

Universidade Federal de Minas Gerais  
Instituto de Ciências Exatas – ICEX  
Departamento de Estatística

Gizelle Lúcia Ferreira

**ANÁLISE DA VOLATILIDADE DO ÍNDICE DO SETOR INDUSTRIAL  
(*INDX*) NO PERÍODO DE 01/01/2000 A 30/04/2011**

Belo Horizonte  
2011

Gizelle Lúcia Ferreira

**ANÁLISE DA VOLATILIDADE DO ÍNDICE DO SETOR INDUSTRIAL  
(*INDX*) NO PERÍODO DE 01/01/2000 A 30/04/2011**

Trabalho apresentado ao Curso de Especialização em Estatística com ênfase em Indústria e Mercado do Departamento de Estatística do Instituto de Ciências Exatas da Universidade Federal de Minas Gerais, para a obtenção do grau de Especialista em Estatística.

Aluna: Gizelle Lúcia Ferreira

Orientadora: Profa. Ela Mercedes M. de Toscano

Belo Horizonte  
2011

# **ANÁLISE DA VOLATILIDADE DO ÍNDICE DO SETOR INDUSTRIAL (*INDX*) NO PERÍODO DE 01/01/2000 A 30/04/2011**

**Gizelle Lúcia Ferreira**

**Profa. Ela Mercedes M. de Toscano**

Departamento de Estatística da Universidade Federal de Minas Gerais

**Outubro, 2011**

## **RESUMO**

O presente trabalho tem como objetivo analisar o padrão de comportamento do Índice do Setor Industrial (*INDX*), bem como as influências exercidas por variações sobre a volatilidade meados de 2008-2009 (efeitos da crise econômica mundial desencadeada no mercado de hipotecas dos Estados Unidos) por meio de modelos da classe ARCH. Os modelos foram construídos com e sem variável indicadora de intervenção, devido ao intenso movimento de queda dos índices das bolsas de valores pelo mundo. Como resultado da análise, o modelo que melhor atende aos critérios de qualidade de ajuste do modelo foi o modelo TAR<sub>CH</sub>(1,1), modelo este que evidencia a presença de assimetria na volatilidade, indicando que choques negativos causam maior volatilidade do que choque positivos. Os demais modelos apresentados encontram-se bem ajustados, destacando que quanto aos critérios de qualidade do ajuste do modelo, entre os modelos ARCH, GARCH e EGARCH, apresentaram melhores resultados aqueles que possuem variável indicadora de intervenção.

Palavra-chave: Volatilidade, Modelos ARCH, Análise de intervenção, *INDX*.

# **ANÁLISE DA VOLATILIDADE DO ÍNDICE DO SETOR INDUSTRIAL (*INDX*) NO PERÍODO DE 01/01/2000 A 30/04/2011**

**Gizelle Lúcia Ferreira**

**Profa. Ela Mercedes M. de Toscano**

Departamento de Estatística da Universidade Federal de Minas Gerais

**Outubro, 2011**

## **ABSTRACT**

The present work aims to analyze the behavior pattern of the Industrial Sector Index, and the influences exerted by variations on the volatility mid-2008 to 2009 (the effects of global economic crisis triggered in the mortgage market in the United States) through ARCH class models. Models were constructed with and without intervention indicator variable, due to the intense downward movement of the indices of stock markets around the world. As a result of the analysis, the model that best meets the criteria for goodness of fit of the model was the model TAR<sub>CH</sub> (1,1), this model shows that the presence of asymmetry in volatility, indicating that negative shocks cause more volatility than positive shocks. The other models presented are well adjusted, highlighting that the quality criteria of model fit between models ARCH, GAR<sub>CH</sub> and EGAR<sub>CH</sub>, showed better results those with variable rates of intervention.

**Keywords:** Volatility, ARCH Models, Intervention Analysis, Industrial Sector Index.

## SUMÁRIO

1. INTRODUÇÃO.....	5
2. METODOLOGIA .....	7
3. DESCRIÇÃO DOS DADOS .....	15
4. ANÁLISE DOS RESULTADOS .....	19
5. CONCLUSÃO .....	21
6. REFERÊNCIA BIBLIOGRÁFICA.....	22
ANEXO 1 – Representação dos Modelos.....	24
ANEXO 2 - Resultados do Modelo 1 : Retorno ~ $C I_t$ AR(1) AR(20) ARCH(3).....	25
ANEXO 3 - Resultados do Modelo 2 : Retorno ~ $C$ AR(1) AR(20) ARCH(3).....	27
ANEXO 4 - Resultados do Modelo 3 : Retorno ~ $C I_t$ AR(1) GARCH(1,1).....	29
ANEXO 5 - Resultados do Modelo 4 : Retorno ~ $C$ AR(1) GARCH(1,1).....	31
ANEXO 6 - Resultados do Modelo 5 : Retorno ~ $C I_t$ AR(1) EGARCH(1,1).....	33
ANEXO 7 - Resultados do Modelo 6 : Retorno ~ $C$ AR(1) EGARCH(1,1).....	35
ANEXO 8 - Resultados do Modelo 7 : Retorno ~ $C$ AR(1) TARCH(1,1).....	37
ANEXO 9 – Valor Residual <i>versus</i> Valor Observado <i>versus</i> Valor Ajustado.....	39
ANEXO 10 – Desvio Padrão Condicional.....	40
ANEXO 11 – Histograma dos Resíduos Padronizados.....	41

## 1. INTRODUÇÃO

Teoricamente, a volatilidade de um ativo representa as alterações ocorridas nos seus preços em razão de diversos fatores que podem estar relacionados ao desempenho das empresas emitentes ou por fatores externos. Assim, as ações podem apresentar comportamentos diferentes no mesmo período, podendo ocorrer valorização ou desvalorização (BM&FBOVESPA).

Conforme Ceretta (1999), em estudos realizados em outros mercados de ações – dos quais destacam-se French *et al* (1987), Schwert (1990) e Glosten *et al* (1993) – constataram que a influência exercida por variações negativas nos preços sobre a volatilidade é maior do que a exercida por variações positivas de mesma magnitude. Períodos de alta volatilidade no mercado financeiro coincidem com períodos nos quais ocorreram crises econômicas em diversos países.

A crise financeira mundial originada no mercado hipotecário dos Estados Unidos, particularmente o segmento *subprime*<sup>1</sup>, chegou em sua fase mais crítica em setembro de 2008 quando um dos maiores bancos de investimentos do país pediu concordata e outro foi forçado a se vender, respectivamente, *Lehman Brothers* e *Merrill Lynch* (GONTIJO; OLIVEIRA, 2009).

Estes eventos desencadearam verdadeiro pânico no mercado financeiro com efeitos arrasadores nas bolsas de valores pelo mundo. Em 15 de setembro de 2008, o Índice Bovespa registrou sua maior queda diária desde os atentados de 11 de setembro em 2001, caiu 7,59%. O índice *INDX* fechou o mês de setembro com queda de 20,07% em relação ao mês anterior (FIESP, DEPECON, 2008).

O mercado imobiliário dos Estados Unidos passou por uma fase de expansão acelerada logo após a crise das empresas *ponto com* em 2001, quando o banco central americano reduziu sua taxa de juros tornando o crédito abundante e barato. Com a política de juros baixos e crédito farto, os preços dos imóveis tiveram forte valorização, encorajando mutuários a refinar suas hipotecas (FOLHA.com).

Parte destes financiamentos passaram a ser feitos a taxas reajustáveis, significando que na eventualidade de um aumento da taxa de juros, as prestações acompanhariam este

---

<sup>1</sup> A diferença entre hipotecas *prime* e *subprime* reside no perfil de risco do tomador de recursos; as hipotecas *subprime* são oferecidas a tomadores de alto risco (GONTIJO; OLIVEIRA, 2009).

aumento; e o risco inerente aos empréstimos Ninjas<sup>2</sup> foram ignorados, as instituições que vendiam estes papéis, os mesclaram com os créditos *prime* (de boa qualidade), securitizando-os e vendendo-os ao mercado como Obrigações de Dívidas Garantidas (*CDOs*, em inglês), classificadas pelas agências de *rating* como isentas de risco (GONTIJO; OLIVEIRA, 2009).

Após atingir um pico em 2006, os preços dos imóveis, no entanto, passaram a cair. As taxas de juros começaram a subir para combater a inflação enquanto os preços dos imóveis passaram a cair, fazendo com que as mensalidades da casa própria ficassem mais caras. A inadimplência disparou e, assim, os títulos que eram garantidos por essas hipotecas perderam valor (FOLHA.com).

A desregulamentação excessiva do mercado financeiro defendida pelo então presidente George W. Bush contribuiu para esta grave crise, os bancos sofreram grandes perdas com a inadimplência e perdas com os títulos; instalou-se uma grave crise de confiança e os bancos não queriam emprestar, com medo de calotes (MORAES, 2009).

Neste sentido, o presente trabalho propõe-se a analisar a influência exercida por variações sobre a volatilidade dos retornos do *Índice do Setor Industrial (INDX)*, com e sem variável indicadora de intervenção.

O restante do trabalho está estruturado da seguinte forma: na próxima seção um resumo dos principais conceitos relacionados ao trabalho. A seção 3 descrição dos dados. A seção 4 análise dos resultados da aplicação da metodologia nos dados. Finalmente, a seção 5 conclusão.

---

<sup>2</sup> Ninja, em inglês representa a abreviatura de “No income, Jobs ou assets” (sem renda, emprego ou bens).

## 2. METODOLOGIA

Características como tendência, sazonalidade, pontos influentes, heteroscedasticidade condicional e não-linearidade, são comuns em séries temporais financeiras. A presença de tendência numa série corrobora para o típico comportamento que encontramos na prática, a de séries não estacionárias (MORETTIN; TOLOI, 2006).

Diz-se que uma série é estacionária quando esta possui média e variância constantes ao longo do tempo. Um recurso utilizado para comprovar a não estacionariedade de uma série é o teste Dickey-Fuller, um teste de raiz unitária onde a hipótese nula corresponde á existência de raiz unitária, indicando assim que o processo testado não é estacionário. Maiores informações sobre a metodologia podem ser visto em Dickey e Fuller (1979 e 1981).

A maioria das técnicas de análise de séries temporais são aplicáveis em diversas áreas, contudo, por uma característica presente em séries temporais financeiras, o que convencionou-se chamar de volatilidade, faz-se necessário recorrer aos modelos ditos heterocedásticos condicionais.

Nestes modelos, a variância (volatilidade) de um retorno num dado instante de tempo, depende de retornos passados e de outras informações disponíveis até aquele instante, de modo que temos que definir uma variância condicional, que não sendo constante, não coincide com a variância incondicional da série observada.

A série de retornos financeiros de uma variável  $P_t$  onde  $P_t$  refere-se ao preço de um ativo no instante  $t$  ( normalmente um dia de negócio) é dada por  $X_t = \ln (P_t) - \ln (P_{t-1})$ . Morettin (2006) descreve os principais  *fatos estilizados sobre os retornos*, estes são: (i) em geral não auto-correlacionados; (ii) os seus quadrados são auto-correlacionados, apresentando uma correlação de defasagem um pequena e depois uma queda lenta das demais; (iii) apresentam agrupamentos de volatilidade ao longo do tempo; (iv) a distribuição (incondicional) dos retornos apresenta caudas mais pesadas do que uma distribuição normal; em geral é leptocúrtica e; (v) algumas séries são não-lineares.

Os modelos auto-regressivos com heteroscedasticidade condicional, conhecido na literatura como modelos ARCH, foram introduzidos por Engle (1982), com o objetivo de estimar a variância da inflação. A idéia básica é que o retorno  $X_t$  é não-correlacionado



serialmente, mas a volatilidade (variância condicional) depende de retornos passados por meio de uma função quadrática, então tem-se que um modelo ARCH( $r$ ) é definido por:

$$X_t = \sqrt{h_t} \varepsilon_t \quad (1)$$

$$h_t = \alpha_0 + \alpha_1 X_{t-1}^2 + \dots + \alpha_r X_{t-r}^2 \quad (2)$$

Onde  $\varepsilon_t$  é uma sequência de variáveis aleatórias independentes e identicamente distribuídas (*i.i.d.*) com média zero e variância um,  $\alpha_0 > 0$ ,  $\alpha_i \geq 0$ ,  $i > 0$ . Na prática supõe-se que  $\varepsilon_t \sim N(0,1)$  ou  $\varepsilon_t \sim t_\nu$  (distribuição  $t$  de Student com  $\nu$  graus de liberdade).

