resíduos dos modelos ajustados para a média condicional da base na estimação dos modelos e considerando o fato estilizado “caudas pesadas”, adotou-se a matriz de variância-covariância corrigida proposta por Bollerslev & Wooldridge (1992) no procedimento de estimação dos modelos da família ARCH.

Assim sendo, ajustou-se vários modelos para a média da série. O melhor ajustamento ponderado pelos critérios de informação de Akaike, Schwarz e Quadrado dos Resíduos foi gerado com um ARMA(2,2) incompleto para um GARCH(1,1), ajustados aos resíduos do modelo ARMA para a média condicional dos retornos.

Os parâmetros dos modelos foram estimados pelo procedimento de Newey & West (1987), tornando-os robustos à heteroscedasticidade e autocorrelação no processo do resíduo. Os resultados da estimação para a média condicional e a volatilidade dos preços do camarão cinza de calibre 100/120kg estão reportados logo a seguir na tabela 06.

TABELA 06 – Estimação do modelo ARMA(2,2) para GARCH(1,1)

Dependent Variable: SHRIMPD

Method: ML – ARCH

Date: 07/05/10 Time: 19:38

Sample (adjusted): 4 213

Included observations: 210 after adjustments

Convergence achieved after 34 iterations

MA backcast: 2 3, Variance backcast: ON

GARCH = $C(3) + C(4)*RESID(-1)^2 + C(5)*GARCH(-1)$

	Coefficient	Std. Error	z-Statistic	Prob.
AR(2)	-0.932145	0.085761	-10.86913	0.0000
MA(2)	0.917253	0.088459	10.36924	0.0000
Variance Equation				
C	0.005555	0.000452	12.30256	0.0000
ε_{t-1}^2	0.518105	0.081787	6.334847	0.0000
σ_{t-1}^2	0.115321	0.053004	2.175686	0.0296
R-squared	-0.006096	Mean dependent var		0.005952
Adjusted R-squared	-0.025727	S.D. dependent var		0.128448
S.E. of regression	0.130090	Akaike info criterion		-1.764583
Sum squared resid	3.469279	Schwarz criterion		-1.684890
Log likelihood	190.2813	Durbin-Watson stat		2.604072

Fonte: Dados da pesquisa

Os critérios de informação escolhidos para as análises da estimação dos modelos acima, foram o AIC (*Akaike info criterion*), que foi igual a -1,76; o Schwarz, que foi igual a -1,68 e a soma dos quadrados dos resíduos (*Sum squared resid*), que foi igual a 3,46.

4.10 Previsão da série defasada e Previsão da variância

GRÁFICO 06- Previsão para a série defasada




GRÁFICO 07- Previsão para a variância

Fonte: Dados da pesquisa

Para o cálculo de VaR, foi prevista a volatilidade condicional $\sigma_{t/t-1}$ através do modelo GARCH como pode ser evidenciado na Figura 5 (previsão da variância condicional). A partir daí, construiu-se o intervalo de confiança com referência na distribuição condicional das bases. A utilização da volatilidade condicional contorna vários dos problemas apontados, dando maior peso às observações mais recentes.

Já para o cálculo efetivo do VaR histórico para a commodity camarão utilizou-se a média dos últimos 10 dias da cotação da série *Shrimp* como fator de referência. Assim sendo, utilizou-se a média (P) de \$ 3,96 como o parâmetro inicial do preço. Admitindo uma variância para todo o período foi possível identificar o Var a 1% e 5%.

TABELA 07 – Estimativas do VaR para a série de preços do camarão cinza de calibre 100/120kg

VaR (Série de preços em \$)		
Componentes do VaR	VaR Histórico	
	1%	5%
P^1	3,96	3,96
V_c^2	2,57	1,96
$\hat{\sigma}^3$	0,37	0,37
VaR	\$ 3,77	\$ 2,87


Fonte: Dados da pesquisa

Considerando o cômputo do Var pela metodologia da Variância Condicional (ARIMA/GARCH) é possível elucidar o padrão instável para a série de VaR.

De acordo com os cálculos sistematizados na Tabela 07, pode-se observar que a um nível de significância de 1% o produtor de camarão tem uma perda máxima admitida de \$ 3,77 para cada 100g de camarão comercializado. Seguindo o mesmo raciocínio, a um nível de significância de 5%, o produtor admite uma perda máxima de \$ 2,87 para cada 100g de camarão vendido.

4.11 Gráfico do VaR aos níveis de 5% e 1% de confiança

GRÁFICO 08- Var aos níveis de 5% e 1% de confiança




Fonte: Dados da pesquisa

Através de uma rápida observação nos gráficos acima percebe-se que o comportamento do VaR a 5% é semelhante ao VaR a um nível de 1%. Estes gráficos permitem o entendimento da dinâmica do Var, da variabilidade dos preços e da visualização de um VaR para cada previsão de volatilidade de preços do camarão, mudando apenas o intervalo de confiança entre os dois níveis.

Importante salientar também que, o VaR a 5% de confiança apresenta um “stress” maior nos seus últimos intervalos, já que neles podemos observar picos maiores (*outliers*).

No gráfico abaixo (09), podemos visualizar o histograma do *Value-at-Risk* a um nível de 1% de confiança, onde a média é de \$ 0,90 para cada 100g de camarão comercializado e a 5%, este valor cai para \$ 0,69. Este decréscimo é considerado normal, pois ao aumentarmos o nível de confiança de 1% para 5%, estaremos aumentando o campo dos erros.

GRÁFICO 09- Histograma do VaR a 1% e a 5% de confiança



Fonte: Dados da pesquisa

Por fim, pode-se notar também que os dois níveis de confiança (VaR 1% e 5%), apresentam uma distribuição assimétrica positiva ou simplesmente a direita, onde há maior concentração de valores nos intervalos de 0 a 1, com curtoses aproximadas a 32,38.

5. CONCLUSÃO

5.1 Considerações Finais

Dado o que foi discutido neste trabalho, pode-se perceber que, ainda que as previsões não tenham tido uma qualidade preditiva muito expressiva para os valores pontuais, os mesmos apresentam alta aderência quando utilizadas para estimativas do cálculo do VaR. Isto porque a série reproduz boas condições da série empírica.

Neste cenário, pode-se afirmar, contudo, que os preços do camarão de calibre 100/120kg, apresentam um padrão assimétrico aos choques de informações e que o mesmo revela uma persistência nestes choques necessitando de um determinado tempo para dissipar-se completamente, sugerindo que há certa imperfeição nos mercados revelados pela previsibilidade das tendências de forma forte embora errática para os valores pontuais dos preços.

Estas características mensuradas são suficientes para justificar o uso dos modelos de variância condicional para o cômputo do risco e previsão de perdas aceitáveis. Esta perspectiva promove e sugere uma nova metodologia para a determinação dos riscos, desligando-se, assim, das estimativas tradicionais em uso que desconsidera os padrões condicionais da variância.

Com a modelagem da série *Shrimpd* (com 1 defasagem), por meio de um modelo autorregressivo ARMA (2,2) e um modelo Heteroscedástico GARCH (1,1), os objetivos iniciais deste trabalho foram atendidos, pois a partir da utilização das técnicas aplicadas nos dados, foi possível precificar a volatilidade da ativo camarão e posteriormente a determinação do VaR.

Dentro desta perspectiva, podemos afirmar, contudo, que a perda em valores máximos admitidos pelos produtores de camarão aos níveis de confiança de 1% a 5%, são de \$ 3,77 e \$ 2,87, respectivamente. Como neste trabalho o foco foi a mensuração da perda máxima aceitável a um nível de significância estatística de 5%, adotou-se o valor de \$ 2,87 como perda máxima, na comercialização de cada 100g de camarão cinza de calibre 100/120kg para os produtores.