Uma generalização dos modelos ARCH foi sugerida por Bollerslev (1986) ao propor que a volatilidade condicionada fosse função não apenas dos quadrados dos erros passados ( $X_{t-i}^2$ ), como também dos seus próprios valores passados ( $h_{t-j}$ ), modelos assim construídos foram denominados por modelo GARCH (“generalized ARCH”). Um modelo GARCH( $r,s$ ) é definido por:

$$X_t = \sqrt{h_t} \varepsilon_t \quad (1)$$

$$h_t = \alpha_0 + \sum_{i=1}^r \alpha_i X_{t-i}^2 + \sum_{j=1}^s \beta_j h_{t-j} \quad (3)$$

em que  $\varepsilon_t$  *i.i.d.* (0,1),  $\alpha_0 > 0$ ,  $\alpha_i \geq 0$ ,  $\beta_j \geq 0$ ,  $\sum_{i=1}^q (\alpha_i + \beta_i) < 1$ ,  $q = \max(r,s)$ .

Contudo, um modelo bastante utilizado na prática, é o GARCH(1,1), para o qual a volatilidade é expressa como:

$$h_t = \alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 h_{t-1} \quad (4)$$

com  $0 \leq \alpha_1$ ,  $\beta_1 < 1$ ,  $\alpha_1 + \beta_1 < 1$ .

A soma dos coeficientes de um modelo GARCH é chamada de *coeficiente de persistência da volatilidade*. Por exemplo, no modelo GARCH(1,1) dada pela equação (4), a persistência será dada pela soma dos coeficientes  $\alpha_1$  e  $\beta_1$ . Valores baixos (próximos de zero) para o coeficiente de persistência indicam que um choque inicial sobre a volatilidade irá

provocar efeitos rápidos sobre o comportamento da série e que, após curto período de tempo, a variância da série deverá convergir à sua média histórica.

Por outro lado, quanto maior (mais próximo de 1) for o valor do coeficiente de persistência, mais vagarosamente o choque sobre a volatilidade irá se enfraquecer e, portanto, maior será a demora do processo de reversão à média para a variância (LAMOUNIER, 2001).

Os modelos GARCH possuem as mesmas vantagens e desvantagens dos modelos ARCH. Volatilidades altas são precedidas de retornos ou volatilidades grandes, observando-se os grupos de volatilidade presentes em séries financeiras (MORETTIN, 2006).

Na análise do comportamento da variância condicional de algumas séries de ativos financeiros (como o preço de ações), alguns autores como Glosten *et al.* (1993) e Nelson (1991), constataram que a influência exercida por variações negativas nos preços sobre a volatilidade é maior do que a exercida por variações positivas de mesma magnitude.

Dessa forma, a variância condicional assimétrica pode ser representada formalmente por uma variação do modelo GARCH, conhecido como modelo TARARCH (“Threshold ARCH”). O modelo TARARCH possui a seguinte forma funcional:

$$h_t^\gamma = \alpha_0 + \alpha_1 g^{(\gamma)}(\varepsilon_{t-1}) + \beta_1 h_{t-1}^\gamma \quad (5)$$

em que

$$g^{(\gamma)}(\varepsilon_t) = \theta I_{\{\varepsilon_t > 0\}} |\varepsilon_t|^\gamma + (1 - \theta) I_{\{\varepsilon_t \leq 0\}} |\varepsilon_t|^\gamma \quad (6)$$

Para  $\gamma = 1$  temos o modelo de Zakoian (1994) e para  $\gamma = 2$  o modelo GJR (de Glosten, Jagannathan and Runkle, 1993).

O software EViews utiliza a seguinte formulação:

$$h_t = \omega + \alpha X_{t-1}^2 + \gamma X_{t-1}^2 d_{t-1} + \beta h_{t-1} \quad (7)$$

com

$$d_t = \begin{cases} 1, & \text{se } X_t < 0 \text{ (más notícias)} \\ 0, & \text{se } X_t \geq 0 \text{ (boas notícias)} \end{cases}$$

Dessa forma, choque positivos ( $X_t \geq 0$ ) e choque negativos ( $X_t < 0$ ) terão diferentes efeitos na variância condicional: choque positivos terão impacto dado por  $\alpha$  e choque negativos terão impacto dado por  $(\alpha + \gamma)$ . Se o coeficiente  $\gamma$  for significativamente diferente de zero, diz-se que a variância condicional é assimétrica. Assim,  $\gamma < 0$  indica que um choque positivo implica menor variabilidade do que um choque negativo de mesma magnitude.

Outra variação do modelo GARCH é o modelo EGARCH (“Exponential GARCH”) introduzido por Nelson (1991), este modelo apresenta duas vantagens em relação ao modelo GARCH: a incorporação dos efeitos assimétricos aos modelos auto-regressivos de volatilidade condicionada, e a não imposição artificial de restrições aos parâmetros da equação, dada a sua formulação em termos logarítmicos. Um modelo EGARCH(1,1) é dado por:

$$X_t = \sqrt{h_t} \varepsilon_t \quad (1)$$

$$\ln(h_t) = \alpha_0 + \alpha_1 g(\varepsilon_{t-1}) + \beta_1 \ln(h_{t-1}) \quad (8)$$

em que  $\varepsilon_t$  *i.i.d.* (0,1) e  $g(\cdot)$  é a curva de impacto de informação, dada por

$$g(\varepsilon_t) = \theta \varepsilon_t + \gamma \left\{ |\varepsilon_t| - E(|\varepsilon_t|) \right\} \quad (9)$$

Aqui,  $\theta$  e  $\gamma$  são parâmetros reais,  $|\varepsilon| - E(|\varepsilon|)$  é uma sequência de *v.a. i.i.d.* com média zero.

Note que pode-se escrever

$$g(\varepsilon_t) = \begin{cases} (\theta + \gamma)\varepsilon_t - \gamma E(|\varepsilon_t|), & \text{se } \varepsilon_t \geq 0, \\ (\theta - \gamma)\varepsilon_t - \gamma E(|\varepsilon_t|), & \text{se } \varepsilon_t < 0. \end{cases} \quad (10)$$

Esta assimetria permite que a volatilidade responda mais rapidamente a retornos negativos do que a positivos, fato este conhecido como “efeito alavanca”.

O software EViews considera o modelo EGARCH na seguinte forma:

$$\ln(h_t) = \omega + \beta \ln(h_{t-1}) + \alpha \frac{|X_{t-1}|}{\sqrt{h_t}} + \frac{\gamma X_{t-1}}{\sqrt{h_t}} \quad (11)$$

Antes de construir os modelos da família ARCH faz-se necessário definir em conjunto uma equação para a média condicional, ou seja, identificar um padrão de modelo ARIMA, uma vez que os erros gerados na equação da média são os insumos necessários à operacionalização dos cálculos da volatilidade condicionada.

Uma metodologia bastante utilizada na análise de modelos paramétricos é conhecida como abordagem de Box e Jenkins (1970), um ciclo iterativo dividido em três etapas, a saber: i) *identificação* de um modelo com base na análise de autocorrelação; ii) *estimação* do modelo identificado; iii) *diagnóstico* do modelo ajustado através de análise de resíduos.

A função de autocorrelação (*FAC*) é dada por:

$$r_j = \frac{c_j}{c_0}, \text{ com } j = 0, 1, \dots, N-1 \quad (12)$$

Onde  $c_j$  é a estimativa da auto-covariância amostral.

E a função de autocorrelação parcial (*FACP*) é dada por:

$$\phi_{kk} = \frac{|P_k^*|}{|P_k|} \quad (13)$$

Onde  $P_k$  é a matriz de autocorrelações e  $P_k^*$  é a matriz  $P_k$  com a última coluna substituída pelo vetor de autocorrelações.

Conforme Morettin (2006) as características apresentadas pela *FAC* e *FACP* para os processos são:

- (i) um processo  $AR(p)$  tem *FAC* que decai de acordo com exponenciais e/ou senóides amortecidas, infinita em extensão; *FACP*  $\phi_{kk} \neq 0$ , para  $k \leq p$  e  $\phi_{kk} = 0$ , para  $k > p$ ;
- (ii) um processo  $MA(q)$  tem *FAC* finita, no sentido que ela apresenta um corte após o *lag*  $q$ ; *FACP* se comporta de maneira similar à *FAC* de um processo  $AR(p)$ : é denominada por exponenciais e/ou senóides amortecidas;
- (iii) um processo  $ARMA(p, q)$  tem *FAC* infinita em extensão, a qual decai de acordo com exponenciais e/ou senóides amortecidas após o *lag*  $q-p$ ; *FACP* se comporta como *FACP* de um processo  $MA$  puro.

Após o ajuste do modelo deve-se ter um vetor de resíduos com características de um processo de inovação com média zero, variância finita e não correlacionados. Estas condições podem ser verificadas através de um teste para as autocorrelações dos resíduos ( $H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$ ), o teste  $Q$  de Ljung e Box (1978). A estatística associada ao teste é dada por:

$$Q(K) = n(n+2) \sum_{j=1}^K \frac{r_j^2}{(n-j)} \quad (14)$$

Se o modelo for apropriado, a estatística  $Q$  terá aproximadamente uma distribuição  $\chi^2$  com  $K - p - q$  graus de liberdade.

Complementar ao teste  $Q$ , tem-se o teste Multiplicador de Lagrange de Engle (1982). Este teste verifica a presença de heterocedasticidade condicional nos resíduos baseado na estatística-F dada por:

$$F = \frac{(SQR_0 - SQR_1) / r}{SQR_1 / (N - 2r - 1)} \sim F(r, N - 2r - 1) \quad (15)$$

Sendo que

$$SQR_0 = \sum_{t=r+1}^N (X_t^2 - \bar{X})^2 \quad (16)$$

e

$$SQR_1 = \sum_{t=r+1}^N \hat{u}_t^2 \quad (17)$$

Onde  $\bar{X}$  é a média amostral dos  $X_t^2$  e  $\hat{u}_t$  os resíduos de MQ da regressão. Se o valor F for significativo, dizemos que há heterocedasticidade condicional na série.

Séries temporais financeiras são frequentemente afetadas não somente por alterações no direcionamento dos instrumentos de política econômica, mas também por fatores externos. Esses eventos não podem ser desconsiderados, sob risco de se obter modelos estruturais inadequados, com a conseqüente perda de seu poder de previsão.

Denominado por *intervenção* por Box e Tiao (1975) a ocorrência de algum tipo de evento num dado instante de tempo  $T$ , conhecido *a priori*, evento que pode manifestar-se por um intervalo de tempo subsequente e afetar temporariamente ou permanentemente uma série.

A *análise de intervenção* tem por objetivo avaliar o impacto de tal evento no comportamento da série. Basicamente duas são as estruturas no caso da análise de intervenção: *função impulso*, representada por  $P_t^T$  e *função degrau*, representada por  $S_t^T$ . A primeira corresponde a uma variável *dummy* onde assume-se valor 1 na ocorrência do evento e valor zero caso contrário enquanto que a segunda assume valor zero antes do evento e valor 1 após o evento.

Função degrau

$$I_{j,t} = S_t^T = \begin{cases} 0, & t < T \\ 1, & t \geq T \end{cases}$$

Função impulso

$$I_{j,t} = P_t^T = \begin{cases} 0, & t \neq T \\ 1, & t = T \end{cases}$$

Quanto aos critérios utilizados na escolha do modelo que possui melhor ajuste, tem-se que:

Critério de Informação de Akaike (*AIC*), critério que procura escolher quantidades  $k$  e  $l$  no modelo de modo a minimizar uma certa quantidade. Para maiores informações veja Akaike (1973,1974). Sua formulação é dada por:

$$AIC(k,l) = \ln \hat{\sigma}_{k,l}^2 + \frac{2(k+l)}{N} \tag{18}$$

*Assimetria e Curtose*. Seja  $X$  uma variável aleatória qualquer, com média  $\mu$  e variância  $\sigma^2$ . Então a assimetria de  $X$  é definida por:

$$A(X) = E\left(\frac{(X - \mu)^3}{\sigma^3}\right) \tag{19}$$

Enquanto que a curtose de  $X$  é definida por:

$$K(X) = E\left(\frac{(X - \mu)^4}{\sigma^4}\right) \tag{20}$$

Para uma distribuição Normal,  $A = 0$  e  $K = 3$ , de modo que a quantidade  $K(X)-3$  é chamada excesso de curtose. Distribuições com caudas pesadas possuem curtose maior do que 3 e esta pode mesmo ser infinita.

### 3. DESCRIÇÃO DOS DADOS

A série de dados do presente trabalho refere-se a pontuação de fechamento diário do índice setorial *INDX* da Bolsa de Valores de São Paulo, dos pregões compreendidos entre os dias 01/01/2000 e 30/04/2011, perfazendo um total de 2.804 observações<sup>3</sup>. Para análise da volatilidade, a série *INDX* foi transformada e diferenciada por intermédio da equação  $r_t = \ln(P_t) - \ln(P_{t-1})$  resultando em uma série de retornos com 2.803 observações<sup>4</sup>. A estimação dos parâmetros e cálculos dos modelos foram efetuadas com o auxílio do software EViews 5.




Figura 1: (a) Série diária do índice *INDX* no período de 03/01/2000 a 29/04/2011. (b) Respetiva série diária de retornos.

Fonte: Elaboração própria a partir dos dados coletados junto ao site da BM&FBOVESPA.

A figura 1 acima ilustra o comportamento da série *INDX* e sua respectiva série de retornos para o período analisado. Observa-se que a série original apresenta um comportamento típico de série financeira, com característica tendenciosa, sugerindo que a série seja um processo não estacionário em média e nem em variância. Para confirmar a não estacionariedade da série, foi realizado o teste de *Dickey-Fuller* cujos resultados podem ser visto na tabela 1. Aos níveis de significância 1, 5 e 10%, não rejeitamos  $H_0$  ( $H_0$ : série não estacionária).

estatística de teste	nível significância	valor crítico
1,005	1%	-2,5658
	5%	-1,9409
	10%	-1,6166

Tabela 1: Teste Dickey-Fuller série de dados *INDX*.

Fonte: Elaboração do autor a partir dos resultados estimados por software EViews 5.

<sup>3</sup> Os dados foram coletados junto ao site da BM&FBOVESPA.

<sup>4</sup>  $P_t$  designa-se a pontuação de fechamento para um dia de negócio.



Das principais estatísticas que descrevem uma série temporal, tem-se que a pontuação de fechamento diário média do índice *INDX* é de 5.175,47 pontos com desvio padrão de 3.463,04 pontos. Já para a série de retornos, por meio do teste de normalidade proposto por *Jarque e Bera* (1987) pode-se verificar que assimetria e curtose são fortemente significativas conforme resultados apresentados na tabela 2. Na figura 2 temos os histogramas nos quais se pode-se ver a presença de valores bem afastados da parte central das distribuições (caudas longas).

Estatísticas	Série	
	INDX	Retorno INDX
Média	5.175,47	0,0008
Mediana	4.649,66	0,0017
Máximo	12.271,56	0,1183
Mínimo	807,85	-0,1182
Desvio Padrão	3.463,05	0,0162
Assimetria	0,31	-0,3277
Curtose	1,67	9,0372
Jarque-Bera	250,84	4.306,94
<i>probability</i>	0	0

Tabela 2: Estatísticas descritivas da série *INDX* e sua respectiva série de retornos.

Fonte: Elaboração do autor a partir dos resultados estimados por software EViews 5.




Figura 2: (c) Histograma da série *INDX*; (d) Histograma da série de retornos (EViews 5).

Os correlogramas seguem no quadro 1, para a série *INDX* tem-se que a FAC (Função de Auto Correlação) apresenta-se com decaimento lento indicando que a série seja um

processo não estacionário, já a FACP (Função de Auto Correlação Parcial) indica que o processo trata-se de um auto regressivo de ordem 1.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob		
*****	*****	1	0.998	0.998	2796.1	0.000			1	0.056	0.056	8.6596	0.003
*****		2	0.996	-0.014	5582.1	0.000			2	-0.008	-0.011	8.8237	0.012
*****		3	0.994	-0.000	8358.0	0.000			3	-0.047	-0.046	15.056	0.002
*****		4	0.992	0.022	11124.0	0.000			4	-0.017	-0.012	15.863	0.003
*****		5	0.990	0.003	13881.0	0.000			5	0.026	0.027	17.713	0.003
*****		6	0.988	-0.003	16628.0	0.000			6	-0.019	-0.025	18.749	0.005
*****		7	0.986	-0.008	19366.0	0.000			7	0.003	0.005	18.780	0.009
*****		8	0.985	-0.004	22094.0	0.000			8	0.037	0.039	22.583	0.004
*****		9	0.983	-0.021	24811.0	0.000			9	0.011	0.006	22.937	0.006
*****		10	0.981	0.002	27519.0	0.000			10	0.045	0.043	28.527	0.001
*****		11	0.979	0.007	30216.0	0.000			11	0.002	0.002	28.542	0.003
*****		12	0.977	-0.001	32904.0	0.000			12	0.023	0.025	30.049	0.003
*****		13	0.975	-0.012	35582.0	0.000			13	0.012	0.012	30.429	0.004
*****		14	0.973	0.003	38249.0	0.000			14	0.002	0.004	30.439	0.007
*****		15	0.971	-0.001	40907.0	0.000			15	-0.011	-0.011	30.788	0.009
*****		16	0.969	-0.002	43555.0	0.000			16	0.052	0.056	38.402	0.001
*****		17	0.967	-0.023	46192.0	0.000			17	0.035	0.027	41.765	0.001
*****		18	0.964	-0.006	48819.0	0.000			18	-0.029	-0.036	44.123	0.001
*****		19	0.962	-0.002	51435.0	0.000			19	-0.030	-0.022	46.585	0.000
*****		20	0.960	0.028	54042.0	0.000	*		20	0.066	0.071	58.914	0.000
*****		21	0.958	-0.016	56638.0	0.000			21	0.004	-0.011	58.967	0.000
*****		22	0.956	-0.004	59224.0	0.000			22	0.010	0.005	59.236	0.000
*****		23	0.954	-0.021	61799.0	0.000			23	-0.003	0.005	59.258	0.000
*****		24	0.952	-0.018	64364.0	0.000			24	0.020	0.018	60.371	0.000

(a)

(b)

Quadro 1: (a) Correlograma da FAC e FACP dos resíduos padronizados da série *INDX*, (b) Correlograma da FAC e FACP dos resíduos padronizados da série de retornos (EViews 5).

A FAC estimada para a série de retornos revela um padrão para a média condicional, um AR(20), evidenciando também a presença de efeitos ARCH na volatilidade do mesmo. Objetivando confirmar tal evidência, efetuou-se o teste *Multiplicador de Lagrange – ARCH LM test* nos resíduos dos modelos AR ajustado para a média condicional.

Os p-valores observados indicam forte presença de autocorrelação dos resíduos, sugerindo desta forma rejeição da hipótese nula de homocedasticidade na série de retornos. Os p-valores dos testes seguem reportados na tabela 3.

Modelo para a média	Probabilidade estatística-F		
	Lag 1	Lag 5	Lag 10
AR(20)	0	0	0
C AR(20)	0	0	0
C AR(1) AR(20)	0	0	0

Tabela 3: Probabilidades da estatística-F para o teste Multiplicador de Lagrange aplicado em modelos para média.

Fonte: Elaboração do autor a partir dos resultados estimados por software EViews 5.

Confirmada a presença de heterocedasticidade condicional auto-regressiva na série de retornos, foram construídos os modelos para a volatilidade (os modelos foram construídos com erros gaussianos) cujos resultados seguem abaixo na tabela 4. A definição do período para inserção da variável indicadora de intervenção foi o comportamento da série conforme análise da figura 3 abaixo, período: 30/05/2008 a 30/12/2008.




Figura 3: (a) Série diária do índice *INDX* no período de 03/01/2000 a 29/04/2011. (b) Respectiva série diária de retornos.

## 4. ANÁLISE DOS RESULTADOS

Os sete modelos apresentados encontram-se estatisticamente bem ajustados e com coeficientes significativamente diferentes de zero. A ausência de heteroscedasticidade condicional nos resíduos dos modelos foram comprovados através do teste *Multiplicador de Lagrange* cujos resultados seguem anexo.

<b>Média</b>	<b>AR</b>	<b>AR</b>	<b>AR</b>	<b>AR</b>	<b>AR</b>	<b>AR</b>	<b>AR</b>
Constante	0,001333	0,001430	0,001375	0,001440	0,000860	0,000903	0,000995
Intervenção	-	-0,0055	-	-0,0051	-	-0,0038	-
AR(1)	0,0603	0,0488	0,0617	0,0590	0,0718	0,0685	0,0690
AR(20)	0,0537	0,0505	-	-	-	-	-
<b>Variância</b>	<b>ARCH(3)</b>	<b>ARCH(3)</b>	<b>GARCH(1,1)</b>	<b>GARCH(1,1)</b>	<b>EGARCH(1,1)</b>	<b>EGARCH(1,1)</b>	<b>TARCH(1,1)</b>
Constante	0,000124	0,000122	0,000008	0,000007	-0,423824	-0,415434	0,000009
$X^2_{t-1}$	0,1580	0,1562	0,1040	0,1024	-	-	0,0348
$X^2_{t-2}$	0,1837	0,1948	-	-	-	-	-
$X^2_{t-3}$	0,1600	0,1586	-	-	-	-	-
$h_{t-1}$	-	-	0,8639	0,8660	-	-	0,8670
$ \varepsilon_{t-1} $	-	-	-	-	0,1811	0,1858	-
$\varepsilon_{t-1}$	-	-	-	-	-0,0758	-0,0727	-
$\ln(h_{t-1})$	-	-	-	-	0,9668	0,9682	-
$X^2_{t-1} d_{t-1}$	-	-	-	-	-	-	0,1097

Tabela 4: Estimação dos modelos.

Fonte: Elaboração do autor a partir dos resultados estimados por software EViews 5.

Entre os modelos ajustados, ARCH(3), GARCH(1,1) e EGARCH(1,1), aqueles que possuem variáveis indicadoras de intervenção retornaram melhores resultados no que refere-se aos critérios de qualidade de ajuste do modelo como pode ser visto na tabela 5.

Entre os modelos que tratam simetricamente a volatilidade dos retornos, modelos ARCH e GARCH, os resultados obtidos para os modelos ARCH, foram os de menor desempenho quanto aos critérios de qualidade. Entre todos os modelos ajustados, estes apresentaram as maiores curtoses.

Os resultados obtidos para os modelos GARCH(1,1), com e sem intervenção, retornaram resultados semelhantes, a soma dos parâmetros  $\alpha_1$  e  $\beta_1$  foi igual a 0.97, indicando que um choque na série de retornos terá efeito por vários períodos na volatilidade dos mesmos. Entre os modelos ARCH(3) e GARCH(1,1) este último apresentou melhores ajustes.

Os resultados obtidos para os modelos EGARCH(1,1) evidenciam a assimetria na volatilidade dos retornos através do coeficiente  $\varepsilon_{t-1}$  significativo, confirmando assim que

choques positivos e negativos tem impactos distintos sobre a volatilidade. A persistência de choques na volatilidade dos retornos, captada pelo termo  $\ln(h_{t-1})$  foi igual a 0.97, mesmo valor captado pelos modelos GARCH(1,1). Entre os modelos ARCH(3), GARCH(1,1) e EGARCH(1,1) este último apresentou melhores ajustes.

Os resultados obtidos para o modelo TARCH(1,1) confirmam a assimetria evidenciada pelos modelos EGARCH(1,1), posto que o parâmetro associado ao termo  $X_{t-1}^2 d_{t-1}$  mostrou-se significativamente diferente de zero indicando assim que choques negativos causam maior volatilidade nos retornos do que choques positivos. Entre todos os modelos ajustados, o modelo TARCH(1,1) foi o modelo que apresentou melhores ajustes.

Indicadores	C	C I	C	C I	C	C I	C
	AR(1)AR(20)	AR(1)AR(20)	AR(1)	AR(1)	AR(1)	AR(1)	AR(1)
	ARCH(3)	ARCH(3)	GARCH(1,1)	GARCH(1,1)	EGARCH(1,1)	EGARCH(1,1)	TARCH(1,1)
Assimetria	-0,1156	-0,0638	-0,2380	-0,2271	-0,2172	-0,2125	-0,2045
Curtose	4,7397	4,7827	3,8539	3,8799	3,8512	3,8719	3,7423
$\ln(L)$	7.799,67	7.803,56	7.948,19	7.950,81	7.963,30	7.964,06	7.968,99
SQR	0,7290	0,7238	0,7366	0,7309	0,7361	0,7317	0,7361
AIC	-5,6002	-5,6023	-5,6697	-5,6708	-5,6797	-5,6796	-5,6838

Tabela 5: Medidas de qualidade do ajuste do modelo.

Fonte: Elaboração do autor a partir dos resultados estimados por software EViews 5.