Esta informação poderá dar um viés positivo aos criadores no âmbito da redução de custos produtivos ou no aumento da margem de comercialização, o que por sua vez permitirá uma menor perda ao produtor ou simplesmente uma margem de segurança no preço de seu produto.

Importante destacar que para uma análise mais refinada destes dados faz-se necessária à utilização de modelos multivariados combinados com modelos de *stress*, posto que a série apresenta fortes *outliers*. Mesmo que tenha se utilizado o ferramental estatístico muito aquém da sua potência preditiva - em virtude de limitações técnicas - os resultados do trabalho avança no sentido de evidenciar a necessidade de se considerar os padrões condicionais da série nas estimativas de risco.

Empiricamente, o que se percebe é que há uma extrema subestimação dos riscos de comercialização a partir da utilização de técnicas simplistas e padrões de extração de volatilidade de preços.

Por fim, no Método Histórico é mais fácil calcular os valores do VaR e há uma mensuração de cada VaR para cada período, porém, é válido ressaltar que estes são menos precisos que o modelo do VaR condicional, pois esse método é influenciado pelo cotação dos valores extremos. Isto ocorre dado às características não lineares da distribuição de probabilidade descrita pela série, contendo excesso de curtose, assimetria, persistência de choques e conglomerados de volatilidade.

REFERÊNCIAS

- ABCC - Associação Brasileira de Criadores de Camarão. **História da carcinicultura no Brasil**. Disponível em: <<http://www.abccam.com.br>>. Acesso em: 04 abr. 2010.
- ASSOCIAÇÃO BRASILEIRA DE CRIADORES DE CAMARÃO. **O Agronegócio do camarão marinho cultivado**. Recife: ABCC, Jul. 2002, p. 3.
- ASSAF NETO, Alexandre. **Mercado Financeiro**. 5ª Ed. São Paulo: Atlas, 2003.
- BARROS, E. A. C.; MAZUCHELI, J. **Aplicações de Simulação Monte Carlo e Bootstrap**. Maringá, Universidade Estadual de Maringá, 2005. 52 p. Monografia Centro de Ciências Exatas, Universidade Estadual de Maringá, Maringá, 2005.
- 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/v12n1bressanpdf>>. Acesso em: 12 jun. 2010.
- BRIGHAM, E. F.; et al. **Administração Financeira: Teoria e prática**. São Paulo: Atlas, 2001.
- COSTA, E., Y. SAMPAIO. **Geração de empregos diretos e indiretos na cadeia produtiva do camarão marinho cultivado**. Economia Aplicada, v.8, nº 2, abr-jun 2004.
- DAFT, Richard. **Organizações: teorias e projetos**. São Paulo: Pioneira, 2002.
- DANIELSSON, J., and C. G. de VRIES (1997c): “**Value at Risk and Extreme Returns**”, London School of Economics, Financial Markets Group Discussion Paper, n. 273.
- DRUCKER, Peter F. **Administrando para o futuro: os anos 90 e a virada do século**. São Paulo: Pioneira, 1992.
- ESCUADERO, L. F. **La Simulación en La empresa**. Barraincúa: Deusto, 1973.
- FALKENSTIEN, E. e HANWECK, J. **Minimizing Basis Risk From Non-Parallel Shifts in the Yield Curve – Part II: Principal Components**, *The Journal of Fixed Income*, jun, p. 85- 90.
- GALDI, Fernando C.; PEREIRA, Leonel M. **Valor em Risco (VaR) utilizando modelos de previsão de volatilidade: EWMA, GARCH e Volatilidade Estocástica**. Brazilian Bussiness Review. Espírito Santo, v. 4, p. 74-95, abr. 2007.
- GITMAN, L. J. **Princípios da Administração Financeira**. São Paulo: Harper & Row do Brasil, 1978.
- HAMMERSLEY, J.M. e HANDSCOMB, D.C. **Monte Carlo Methods**. London: Methuen, 1964.
- JORION, P. **Value at risk: the new benchmark for controlling derivatives risk**. Chicago: Irwin, 1999. Tradução BM&F.
- JU, X. ; PEARSON, N. D. **Using Value-at-Risk to Control Risk Taing: how wrong can you be?** Illinois: University of Illinois at Urbana-Champaign, 1998. OFOR paper 98-08.
- LESCA, H.; ALMEIDA, F. C. **Administração Estratégica da informação**. Revista de Administração. São Paulo, v. 29, n. 3, p. 66-75, jul./set. 1994.
- LI, D. X. Value-at-Risk based on the Volatility, Skewness and Kurtosis. Riskmetrics: Group Working Paper, 1999. Paper 4.
- KUPIEC, P., “**Techniques for verifying the accuracy of risk measurement models**”. Journal of Derivates, Winter 1995.
- JACKSON, P., D.J. Maude and W. Perraudin (1997). **Bank Capital and Value-at-Risk**. *Journal of Derivatives* 4 (Spring): 73-90.
- LINSMEIER, T. J. ; PEARSON, N. D. **Risk measurement: an introduction to value at risk**. Illinois: University of Illinois at Urbana-Champaign, 1996. OFOR paper.
- MAHONEY, J. M. C. Sundaramurthy and J. T. Mahoney (1996). **The Differential Impact on Stockholder Wealth of Various Antitakeover Provisions**, *Managerial and Decision Economics*, 17(6), 531-549.

- MÓL, A. L. R. **Value at risk como medida de risco da volatilidade dos ajustes diários em mercados futuros de café.** 2002. Dissertação (Mestrado em Administração) – Programa de Pós-Graduação em Administração da UFLA, Lavras, 2002.
- MÓL, A. L. R. et al. **Value-at-Risk: uma abordagem heteroscedástica do risco de base para o Café no Cerrado Mineiro.** Disponível em: <<http://www.sober.org.br/palestra/2/769.pdf>>. Acesso em: 20 jun. 2010.
- MOLLICA, M. A. **Uma avaliação de Modelos de Value-at-Risk:** comparação entre métodos tradicionais e modelos de variância condicional. 1999. Dissertação (Mestrado em Economia)-Universidade de São Paulo, São Paulo.
- RAMOS, P. M.; MAYA, P. C. C.; BORNIA A. C. **Um estudo científico do componente preço e sua relação com o marketing mix de produto brasileiro de exportação:** uma Pesquisa Multicasos nas Empresas do Consórcio de Exportação de Calçados de São João Batista / Santa Catarina. *In: Anais da XXIX EnANPAD.* Brasília: ANPAD, 2005.
- ANDERSEN, T.; BOLLERSLEV, T.; DIEBOLD, F.X.; LABYS, P. Modeling and forecasting realized volatility. *Econometrica*, v.71, n.2, p.529-626, 2003.
- ANDERSON, G. and HENDRY, D. F., **An econometric model of United Kingdom building societies.** Oxford Bulletin of Economics and Statistics, 1971.
- BOLLERSLEV, T ; WOOLDRIDGE, J. M. **Quasi-maximum likelihood estimation and inference in dynamic models with time-Varying Covariances.** *Econometric Reviews*, v.11, n.2, p.143-172, 1992.
- BOLLERSLEV, T. **Generalized autoregressive conditional heteroscedasticity.** *Journal of Econometrics*, v. 31, p. 307-327, 1986.
- BOURBONNAIS R; TERRAZA, M, **Analyse Des Séries Temporelles En Economie,** Press Universitaire de France, Paris, 1998.
- BOX, G. E. P. & JENKINS, G. M.. *Time Series Analysis: forecasting and control.* San Francisco, Holden-Day, 1976.
- DICKEY, D.A; FULLER W.A. Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*, v.74, p 427–431; 1979
- ENDERS, W. **Applied Econometrics Time Series.** John Wiley and Sons, Inc. 1995.
- ENGLE, R. F. **Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation.** *Econometrica*, Vol. 50, pp.987- 1007, 1982.
- ENGLE, R. F.; BOLLERSLEV, T. **Modeling the Persistence Conditional Variance** (with discussion). *Econometrics Reviews*, v. 5, p. 1-50, 80-87, 1986.
- ENGLE, R.F. **GARCH 101: the use of ARCH/GARCH models in applied econometrics.** *Journal of Economic Perspectives*, v.15, n.4, p.157-168, 2001.
- ENGLE, R.F.; GONZALEZ-RIVERA, G. (1991), **Semiparametric ARCH models,** *Journal of Business and Economics Statistics*, v. 9, p. 345-59.
- FRANSES, P. H. **Time Series models for business and economic forecasting,** Cambridge, 1998.
- GRANGER, C.W.J. **Overview of Non-Linear Time Series Specification in Economics,** NSF-Symposia, Berkeley, CA.1998.
- GRANGER, C. W. J.; NEWBOLD, Paul. **Forecasting Economic Time Series.** New York :Academic Press, 1977.
- JARQUE, C.; BERA, A. **A Test for normality of observations and regression residuals.** *International Statistical Review*, v.55, p.163-172, 1987.
- LONGERSTAEY J and MORE L, **Introduction to riskmetrics™,** fourth ed., Morgan Guaranty Trust Company, New York, 1995.