Notas:

1.  $\ln(L)$ : log da verossimilhança.
2. SQR: Soma de Quadrados dos Resíduos.
3. AIC: Critério de Informação Akaike.

## **5. CONCLUSÃO**

O resultado obtido com a análise da volatilidade do índice INDX comprova através do seu melhor modelo, TARCH(1,1) que a volatilidade reage de modo diferente a retornos positivos e negativos, evidenciando que choques negativos causam maior volatilidade do que choque positivos.

## 6. REFERÊNCIA BIBLIOGRÁFICA

- BM&FBOVESPA. *Bolsa de Mercadorias e Futuros (BM&F) e Bolsa de Valores de São Paulo (BOVESPA): INDX*. Disponível em: < <http://www.bmfbovespa.com.br/Indices/download/INDX.pdf> >.  
[Acesso em: 2011 maio 31]
- BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics* **31**, pp. 307-327, 1986.
- BOX, G.E.P.; TIAO, G.C. Intervention Analysis with Applications to Economic and Environmental Problems. *Journal of the American Statistical Association*, v. 70, n. 349, pp. 70-79, Mar. 1975.
- CERETTA, P. S.; COSTA JR., N.C.A. da. Influência de eventos positivos e negativos sobre a volatilidade dos mercados na América Latina. *Cadernos de Pesquisa em Administração*, v.1, n.10, p. 35-41, 3º trim. 1999.
- DICKEY, David A.; FULLER, Wayne A. Distribution of the estimators for autoregressive time series with unit root. *Journal of the American Statistical Association*, Washington, v. 74, n. 366, p. 427-431, Jun. 1979.
- DICKEY, David A.; FULLER, Wayne A. Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica*, Chicago, v. 49, n. 4, p. 1057-1072, Jul. 1981.
- ENGLE, R. F. Autoregressive conditional heteroskedasticity with estimates of the variance of the United Kingdom inflation. *Econometrica*, v. 50, n. 4, pp. 987-1007, Jul. 1982.
- FIESP-DEPECON. **INDX – Análise Mensal**. Dados de setembro de 2008, número 21, São Paulo [online]. Disponível em: <[http://www.fiesp.com.br/economia/pdf/indx\\_setembro08.pdf](http://www.fiesp.com.br/economia/pdf/indx_setembro08.pdf)>. [Acesso em: 2011 maio 31].
- FIESP. **Macro Visão**. Informativo eletrônico – edição 137 – 16 de setembro de 2008 [online]. Disponível em: <<http://www.fiesp.com.br/newsletter/macro-visao/info-137.htm>>. [Acesso em: 2011 maio 31].
- FOLHA.COM. **Entenda a evolução da crise que atinge a economia dos EUA** [Internet]. Folha Online; 2008 Outubro 06. Disponível em:< <http://www1.folha.uol.com.br/folha/dinheiro/ult91u453003.shtml> >. [Acesso em: 2011 maio 31].
- GLOSTEN, L.R., JAGANNATHAN, R., RUNKLE, D. On the relation between the expected value and the volatility of the normal excess return on stocks. *Journal of Finance*, v. 48, p.1779-1801, 1993.
- GONTIJO, Cláudio; OLIVEIRA, Fabrício Augusto de. **Subprime: os 100 dias que abalaram o capital financeiro mundial e os efeitos da crise sobre o Brasil**. Belo Horizonte: [s.n.], 2009. 169 p.
- JARQUE C. M.; BERA A. A. A test for normality of observations and regression residuals. *International Statistical Review*, v.55, n.2, p. 163-172, Aug. 1987.
- LAMOUNIER, Wagner M. **Comportamento dos preços no mercado “spot” de café do Brasil: análise nos domínios do tempo e da frequência. 2001**. Tese (Doutorado) – Universidade Federal de Viçosa, Viçosa, 2001. Disponível em: <<http://www.sbicafe.ufv.br/bitstream/handle/10820/3169/166697f.pdf?sequence=1>>. [Acesso em: 2011 agosto 01].
- MORAES, Márcia Soman. Bush queria ser libertador, mas acabou marcado por guerras e crise [Internet]. Folha Online; 2009 Janeiro 15. Disponível em: < <http://www1.folha.uol.com.br/folha/mundo/ult94u489954.shtml> >. [Acesso em: 2011 maio 31].
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgard Blucher, 2006. 535p.
- NELSON, D.B. Conditional heteroskedasticity in asset returns: a new approach. *Econometrica*, v. 59, p. 347-370, 1991.

## **ANEXO**



## ANEXO 1 – REPRESENTAÇÃO DOS MODELOS

### Modelo 1 : Retorno ~ C I<sub>t</sub> AR(1) AR(20) ARCH(3)

$$Y_t = 0,0014 - 0,0055I_t + 0,0488Y_{t-1} + 0,0505Y_{t-20} + X_t \quad X_t = \sqrt{h_t}\varepsilon_t$$

$$\text{onde } I_t = \begin{cases} 1 & 2083 \leq t \leq 2231 \\ 0 & \text{c.c.} \end{cases}$$

$$h_t = 0,00012 + 0,1562X_{t-1}^2 + 0,1948X_{t-2}^2 + 0,1586X_{t-3}^2$$

### Modelo 2: Retorno ~ C AR(1) AR(20) ARCH(3)

$$Y_t = 0,0013 + 0,0603Y_{t-1} + 0,0536Y_{t-20} + X_t \quad X_t = \sqrt{h_t}\varepsilon_t$$

$$h_t = 0,00012 + 0,158X_{t-1}^2 + 0,1837X_{t-2}^2 + 0,16X_{t-3}^2$$

### Modelo 3: Retorno ~ C I<sub>t</sub> AR(1) GARCH(1,1)

$$Y_t = 0,0014 - 0,0051I_t + 0,059Y_{t-1} + X_t \quad X_t = \sqrt{h_t}\varepsilon_t$$

$$\text{onde } I_t = \begin{cases} 1 & 2083 \leq t \leq 2231 \\ 0 & \text{c.c.} \end{cases}$$

$$h_t = 0,00000746 + 0,1024X_{t-1}^2 + 0,866h_{t-1}$$

### Modelo 4: Retorno ~ C AR(1) GARCH(1,1)

$$Y_t = 0,0014 + 0,0617Y_{t-1} + X_t \quad X_t = \sqrt{h_t}\varepsilon_t$$

$$h_t = 0,0000076 + 0,104X_{t-1}^2 + 0,864h_{t-1}$$

### Modelo 5: Retorno ~ C I<sub>t</sub> AR(1) EGARCH(1,1)

$$Y_t = 0,0009 - 0,0038I_t + 0,0685Y_{t-1} + X_t \quad X_t = \sqrt{h_t}\varepsilon_t$$

$$\text{onde } I_t = \begin{cases} 1 & 2083 \leq t \leq 2231 \\ 0 & \text{c.c.} \end{cases}$$

$$\ln(h_t) = -0,4154 + 0,9682\ln(h_{t-1}) + 0,1858|\varepsilon_{t-1}| - 0,0727\varepsilon_{t-1}$$

### Modelo 6: Retorno ~ C AR(1) EGARCH(1,1)

$$Y_t = 0,00086 + 0,0717Y_{t-1} + X_t \quad X_t = \sqrt{h_t}\varepsilon_t$$

$$\ln(h_t) = -0,4238 + 0,9668\ln(h_{t-1}) + 0,1811|\varepsilon_{t-1}| - 0,0758\varepsilon_{t-1}$$

### Modelo 7: Retorno ~ C AR(1) TARCH(1,1)

$$Y_t = 0,000995 + 0,069Y_{t-1} + X_t \quad X_t = \sqrt{h_t}\varepsilon_t$$

$$h_t = 0,00000865 + 0,0348X_{t-1}^2 + 0,1097X_{t-1}^2d_{t-1} + 0,8699h_{t-1}$$

## ANEXO 2 – RESULTADOS DO MODELO 1: Retorno ~ C I AR(1) AR(20) ARCH(3)

Dependent Variable: RETORNO  
 Method: ML - ARCH (Marquardt) - Normal distribution  
 Date: 06/18/11 Time: 18:28  
 Sample (adjusted): 22 2804  
 Included observations: 2783 after adjustments  
 Convergence achieved after 17 iterations  
 Variance backcast: ON  
 GARCH = C(5) + C(6)\*RESID(-1)^2 + C(7)\*RESID(-2)^2 + C(8)\*RESID(-3)^2

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001430	0.000299	4.791544	0.0000
I	-0.005524	0.000903	-6.115671	0.0000
AR(1)	0.048765	0.019664	2.479866	0.0131
AR(20)	0.050513	0.013057	3.868703	0.0001
Variance Equation				
C	0.000122	4.44E-06	27.53129	0.0000
RESID(-1)^2	0.156238	0.015775	9.904143	0.0000
RESID(-2)^2	0.194793	0.022091	8.817748	0.0000
RESID(-3)^2	0.158626	0.020820	7.618986	0.0000
R-squared	0.014000	Mean dependent var	0.000857	
Adjusted R-squared	0.011513	S.D. dependent var	0.016244	
S.E. of regression	0.016150	Akaike info criterion	-5.602269	
Sum squared resid	0.723803	Schwarz criterion	-5.585219	
Log likelihood	7803.557	F-statistic	5.628997	
Durbin-Watson stat	1.994279	Prob(F-statistic)	0.000002	

**Quadro 1:** Ajuste do modelo 1 (EViews 5).

Estimation Command:

ARCH(3,0,ASY=1,DERIV=AN) RETORNO C I AR(1) AR(20)

Estimation Equation:

RETORNO = C(1) + C(2)\*I + [AR(1)=C(3),AR(20)=C(4)]

GARCH = C(5) + C(6)\*RESID(-1)^2 + C(7)\*RESID(-2)^2 + C(8)\*RESID(-3)^2

Substituted Coefficients:

RETORNO = 0.001430392344 - 0.005524299396\*I + [AR(1)=0.04876482587,AR(20)=0.05051335563]

GARCH = 0.0001221647052 + 0.1562378361\*RESID(-1)^2 + 0.1947925111\*RESID(-2)^2 + 0.1586261639\*RESID(-3)^2

**Quadro 2:** Representação do modelo 1 (EViews 5).

ARCH Test:

F-statistic	0.401176	Probability	0.526535
Obs*R-squared	0.401406	Probability	0.526364

Test Equation:

Dependent Variable: STD\_RESID^2  
 Method: Least Squares  
 Date: 06/07/11 Time: 15:25  
 Sample (adjusted): 23 2804  
 Included observations: 2782 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.011669	0.041496	24.37978	0.0000
STD_RESID^2(-1)	-0.012012	0.018964	-0.633384	0.5265
R-squared	0.000144	Mean dependent var	0.999654	
Adjusted R-squared	-0.000215	S.D. dependent var	1.946413	
S.E. of regression	1.946622	Akaike info criterion	4.170787	
Sum squared resid	10534.36	Schwarz criterion	4.175051	
Log likelihood	-5799.565	F-statistic	0.401176	
Durbin-Watson stat	2.000341	Prob(F-statistic)	0.526535	

**Quadro 3:** Teste Multiplicador de Lagrange – ARCH LM Test (EViews 5).

(a)						(b)						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.020	0.020	1.0850			1	-0.012	-0.012	0.4030	
		2	0.018	0.018	1.9792			2	-0.026	-0.026	2.3228	
		3	-0.042	-0.043	6.9759	0.008		3	-0.038	-0.039	6.4485	0.011
		4	-0.009	-0.008	7.2107	0.027		4	0.041	0.039	11.101	0.004
		5	-0.001	0.000	7.2161	0.065	*	5	0.072	0.071	25.468	0.000
		6	-0.008	-0.010	7.4085	0.116		6	0.063	0.066	36.562	0.000
		7	-0.001	-0.002	7.4146	0.192		7	0.052	0.061	44.035	0.000
		8	0.003	0.003	7.4387	0.282		8	0.025	0.034	45.718	0.000
		9	0.025	0.024	9.1966	0.239		9	0.024	0.028	47.386	0.000
		10	0.036	0.035	12.882	0.116	*	10	0.117	0.116	85.629	0.000
		11	0.000	-0.002	12.882	0.168		11	0.063	0.061	96.713	0.000
		12	-0.000	0.001	12.883	0.230		12	0.040	0.040	101.08	0.000
		13	-0.007	-0.003	13.004	0.293		13	0.026	0.030	102.91	0.000
		14	0.009	0.010	13.252	0.351		14	0.009	0.001	103.14	0.000
		15	-0.018	-0.018	14.131	0.365	*	15	0.082	0.064	121.92	0.000
		16	0.024	0.024	15.698	0.332		16	0.047	0.028	128.18	0.000
		17	0.013	0.013	16.147	0.372		17	0.054	0.035	136.21	0.000
		18	-0.017	-0.021	16.976	0.387		18	0.054	0.047	144.44	0.000
		19	-0.013	-0.012	17.416	0.427		19	0.029	0.020	146.87	0.000
		20	-0.010	-0.009	17.707	0.475		20	0.024	0.002	148.50	0.000
		21	-0.010	-0.010	17.967	0.525		21	0.045	0.022	154.29	0.000
		22	-0.013	-0.014	18.469	0.557	*	22	0.066	0.041	166.51	0.000
		23	0.000	0.000	18.469	0.619		23	0.038	0.018	170.67	0.000
		24	0.020	0.019	19.568	0.610		24	-0.008	-0.023	170.85	0.000

(a)

(b)

**Quadro 4:** (a) Correlograma FAC e FACP dos resíduos padronizados do modelo 1; (b) Correlograma FAC e FACP dos quadrados dos resíduos padronizados do modelo 1 (EViews 5).

**ANEXO 3 – RESULTADOS DO MODELO 2 : Retorno ~ C AR(1) AR(20) ARCH(3)**

Dependent Variable: RETORNO  
 Method: ML - ARCH (Marquardt) - Normal distribution  
 Date: 06/18/11 Time: 18:35  
 Sample (adjusted): 22 2804  
 Included observations: 2783 after adjustments  
 Convergence achieved after 13 iterations  
 Variance backcast: ON  
 GARCH = C(4) + C(5)\*RESID(-1)^2 + C(6)\*RESID(-2)^2 + C(7)\*RESID(-3)^2

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001333	0.000291	4.573283	0.0000
AR(1)	0.060297	0.019568	3.081439	0.0021
AR(20)	0.053657	0.012221	4.390652	0.0000

Variance Equation				
C	0.000124	4.11E-06	30.01936	0.0000
RESID(-1)^2	0.158021	0.015145	10.43411	0.0000
RESID(-2)^2	0.183742	0.020406	9.004517	0.0000
RESID(-3)^2	0.160048	0.020746	7.714783	0.0000

R-squared	0.006930	Mean dependent var	0.000857
Adjusted R-squared	0.004783	S.D. dependent var	0.016244
S.E. of regression	0.016205	Akaike info criterion	-5.600190
Sum squared resid	0.728993	Schwarz criterion	-5.585272
Log likelihood	7799.665	F-statistic	3.228498
Durbin-Watson stat	2.002617	Prob(F-statistic)	0.003660

**Quadro 1:** Ajusto do modelo 2 (EViews 5).

Estimation Command:  
 =====  
 ARCH(3,0,DERIV=AA) RETORNO C AR(1) AR(20)

Estimation Equation:  
 =====  
 RETORNO = C(1) + [AR(1)=C(2),AR(20)=C(3)]

GARCH = C(4) + C(5)\*RESID(-1)^2 + C(6)\*RESID(-2)^2 + C(7)\*RESID(-3)^2

Substituted Coefficients:  
 =====  
 RETORNO = 0.001333034603 + [AR(1)=0.0602965841,AR(20)=0.05365713518]

GARCH = 0.0001235072228 + 0.1580208292\*RESID(-1)^2 + 0.1837417468\*RESID(-2)^2 + 0.160047911\*RESID(-3)^2

**Quadro 2:** Representação do modelo 2 (EViews 5).

ARCH Test:

F-statistic	0.534869	Probability	0.464629
Obs*R-squared	0.535151	Probability	0.464449

Test Equation:

Dependent Variable: STD\_RESID^2

Method: Least Squares

Date: 06/07/11 Time: 16:13

Sample (adjusted): 23 2804

Included observations: 2782 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.013527	0.041333	24.52079	0.0000
STD_RESID^2(-1)	-0.013869	0.018964	-0.731347	0.4646

R-squared	0.000192	Mean dependent var	0.999655
Adjusted R-squared	-0.000167	S.D. dependent var	1.936818
S.E. of regression	1.936979	Akaike info criterion	4.160855
Sum squared resid	10430.25	Schwarz criterion	4.165119
Log likelihood	-5785.750	F-statistic	0.534869
Durbin-Watson stat	2.000344	Prob(F-statistic)	0.464629

**Quadro 3:** Teste Multiplicador de Lagrange – ARCH LM Test (EViews 5).

Autocorrelation						Autocorrelation							
Partial Correlation		AC	PAC	Q-Stat	Prob	Partial Correlation		AC	PAC	Q-Stat	Prob		
		1	0.013	0.013	0.4449			1	-0.014	-0.014	0.5373		
		2	0.022	0.022	1.7786			2	-0.022	-0.023	1.9346		
		3	-0.040	-0.041	6.2769	0.012			3	-0.038	-0.039	6.0432	0.014
		4	-0.005	-0.005	6.3527	0.042			4	0.044	0.043	11.557	0.003
		5	0.000	0.002	6.3530	0.096			5	0.090	0.090	34.276	0.000
		6	-0.008	-0.010	6.5457	0.162			6	0.057	0.061	43.370	0.000
		7	0.002	0.002	6.5557	0.256			7	0.052	0.062	50.882	0.000
		8	0.004	0.005	6.6069	0.359			8	0.025	0.036	52.671	0.000
		9	0.027	0.026	8.6416	0.279			9	0.033	0.034	55.663	0.000
		10	0.040	0.039	13.026	0.111			10	0.115	0.112	92.865	0.000
		11	0.004	0.002	13.066	0.160			11	0.054	0.051	101.07	0.000
		12	0.003	0.003	13.093	0.219			12	0.046	0.044	106.98	0.000
		13	-0.003	0.000	13.115	0.286			13	0.027	0.030	109.04	0.000
		14	0.011	0.012	13.481	0.335			14	0.001	-0.011	109.04	0.000
		15	-0.011	-0.011	13.837	0.385			15	0.100	0.079	137.27	0.000
		16	0.027	0.027	15.822	0.324			16	0.038	0.018	141.23	0.000
		17	0.015	0.015	16.438	0.354			17	0.072	0.052	155.57	0.000
		18	-0.014	-0.017	16.986	0.386			18	0.049	0.045	162.33	0.000
		19	-0.009	-0.009	17.217	0.440			19	0.031	0.019	164.94	0.000
		20	-0.011	-0.010	17.552	0.486			20	0.034	0.010	168.10	0.000
		21	-0.007	-0.008	17.689	0.543			21	0.042	0.020	173.10	0.000
		22	-0.011	-0.011	18.016	0.586			22	0.071	0.043	187.38	0.000
		23	0.001	0.000	18.018	0.648			23	0.034	0.013	190.61	0.000
		24	0.021	0.020	19.251	0.630			24	-0.014	-0.031	191.16	0.000

(a)

(b)

**Quadro 4:** (a) Correlograma FAC e FACP dos resíduos padronizados do modelo 2; (b) Correlograma FAC e FACP dos quadrados dos resíduos padronizados do modelo 2 (EViews 5).

## ANEXO 4 – RESULTADOS DO MODELO 3 : Retorno ~ C I, AR(1) GARCH(1,1)

Dependent Variable: RETORNO  
 Method: ML - ARCH (Marquardt) - Normal distribution  
 Date: 06/18/11 Time: 18:39  
 Sample (adjusted): 3 2804  
 Included observations: 2802 after adjustments  
 Convergence achieved after 12 iterations  
 Variance backcast: ON  
 GARCH = C(4) + C(5)\*RESID(-1)^2 + C(6)\*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001440	0.000267	5.401000	0.0000
I	-0.005123	0.001571	-3.261010	0.0011
AR(1)	0.058980	0.020536	2.872096	0.0041

Variance Equation				
C	7.46E-06	1.25E-06	5.976632	0.0000
RESID(-1)^2	0.102425	0.009321	10.98853	0.0000
GARCH(-1)	0.866036	0.011560	74.91352	0.0000

R-squared	0.009808	Mean dependent var	0.000848
Adjusted R-squared	0.008037	S.D. dependent var	0.016234
S.E. of regression	0.016168	Akaike info criterion	-5.670814
Sum squared resid	0.730910	Schwarz criterion	-5.658099
Log likelihood	7950.810	F-statistic	5.538801
Durbin-Watson stat	2.018833	Prob(F-statistic)	0.000044

**Quadro 1:** Ajuste do modelo 3 (EViews 5).

Estimation Command:

=====

ARCH(DERIV=AA) RETORNO C I AR(1)

Estimation Equation:

=====

RETORNO = C(1) + C(2)\*I + [AR(1)=C(3)]

GARCH = C(4) + C(5)\*RESID(-1)^2 + C(6)\*GARCH(-1)

Substituted Coefficients:

=====

RETORNO = 0.001440000529 - 0.005123394512\*I + [AR(1)=0.05898009945]

GARCH = 7.456820619e-006 + 0.1024249103\*RESID(-1)^2 + 0.8660363167\*GARCH(-1)

**Quadro 2:** Representação do modelo 3 (EViews 5).

ARCH Test:

F-statistic	0.016506	Probability	0.897781
Obs*R-squared	0.016518	Probability	0.897735

Test Equation:

Dependent Variable: STD\_RESID^2

Method: Least Squares

Date: 06/07/11 Time: 15:44

Sample (adjusted): 4 2804

Included observations: 2801 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.003265	0.037356	26.85712	0.0000
STD_RESID^2(-1)	-0.002428	0.018901	-0.128477	0.8978

R-squared	0.000006	Mean dependent var	1.000835
Adjusted R-squared	-0.000351	S.D. dependent var	1.704561
S.E. of regression	1.704861	Akaike info criterion	3.905558
Sum squared resid	8135.435	Schwarz criterion	3.909798
Log likelihood	-5467.734	F-statistic	0.016506
Durbin-Watson stat	1.999939	Prob(F-statistic)	0.897781

**Quadro 3:** Teste Multiplicador de Lagrange – ARCH LM Test (EViews 5).

(a)						(b)							
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob		
		1	0.009	0.009	0.2478			1	-0.002	-0.002	0.0165		
		2	0.020	0.019	1.3156	0.251			2	0.025	0.025	1.7510	0.186
		3	-0.041	-0.042	6.1329	0.047			3	-0.003	-0.003	1.7705	0.413
		4	-0.012	-0.011	6.5239	0.089			4	0.004	0.003	1.8149	0.612
		5	-0.000	0.002	6.5243	0.163			5	-0.011	-0.011	2.1364	0.711
		6	-0.003	-0.005	6.5537	0.256			6	-0.006	-0.007	2.2476	0.814
		7	-0.002	-0.003	6.5669	0.363			7	0.022	0.023	3.6312	0.726
		8	0.003	0.003	6.5954	0.472			8	0.003	0.003	3.6488	0.819
		9	0.030	0.030	9.0815	0.335			9	-0.005	-0.006	3.7281	0.881
		10	0.037	0.036	12.896	0.167			10	0.020	0.020	4.8869	0.844
		11	0.000	-0.002	12.896	0.230			11	-0.009	-0.009	5.1088	0.884
		12	0.013	0.014	13.375	0.270			12	-0.007	-0.008	5.2577	0.918
		13	-0.005	-0.002	13.447	0.337			13	-0.005	-0.004	5.3355	0.946
		14	0.009	0.010	13.692	0.396			14	-0.026	-0.027	7.3029	0.886
		15	-0.022	-0.021	15.010	0.377			15	-0.007	-0.007	7.4418	0.916
		16	0.015	0.016	15.667	0.405			16	0.008	0.009	7.6070	0.939
		17	0.015	0.016	16.281	0.434			17	-0.040	-0.041	12.101	0.737
		18	-0.014	-0.018	16.869	0.463			18	0.031	0.031	14.827	0.608
		19	-0.008	-0.010	17.068	0.518			19	-0.006	-0.003	14.916	0.668
		20	0.039	0.040	21.260	0.323			20	-0.011	-0.014	15.270	0.705
		21	0.007	0.005	21.404	0.374			21	-0.005	-0.003	15.345	0.756
		22	0.005	0.001	21.481	0.430			22	0.004	0.004	15.395	0.803
		23	-0.003	-0.000	21.507	0.490			23	-0.007	-0.007	15.529	0.839
		24	0.014	0.016	22.057	0.517			24	-0.022	-0.019	16.879	0.815

(a)

(b)

**Quadro 4:** (a) Correlograma FAC e FACP dos resíduos padronizados do modelo 3; (b) Correlograma FAC e FACP dos quadrados dos resíduos padronizados do modelo 3 (EViews 5).