- LUSTOSA, P. R. B.; PONTE, V. M. R.; DOMINAS, W. R. Simulação. In: CORRAR, L. J.; THEÓPHILO, C. R. (Coord.). **Pesquisa operacional para decisão em contabilidade e administração: contabilometria**. São Paulo: Atlas, 2004. p. 242-284.
- NELSON, D. B. **Conditional heteroskedasticity in asset returns: a new approach**. *Econometrica*, v.59, n.2, p.347-370, 1991.
- NELSON, Charles. R. **Applied time series analysis for managerial forecasting**. San Francisco: Holden-Day, 1973.
- NEWKEY, W., WEST, K., **A Simple, Positive Semi-definite, Heteroscedasticity and Autocorrelation Consistent Covariance Matrix**, *Econometrica*, v.55, p. 703-708. 1987.
- NICHOLLS, D.F.; QUINN, B.G. **Random Coefficient Autoregressive Models: An Introduction**. Lecture Notes in Statistics, v. 11, Springer, New York, NY, 1982.
- PHILLIPS, P. C. B.; PERRON, P. **Testing for a unit root in time series regression**, *Biometrika*, v. 75, n. 2, 1988.
- PINDYCK, R. e RUBINFELD, D. **Econometric Models and Economic Forecast**. McGraw-Hill, EUA, 1981.
- SWARAY, R. B. **Volatility of primary commodity prices: some evidence from agricultural exports in Sub-saharan Africa**. New York: University of New York, 2002. Discussion Papers in Economics, n.2002/06.
- TAYLOR, S. J. **Modeling Financial Times Series**. UK: John Wiley & Sons, 1986.
- THAVANESWARAN, A., APPADOO, S.S. and SAMANTA, M. **Random Coefficient GARCH models**. *Mathematics and Computer Modelling*, v.41 no 6-7, pp. 723-33. 2005b.
- THAVANESWARAN, A., APPADOO, S.S., PEIRIS, S. **Forecasting volatility**. *Statistics and Probability Letters*, v.75 no. 1, pp. 1-10. 2005a
- TOSCANO JUNIOR, Luis Carlos. **Guia de Referência para o Mercado Financeiro**. São Paulo: Edições Inteligentes, 2004.
- ZAKOIAN, J.M. **Threshold Heteroskedasticity Models**. *Journal of Economic Dynamics and Control*, v.18, p.931-955, 1994.
- YIM, J. **Previsão de Séries de Tempo: Modelos ARIMA, Modelos Estruturais e Redes Neurais Artificiais**. Dissertação (Economia) - Universidade de São Paulo, 2001.