## ANEXO 5 – RESULTADOS DO MODELO 4 : Retorno ~ C AR(1) GARCH(1,1)

Dependent Variable: RETORNO  
 Method: ML - ARCH (Marquardt) - Normal distribution  
 Date: 06/07/11 Time: 16:19  
 Sample (adjusted): 3 2804  
 Included observations: 2802 after adjustments  
 Convergence achieved after 12 iterations  
 Variance backcast: ON  
 GARCH = C(3) + C(4)\*RESID(-1)^2 + C(5)\*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001375	0.000264	5.208263	0.0000
AR(1)	0.061716	0.020587	2.997880	0.0027

Variance Equation				
C	7.60E-06	1.29E-06	5.874943	0.0000
RESID(-1)^2	0.104023	0.009530	10.91540	0.0000
GARCH(-1)	0.863927	0.011990	72.05605	0.0000

R-squared	0.002117	Mean dependent var	0.000848
Adjusted R-squared	0.000690	S.D. dependent var	0.016234
S.E. of regression	0.016228	Akaike info criterion	-5.669654
Sum squared resid	0.736587	Schwarz criterion	-5.659058
Log likelihood	7948.186	F-statistic	1.483571
Durbin-Watson stat	2.008815	Prob(F-statistic)	0.204428

**Quadro 1:** Ajuste do modelo 4 (EViews 5).

Estimation Command:

=====

ARCH(DERIV=AA) RETORNO C AR(1)

Estimation Equation:

=====

RETORNO = C(1) + [AR(1)=C(2)]

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

Substituted Coefficients:

=====

RETORNO = 0.001374771412 + [AR(1)=0.06171612791]

GARCH = 7.595214336e-006 + 0.1040233668\*RESID(-1)^2 + 0.8639269173\*GARCH(-1)

**Quadro 2:** Representação do modelo 4 (EViews 5).



ARCH Test:

F-statistic	0.029313	Probability	0.864072
Obs*R-squared	0.029333	Probability	0.864012

Test Equation:

Dependent Variable: STD\_RESID^2

Method: Least Squares

Date: 06/08/11 Time: 08:24

Sample (adjusted): 4 2804

Included observations: 2801 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.004053	0.037259	26.94793	0.0000
STD_RESID^2(-1)	-0.003236	0.018901	-0.171209	0.8641

R-squared	0.000010	Mean dependent var	1.000815
Adjusted R-squared	-0.000347	S.D. dependent var	1.698646
S.E. of regression	1.698941	Akaike info criterion	3.898601
Sum squared resid	8079.035	Schwarz criterion	3.902841
Log likelihood	-5457.991	F-statistic	0.029313
Durbin-Watson stat	1.999895	Prob(F-statistic)	0.864072

**Quadro 3:** Teste Multiplicador de Lagrange – ARCH LM Test (EViews 5).

Autocorrelation						Partial Correlation								
AC	PAC	Q-Stat	Prob	AC	PAC	Q-Stat	Prob	AC	PAC	Q-Stat	Prob			
1	0.010	0.010	0.2713	1	-0.003	-0.003	0.0294	1	-0.003	-0.003	0.0294			
2	0.023	0.023	1.7302	0.188	2	0.026	0.026	1.8604	0.173	2	0.026	0.026	1.8604	0.173
3	-0.038	-0.039	5.8720	0.053	3	-0.003	-0.003	1.8886	0.389	3	-0.003	-0.003	1.8886	0.389
4	-0.009	-0.009	6.0972	0.107	4	0.004	0.004	1.9387	0.585	4	0.004	0.004	1.9387	0.585
5	0.002	0.004	6.1100	0.191	5	-0.011	-0.011	2.2913	0.682	5	-0.011	-0.011	2.2913	0.682
6	-0.001	-0.002	6.1122	0.295	6	-0.008	-0.008	2.4777	0.780	6	-0.008	-0.008	2.4777	0.780
7	0.001	-0.000	6.1139	0.411	7	0.023	0.024	3.9810	0.679	7	0.023	0.024	3.9810	0.679
8	0.006	0.006	6.2052	0.516	8	0.003	0.004	4.0148	0.778	8	0.003	0.004	4.0148	0.778
9	0.032	0.032	9.0948	0.334	9	-0.003	-0.004	4.0351	0.854	9	-0.003	-0.004	4.0351	0.854
10	0.039	0.039	13.443	0.144	10	0.021	0.021	5.2905	0.808	10	0.021	0.021	5.2905	0.808
11	0.003	0.001	13.468	0.199	11	-0.011	-0.011	5.6053	0.847	11	-0.011	-0.011	5.6053	0.847
12	0.016	0.017	14.164	0.224	12	-0.006	-0.007	5.7006	0.893	12	-0.006	-0.007	5.7006	0.893
13	-0.002	0.001	14.174	0.290	13	-0.004	-0.003	5.7530	0.928	13	-0.004	-0.003	5.7530	0.928
14	0.011	0.011	14.529	0.338	14	-0.028	-0.029	8.0377	0.841	14	-0.028	-0.029	8.0377	0.841
15	-0.019	-0.018	15.521	0.344	15	-0.008	-0.008	8.2360	0.877	15	-0.008	-0.008	8.2360	0.877
16	0.017	0.017	16.351	0.359	16	0.006	0.007	8.3272	0.910	16	0.006	0.007	8.3272	0.910
17	0.017	0.018	17.143	0.376	17	-0.037	-0.038	12.209	0.729	17	-0.037	-0.038	12.209	0.729
18	-0.011	-0.015	17.468	0.423	18	0.031	0.030	14.837	0.607	18	0.031	0.030	14.837	0.607
19	-0.005	-0.008	17.551	0.486	19	-0.006	-0.005	14.956	0.665	19	-0.006	-0.005	14.956	0.665
20	0.041	0.042	22.232	0.273	20	-0.011	-0.014	15.293	0.704	20	-0.011	-0.014	15.293	0.704
21	0.009	0.007	22.456	0.316	21	-0.004	-0.001	15.329	0.757	21	-0.004	-0.001	15.329	0.757
22	0.007	0.003	22.597	0.366	22	0.004	0.005	15.383	0.803	22	0.004	0.005	15.383	0.803
23	-0.001	0.001	22.603	0.424	23	-0.007	-0.007	15.520	0.839	23	-0.007	-0.007	15.520	0.839
24	0.016	0.017	23.345	0.441	24	-0.026	-0.023	17.479	0.785	24	-0.026	-0.023	17.479	0.785

(a)

(b)

**Quadro 4:** (a) Correlograma FAC e FACP dos resíduos padronizados do modelo 4; (b) Correlograma FAC e FACP dos quadrados dos resíduos padronizados do modelo 4 (EViews 5).

## ANEXO 6 – RESULTADOS DO MODELO 5 : Retorno ~ C I, AR(1) EGARCH(1,1)

Dependent Variable: RETORNO  
 Method: ML - ARCH (Marquardt) - Normal distribution  
 Date: 06/18/11 Time: 18:50  
 Sample (adjusted): 3 2804  
 Included observations: 2802 after adjustments  
 Convergence achieved after 17 iterations  
 Variance backcast: ON

$$\text{LOG(GARCH)} = C(4) + C(5)*\text{ABS}(\text{RESID}(-1)/\text{SQRT}(\text{GARCH}(-1))) + C(6)*\text{RESID}(-1)/\text{SQRT}(\text{GARCH}(-1)) + C(7)*\text{LOG}(\text{GARCH}(-1))$$

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000903	0.000270	3.339299	0.0008
I	-0.003762	0.001712	-2.196918	0.0280
AR(1)	0.068463	0.020265	3.378416	0.0007
Variance Equation				
C(4)	-0.415434	0.042434	-9.790192	0.0000
C(5)	0.185805	0.015971	11.63389	0.0000
C(6)	-0.072740	0.008303	-8.761090	0.0000
C(7)	0.968161	0.004414	219.3603	0.0000
R-squared	0.008786	Mean dependent var		0.000848
Adjusted R-squared	0.006658	S.D. dependent var		0.016234
S.E. of regression	0.016179	Akaike info criterion		-5.679558
Sum squared resid	0.731664	Schwarz criterion		-5.664723
Log likelihood	7964.060	F-statistic		4.129030
Durbin-Watson stat	2.035921	Prob(F-statistic)		0.000391

**Quadro 1:** Ajuste do modelo 5 (EViews 5).

Estimation Command:

```
=====
ARCH(EGARCH,DERIV=AA) RETORNO C I AR(1)
```

Estimation Equation:

```
=====
RETORNO = C(1) + C(2)*I + [AR(1)=C(3)]
```

```
LOG(GARCH) = C(4) + C(5)*ABS(RESID(-1)/SQRT(GARCH(-1))) +
C(6)*RESID(-1)/SQRT(GARCH(-1)) + C(7)*LOG(GARCH(-1))
```

Substituted Coefficients:

```
=====
RETORNO = 0.0009027012069 - 0.003761742166*I + [AR(1)=0.06846257102]
```

```
LOG(GARCH) = -0.4154341056 + 0.1858045107*ABS(RESID(-1)/SQRT(GARCH(-1))) -
0.07273982711*RESID(-1)/SQRT(GARCH(-1)) + 0.9681605265*LOG(GARCH(-1))
```

**Quadro 2:** Representação do modelo 5 (EViews 5).

ARCH Test:

F-statistic	1.239409	Probability	0.265681
Obs*R-squared	1.239745	Probability	0.265520

Test Equation:

Dependent Variable: STD\_RESID^2

Method: Least Squares

Date: 06/12/11 Time: 19:36

Sample (adjusted): 4 2804

Included observations: 2801 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.022236	0.037182	27.49297	0.0000
STD_RESID^2(-1)	-0.021038	0.018897	-1.113287	0.2657

R-squared	0.000443	Mean dependent var	1.001176
Adjusted R-squared	0.000085	S.D. dependent var	1.694172
S.E. of regression	1.694100	Akaike info criterion	3.892894
Sum squared resid	8033.055	Schwarz criterion	3.897133
Log likelihood	-5449.997	F-statistic	1.239409
Durbin-Watson stat	1.998643	Prob(F-statistic)	0.265681

**Quadro 3:** Teste Multiplicador de Lagrange – ARCH LM Test (EViews 5).

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob		
		1	-0.001	-0.001	0.0023			1	-0.021	-0.021	1.2427		
		2	0.024	0.024	1.6137	0.204			2	0.034	0.034	4.4790	0.034
		3	-0.039	-0.039	5.9701	0.051			3	-0.003	-0.002	4.5089	0.105
		4	-0.006	-0.006	6.0588	0.109			4	0.008	0.007	4.6869	0.196
		5	0.002	0.004	6.0733	0.194			5	-0.007	-0.006	4.8223	0.306
		6	-0.001	-0.002	6.0741	0.299			6	0.009	0.008	5.0495	0.410
		7	-0.003	-0.004	6.1004	0.412			7	0.029	0.030	7.4917	0.278
		8	0.004	0.004	6.1479	0.523			8	0.010	0.011	7.7709	0.353
		9	0.027	0.028	8.2677	0.408			9	-0.004	-0.005	7.8138	0.452
		10	0.037	0.036	12.023	0.212			10	0.023	0.022	9.3352	0.407
		11	-0.001	-0.002	12.025	0.283			11	-0.008	-0.007	9.5365	0.482
		12	0.014	0.014	12.550	0.324			12	-0.003	-0.005	9.5616	0.570
		13	-0.003	0.000	12.578	0.400			13	-0.002	-0.002	9.5754	0.653
		14	0.012	0.011	12.968	0.450			14	-0.020	-0.021	10.672	0.638
		15	-0.019	-0.018	14.021	0.448			15	-0.005	-0.006	10.757	0.705
		16	0.013	0.013	14.494	0.488			16	0.007	0.008	10.886	0.761
		17	0.015	0.017	15.109	0.517			17	-0.032	-0.033	13.835	0.611
		18	-0.013	-0.016	15.600	0.552			18	0.031	0.029	16.513	0.488
		19	-0.006	-0.008	15.694	0.614			19	-0.005	-0.001	16.586	0.552
		20	0.039	0.040	20.062	0.391			20	-0.005	-0.007	16.651	0.614
		21	0.003	0.002	20.086	0.453			21	0.001	0.004	16.655	0.675
		22	0.007	0.004	20.244	0.506			22	0.012	0.012	17.038	0.709
		23	-0.008	-0.005	20.414	0.557			23	-0.003	-0.002	17.059	0.760
		24	0.017	0.018	21.216	0.568			24	-0.028	-0.027	19.339	0.681

(a)

(b)

**Quadro 4:** (a) Correlograma FAC e FACP dos resíduos padronizados do modelo 5; (b) Correlograma FAC e FACP dos quadrados dos resíduos padronizados do modelo 5 (EViews).

## ANEXO 7 – RESULTADOS DO MODELO 6 : Retorno ~ C AR(1) EGARCH(1,1)

Dependent Variable: RETORNO  
 Method: ML - ARCH (Marquardt) - Normal distribution  
 Date: 06/08/11 Time: 08:31  
 Sample (adjusted): 3 2804  
 Included observations: 2802 after adjustments  
 Convergence achieved after 18 iterations  
 Variance backcast: ON  
 $\text{LOG}(\text{GARCH}) = \text{C}(3) + \text{C}(4) * \text{ABS}(\text{RESID}(-1) / @\text{SQRT}(\text{GARCH}(-1))) + \text{C}(5) * \text{RESID}(-1) / @\text{SQRT}(\text{GARCH}(-1)) + \text{C}(6) * \text{LOG}(\text{GARCH}(-1))$

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000860	0.000268	3.209793	0.0013
AR(1)	0.071755	0.020238	3.545631	0.0004
Variance Equation				
C(3)	-0.423824	0.042960	-9.865517	0.0000
C(4)	0.181116	0.015920	11.37667	0.0000
C(5)	-0.075784	0.008326	-9.102442	0.0000
C(6)	0.966788	0.004481	215.7310	0.0000
R-squared	0.002813	Mean dependent var		0.000848
Adjusted R-squared	0.001030	S.D. dependent var		0.016234
S.E. of regression	0.016225	Akaike info criterion		-5.679728
Sum squared resid	0.736073	Schwarz criterion		-5.667012
Log likelihood	7963.299	F-statistic		1.577469
Durbin-Watson stat	2.030490	Prob(F-statistic)		0.162948

**Quadro 1:** Ajuste do modelo 6 (EViews 5).

Estimation Command:

=====

ARCH(EGARCH,DERIV=AA) RETORNO C AR(1)

Estimation Equation:

=====

RETORNO = C(1) + [AR(1)=C(2)]

LOG(GARCH) = C(3) + C(4)\*ABS(RESID(-1)/@SQRT(GARCH(-1))) + C(5)\*RESID(-1)/@SQRT(GARCH(-1))  
 + C(6)\*LOG(GARCH(-1))

Substituted Coefficients:

=====

RETORNO = 0.0008600980275 + [AR(1)=0.07175495502]

LOG(GARCH) = -0.4238240507 + 0.181116484\*ABS(RESID(-1)/@SQRT(GARCH(-1))) -  
 0.07578393389\*RESID(-1)/@SQRT(GARCH(-1)) + 0.9667882276\*LOG(GARCH(-1))

**Quadro 2:** Representação do modelo 6 (EViews 5).

ARCH Test:

F-statistic	1.218904	Probability	0.269671
Obs*R-squared	1.219244	Probability	0.269509

Test Equation:

Dependent Variable: STD\_RESID^2

Method: Least Squares

Date: 06/08/11 Time: 08:37

Sample (adjusted): 4 2804

Included observations: 2801 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.022130	0.037102	27.54909	0.0000
STD_RESID^2(-1)	-0.020863	0.018897	-1.104040	0.2697

R-squared	0.000435	Mean dependent var	1.001243
Adjusted R-squared	0.000078	S.D. dependent var	1.689228
S.E. of regression	1.689162	Akaike info criterion	3.887056
Sum squared resid	7986.299	Schwarz criterion	3.891296
Log likelihood	-5441.822	F-statistic	1.218904
Durbin-Watson stat	1.998665	Prob(F-statistic)	0.269671

**Quadro 3:** Teste Multiplicador de Lagrange – ARCH LM Test (EViews 5).

Autocorrelation						Autocorrelation								
Partial Correlation	AC	PAC	Q-Stat	Prob	Partial Correlation	AC	PAC	Q-Stat	Prob					
			1	-0.002	-0.002	0.0094				1	-0.021	-0.021	1.2223	
			2	0.027	0.027	1.9929	0.158			2	0.034	0.033	4.4054	0.036
			3	-0.036	-0.036	5.7142	0.057			3	-0.002	-0.001	4.4214	0.110
			4	-0.003	-0.004	5.7412	0.125			4	0.008	0.007	4.5930	0.204
			5	0.005	0.007	5.8043	0.214			5	-0.006	-0.006	4.7012	0.319
			6	0.001	0.000	5.8106	0.325			6	0.008	0.007	4.8735	0.432
			7	-0.001	-0.001	5.8125	0.445			7	0.031	0.032	7.6040	0.269
			8	0.006	0.007	5.9221	0.549			8	0.011	0.012	7.9342	0.338
			9	0.029	0.030	8.3664	0.399			9	-0.004	-0.005	7.9725	0.436
			10	0.038	0.038	12.480	0.188			10	0.023	0.022	9.5002	0.392
			11	0.002	0.001	12.492	0.253			11	-0.011	-0.010	9.8428	0.454
			12	0.016	0.016	13.195	0.281			12	-0.002	-0.003	9.8503	0.544
			13	-0.000	0.003	13.195	0.355			13	-0.002	-0.002	9.8651	0.628
			14	0.013	0.013	13.694	0.396			14	-0.020	-0.022	11.049	0.607
			15	-0.017	-0.016	14.505	0.413			15	-0.007	-0.008	11.203	0.670
			16	0.014	0.013	15.049	0.448			16	0.005	0.006	11.267	0.733
			17	0.016	0.018	15.805	0.467			17	-0.031	-0.032	13.964	0.601
			18	-0.010	-0.013	16.087	0.518			18	0.030	0.029	16.438	0.493
			19	-0.003	-0.005	16.107	0.585			19	-0.006	-0.003	16.547	0.554
			20	0.041	0.042	20.968	0.339			20	-0.004	-0.007	16.595	0.617
			21	0.004	0.003	21.018	0.396			21	0.001	0.004	16.599	0.679
			22	0.009	0.005	21.249	0.444			22	0.012	0.012	16.994	0.711
			23	-0.006	-0.004	21.366	0.498			23	-0.004	-0.003	17.041	0.761
			24	0.019	0.019	22.406	0.496			24	-0.031	-0.030	19.774	0.656

**Quadro 4:** (a) Correlograma FAC e FACP dos resíduos padronizados do modelo 6; (b) Correlograma FAC e FACP dos quadrados dos resíduos padronizados do modelo 6 (EViews 5).

## ANEXO 8 – RESULTADOS DO MODELO 7 : Retorno ~ C AR(1) TARCH(1,1)

Dependent Variable: RETORNO  
 Method: ML - ARCH (Marquardt) - Normal distribution  
 Date: 06/08/11 Time: 08:25  
 Sample (adjusted): 3 2804  
 Included observations: 2802 after adjustments  
 Convergence achieved after 12 iterations  
 Variance backcast: ON  
 GARCH = C(3) + C(4)\*RESID(-1)^2 + C(5)\*RESID(-1)^2\*(RESID(-1)<0)  
 + C(6)\*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000995	0.000271	3.665750	0.0002
AR(1)	0.069035	0.020611	3.349412	0.0008
Variance Equation				
C	8.65E-06	1.27E-06	6.805636	0.0000
RESID(-1)^2	0.034780	0.010579	3.287742	0.0010
RESID(-1)^2*(RESID(-1)<0)	0.109733	0.014166	7.746343	0.0000
GARCH(-1)	0.869886	0.012558	69.26816	0.0000
R-squared	0.002825	Mean dependent var		0.000848
Adjusted R-squared	0.001042	S.D. dependent var		0.016234
S.E. of regression	0.016225	Akaike info criterion		-5.683787
Sum squared resid	0.736064	Schwarz criterion		-5.671071
Log likelihood	7968.985	F-statistic		1.584454
Durbin-Watson stat	2.024986	Prob(F-statistic)		0.160965

**Quadro 1:** Ajuste do modelo 7 (EViews 5).

Estimation Command:

=====  
 ARCH(THRSH=1,DERIV=AA) RETORNO C AR(1)

Estimation Equation:

=====  
 RETORNO = C(1) + [AR(1)=C(2)]

GARCH = C(3) + C(4)\*RESID(-1)^2 + C(5)\*RESID(-1)^2\*(RESID(-1)<0) + C(6)\*GARCH(-1)

Substituted Coefficients:

=====  
 RETORNO = 0.0009945146644 + [AR(1)=0.06903535956]

GARCH = 8.651911686e-006 + 0.03478033398\*RESID(-1)^2 + 0.1097328402\*RESID(-1)^2\*(RESID(-1)<0) +  
 0.8698864525\*GARCH(-1)

**Quadro 2:** Representação do modelo 7 (EViews 5).

ARCH Test:

F-statistic	1.449714	Probability	0.228676
Obs*R-squared	1.449999	Probability	0.228528

Test Equation:

Dependent Variable: STD\_RESID^2

Method: Least Squares

Date: 06/08/11 Time: 08:30

Sample (adjusted): 4 2804

Included observations: 2801 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.024019	0.036608	27.97282	0.0000
STD_RESID^2(-1)	-0.022752	0.018896	-1.204041	0.2287

R-squared	0.000518	Mean dependent var	1.001241
Adjusted R-squared	0.000161	S.D. dependent var	1.658825
S.E. of regression	1.658692	Akaike info criterion	3.850649
Sum squared resid	7700.772	Schwarz criterion	3.854889
Log likelihood	-5390.834	F-statistic	1.449714
Durbin-Watson stat	1.999675	Prob(F-statistic)	0.228676

**Quadro 3:** Teste Multiplicador de Lagrange – ARCH LM Test (EViews 5).

Autocorrelation						Partial Correlation								
AC	PAC	Q-Stat	Prob	AC	PAC	Q-Stat	Prob	AC	PAC	Q-Stat	Prob			
1	0.003	0.003	0.0321	1	-0.023	-0.023	1.4536	1	-0.023	-0.023	1.4536			
2	0.024	0.024	1.6887	0.194	2	0.009	0.008	1.6735	0.196	2	0.009	0.008	1.6735	0.196
3	-0.038	-0.038	5.6775	0.058	3	-0.005	-0.004	1.7372	0.420	3	-0.005	-0.004	1.7372	0.420
4	-0.007	-0.008	5.8312	0.120	4	0.006	0.006	1.8331	0.608	4	0.006	0.006	1.8331	0.608
5	0.004	0.006	5.8690	0.209	5	-0.015	-0.015	2.4937	0.646	5	-0.015	-0.015	2.4937	0.646
6	0.003	0.002	5.8954	0.317	6	0.006	0.006	2.6123	0.759	6	0.006	0.006	2.6123	0.759
7	-0.003	-0.004	5.9241	0.432	7	0.029	0.029	4.9255	0.553	7	0.029	0.029	4.9255	0.553
8	0.004	0.004	5.9661	0.544	8	0.012	0.013	5.3252	0.620	8	0.012	0.013	5.3252	0.620
9	0.029	0.030	8.3957	0.396	9	-0.006	-0.005	5.4156	0.712	9	-0.006	-0.005	5.4156	0.712
10	0.039	0.038	12.622	0.180	10	0.023	0.022	6.8555	0.652	10	0.023	0.022	6.8555	0.652
11	0.005	0.003	12.688	0.242	11	-0.016	-0.015	7.5909	0.669	11	-0.016	-0.015	7.5909	0.669
12	0.016	0.017	13.447	0.265	12	-0.002	-0.003	7.6066	0.748	12	-0.002	-0.003	7.6066	0.748
13	-0.002	0.001	13.459	0.337	13	-0.002	-0.002	7.6177	0.814	13	-0.002	-0.002	7.6177	0.814
14	0.014	0.014	13.996	0.374	14	-0.022	-0.023	8.9536	0.776	14	-0.022	-0.023	8.9536	0.776
15	-0.020	-0.020	15.160	0.367	15	-0.008	-0.009	9.1455	0.822	15	-0.008	-0.009	9.1455	0.822
16	0.015	0.015	15.823	0.394	16	-0.001	-0.002	9.1490	0.870	16	-0.001	-0.002	9.1490	0.870
17	0.016	0.017	16.501	0.419	17	-0.036	-0.037	12.713	0.694	17	-0.036	-0.037	12.713	0.694
18	-0.010	-0.013	16.766	0.470	18	0.032	0.031	15.528	0.558	18	0.032	0.031	15.528	0.558
19	-0.005	-0.007	16.825	0.535	19	-0.005	-0.003	15.612	0.620	19	-0.005	-0.003	15.612	0.620
20	0.044	0.044	22.185	0.275	20	-0.004	-0.006	15.665	0.680	20	-0.004	-0.006	15.665	0.680
21	0.007	0.005	22.325	0.323	21	-0.001	0.001	15.670	0.737	21	-0.001	0.001	15.670	0.737
22	0.008	0.004	22.512	0.371	22	0.014	0.014	16.240	0.756	22	0.014	0.014	16.240	0.756
23	-0.004	-0.001	22.547	0.428	23	-0.009	-0.007	16.473	0.792	23	-0.009	-0.007	16.473	0.792
24	0.019	0.020	23.564	0.428	24	-0.026	-0.024	18.379	0.737	24	-0.026	-0.024	18.379	0.737

(a)

(b)

**Quadro 4:** (a) Correlograma FAC e FACP dos resíduos padronizados do modelo 7; (b) Correlograma FAC e FACP dos quadrados dos resíduos padronizados do modelo 7 (EViews 5).

## ANEXO 9 - Valor Residual *versus* Valor Observado *versus* Valor Ajustado

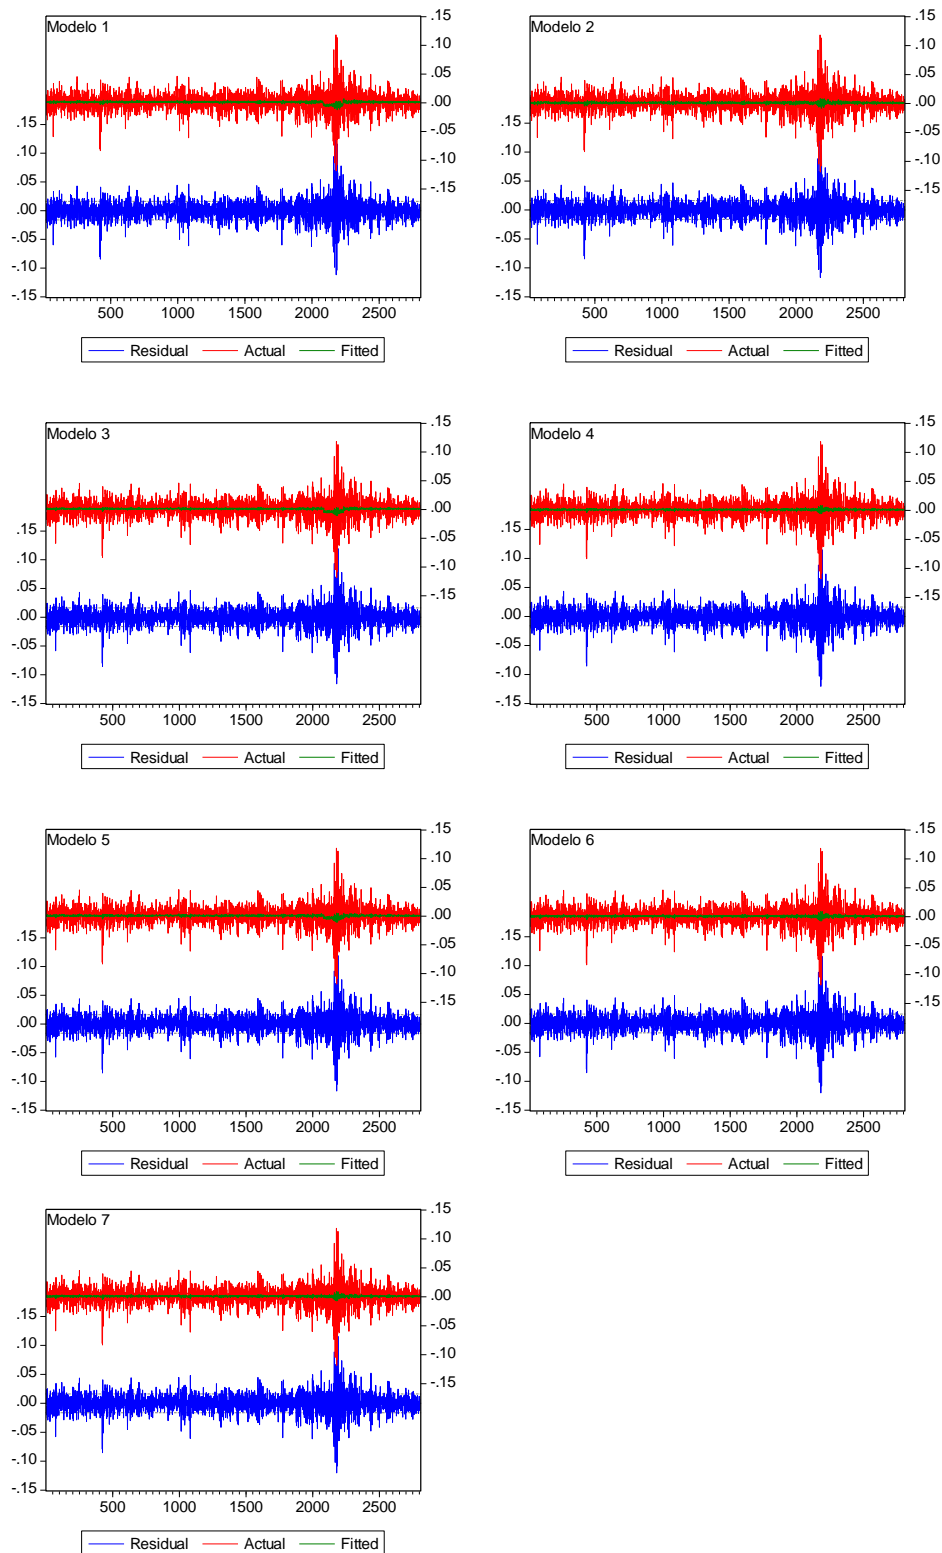


Figura 1: **Modelo 1:** Retorno  $\sim C I_t AR(1) AR(20) ARCH(3)$ ; **Modelo 2:** Retorno  $\sim C AR(1) AR(20) ARCH(3)$ ; **Modelo 3:** Retorno  $\sim C I_t AR(1) GARCH(1,1)$ ; **Modelo 4:** Retorno  $\sim C AR(1) GARCH(1,1)$ ; **Modelo 5:** Retorno  $\sim C I_t AR(1) EGARCH(1,1)$ ; **Modelo 6:** Retorno  $\sim C AR(1) EGARCH(1,1)$ ; **Modelo 7:** Retorno  $\sim C AR(1) TARCH(1,1)$



## ANEXO 10 - Desvio Padrão Condicional

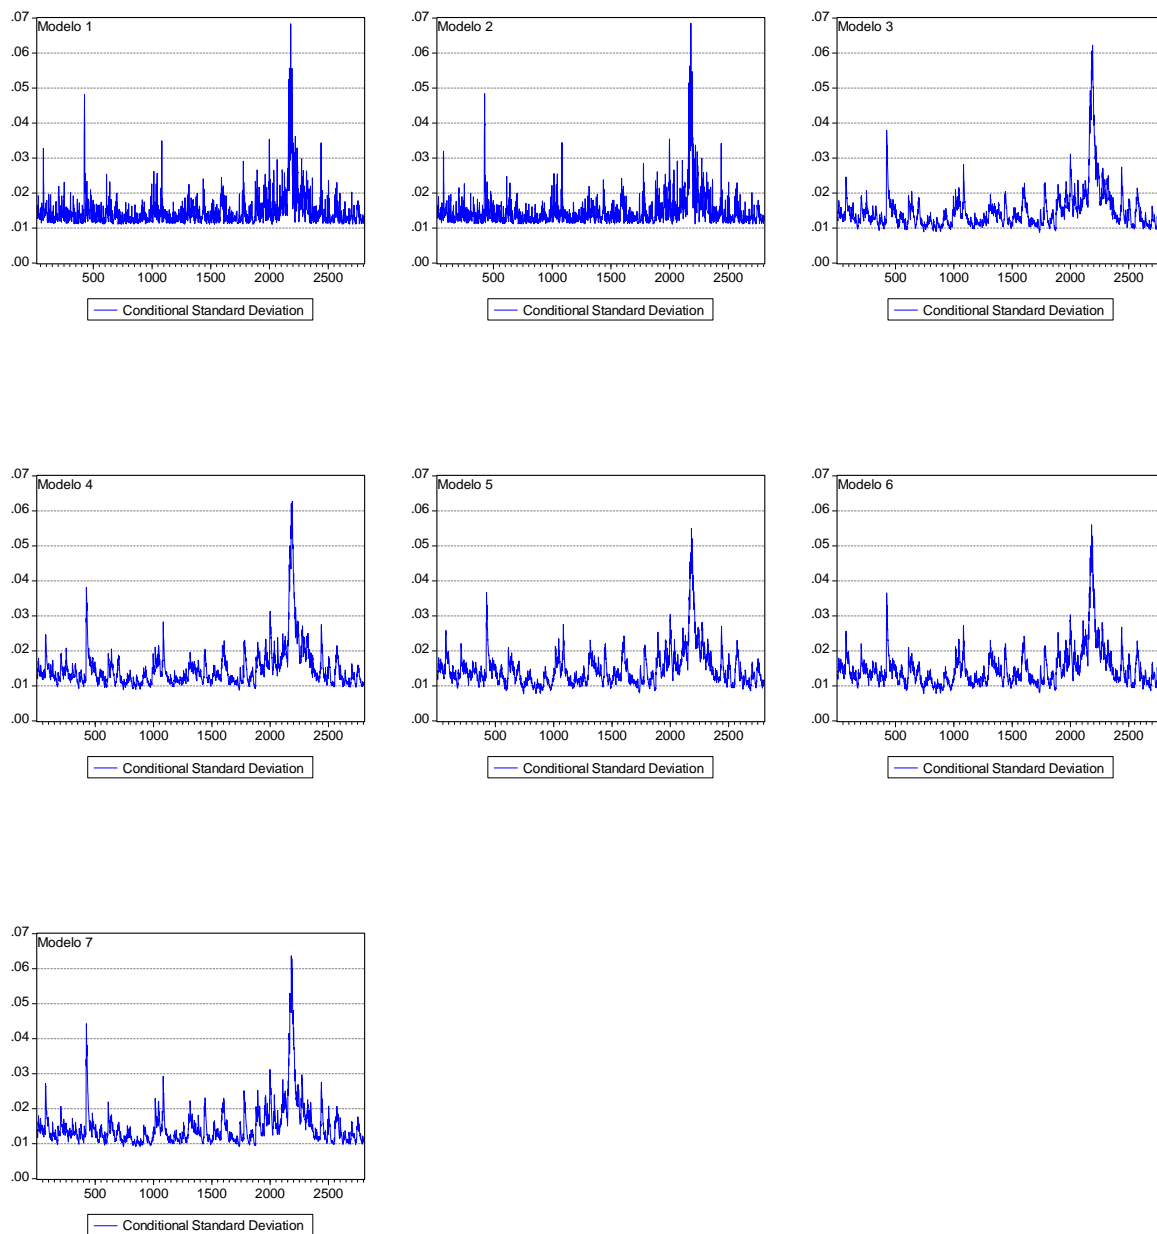


Figura 2: **Modelo 1:** Retorno  $\sim C I_t AR(1) AR(20) ARCH(3)$ ; **Modelo 2:** Retorno  $\sim C AR(1) AR(20) ARCH(3)$ ; **Modelo 3:** Retorno  $\sim C I_t AR(1) GARCH(1,1)$ ; **Modelo 4:** Retorno  $\sim C AR(1) GARCH(1,1)$ ; **Modelo 5:** Retorno  $\sim C I_t AR(1) EGARCH(1,1)$ ; **Modelo 6:** Retorno  $\sim C AR(1) EGARCH(1,1)$ ; **Modelo 7:** Retorno  $\sim C AR(1) TARCH(1,1)$

## ANEXO 11 – HISTOGRAMA DOS RESÍDUOS PADRONIZADOS




Figura 3: **Modelo 1:** Retorno  $\sim C I_t$  AR(1) AR(20) ARCH(3); **Modelo 2:** Retorno  $\sim C$  AR(1) AR(20) ARCH(3); **Modelo 3:** Retorno  $\sim C I_t$  AR(1) GARCH(1,1); **Modelo 4:** Retorno  $\sim C$  AR(1) GARCH(1,1); **Modelo 5:** Retorno  $\sim C I_t$  AR(1) EGARCH(1,1); **Modelo 6:** Retorno  $\sim C$  AR(1) EGARCH(1,1); **Modelo 7:** Retorno  $\sim C$  AR(1) TARCH(1,1)