



UNIVERSIDADE FEDERAL DO CEARÁ - UFC
CURSO DE PÓS-GRADUAÇÃO EM ECONOMIA - CAEN
MESTRADO PROFISSIONAL EM ECONOMIA - MPE

FERNANDA SALLES DE OLIVEIRA PESSOA

GESTÃO DE RISCO SETORIAL NO MERCADO DE AÇÕES BRASILEIRO

FORTALEZA

2013

FERNANDA SALLES DE OLIVEIRA PESSOA

GESTÃO DE RISCO SETORIAL NO MERCADO DE AÇÕES BRASILEIRO

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Economia – Mestrado Profissional – da Universidade Federal do Ceará - UFC, como requisito parcial para a obtenção do grau de Mestre em Economia. Área de Concentração: Finanças e Seguros.

Orientador: Prof. Dr. Paulo Rogério Faustino Matos

FORTALEZA

2013

FERNANDA SALLES DE OLIVEIRA PESSOA

GESTÃO DE RISCO SETORIAL NO MERCADO DE AÇÕES BRASILEIRO

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Economia – Mestrado Profissional – da Universidade Federal do Ceará - UFC, como requisito parcial para a obtenção do grau de Mestre em Economia. Área de Concentração: Finanças e Seguros.

Aprovada em: **21 de fevereiro de 2013**

BANCA EXAMINADORA

Prof. Dr. Paulo Rogério Faustino Matos (Orientador)
Universidade Federal do Ceará - UFC

Prof. Dr. Emerson Luís Lemos Marinho
Universidade Federal do Ceará - UFC

Prof. Dr. Marcelo de Castro Callado
Universidade Federal do Ceará - UFC

RESUMO

Este trabalho analisa durante o período de 01/2008 a 12/2011 o risco de mercado de seis índices setoriais da Bolsa de Valores de São Paulo (BM&FBovespa): o índice imobiliário (IMOB), o índice de energia elétrica (IEE), o índice de consumo (ICON), o índice do setor industrial (INDX), o índice financeiro (IFNC) e o índice setorial de telecomunicações (ITEL). Através da métrica *Value-at-Risk* (VaR) estimam-se quatro modelos. Dois desses modelos são ditos incondicionais no que se refere à variância: o VaR Gaussiano Incondicional, admitindo que os retornos seguem uma distribuição normal, e o VaR *Best Fitting* Incondicional, construído a partir da distribuição de probabilidades que melhor se ajusta às séries de retornos. Os outros dois modelos são chamados de condicionais, assumindo que a volatilidade varia ao longo do tempo. Os modelos autoregressivos do tipo GARCH são utilizados para estimar a variância condicional de cada índice, possibilitando a estimação do VaR Gaussiano Incondicional e do VaR *Best Fitting* Incondicional. Em seguida, realizam-se *backtestings* dos modelos de VaR, revelando a superioridade dos modelos condicionais. Por fim, através de gráficos de Balzer, observou-se a *performance* dos índices por meio de confrontos entre eles. Foi constatado que, para o período analisado, o IEE vence todos os embates feitos com os demais índices, apresentando a melhor relação risco x retorno. O setor imobiliário, representado pelo IMOB, perde todos os confrontos.

Palavras-chave: Índices Setoriais. *Value-at-Risk*. Distribuição Normal. Volatilidade Condicional. GARCH. *Backtesting*. Gráficos de Balzer.

ABSTRACT

This work analyzes during the period between 2008/01 and 2011/12 the market risk of six sectorial indexes from the São Paulo's Stock Market (BM&FBovespa): the real state index (IMOB), the electric power index (IEE), the consumption index (ICON), the industrial sector index (INDX), the financial index (IFNC) and the telecommunications sector index (ITEL). Throughout the Value-at-Risk metric (VaR), four models are estimated. Two of those models are called unconditional, due to its variance: the Unconditional Gaussian VaR, that admits that the returns follow a normal distribution, and the Unconditional Best Fitting VaR, built from the distribution of probabilities that better fits to the returns series. The other two models are called conditionals, assuming that the volatility changes along the time. The GARCH autoregressive models are used to estimate the conditional variance of each index, allowing an estimation of the Unconditional Gaussian VaR and the Unconditional Best Fitting VaR. Afterwards, the VaR models backtestings are realized, revealing the conditional models superiority. Finally, throughout the Balzer's graphics, the indexes performances were observed over the confrontations between them. It was found that, for the analyzed period, the IEE wins every confrontation against the all other indexes, showing the best relation risk x return. The real state index sector, represented by the IMOB, lost all the confronts.

Keywords: Sectorial Indexes. Value at Risk. Normal Distribution. Conditional Volatility. GARCH. Backtesting. Balzer's Graphics.

LISTA DE FIGURAS

Figura 1 - Evolução dos retornos líquidos nominais dos índices setoriais.....	27
Figura 2 - Distribuição que melhor se ajusta às séries de retornos dos índices setoriais.....	29
Figura 3 - Volatilidade condicional dos retornos líquidos nominais dos índices setoriais.....	34
Figura 4 - Séries estimadas de VaR para 01 dia, com 95% de confiança, para os Modelos Gaussiano Condicional e Incondicional.....	36
Figura 5 - Séries estimadas de VaR para 01 dia, com 95% de confiança, para os Modelos <i>Best Fitting</i> Condicional e Incondicional.....	38
Figura 6 - Séries estimadas de VaR para 01 dia, com 99% de confiança, para os Modelos Gaussiano Condicional e Incondicional.....	41
Figura 7 - Séries estimadas de VaR para 01 dia, com 99% de confiança, para os Modelos <i>Best Fitting</i> Condicional e Incondicional.....	42
Figura 8 - Gráficos de Balzer para os índices setoriais tomados dois a dois.....	47

LISTA DE GRÁFICOS

Gráfico 1 - Evolução do retorno diário acumulado dos índices setoriais..... 28

LISTA DE TABELAS

Tabela 1 - Tabela de Exceções.....	22
Tabela 2 - Estatísticas descritivas dos retornos nominais diários dos índices setoriais vis-à-vis <i>benchmarks</i> de mercado.....	25
Tabela 3 - Normalidade dos retornos dos índices setoriais.....	28
Tabela 4 - Melhor distribuição para as séries de retornos dos índices setoriais.....	30
Tabela 5 - Estacionariedade dos retornos dos índices setoriais.....	31
Tabela 6 - Modelos ARMA estimados para as séries de retornos dos índices setoriais e testes de autocorrelação dos resíduos.....	31
Tabela 7 - Heterocedasticidade nos modelos ARMA estimados para as séries de retornos dos índices setoriais.....	32
Tabela 8 - Modelos ARMA-GARCH estimados para os retornos dos índices setoriais.....	33
Tabela 9 - Heterocedasticidade nos modelos ARMA-GARCH estimados para as séries de retornos dos índices setoriais.....	35
Tabela 10 - Resultados dos <i>Backtestings</i> das séries de <i>Value-at-Risk</i> estimadas para os retornos dos índices setoriais, com 95% e 99% de confiança.....	43
Tabela 11 - Embates entre os índices setoriais.....	48

SUMÁRIO

1	INTRODUÇÃO.....	9
2	REVISÃO DA LITERATURA.....	11
2.1	Análise setorial no mercado de ações.....	11
2.2	A métrica <i>Value-at-Risk</i> e o <i>Backtesting</i>	12
2.3	Modelos ARCH-GARCH para volatilidade condicional.....	14
3	METODOLOGIA.....	16
3.1	Value-at-Risk (VaR).....	16
3.1.1	<i>Modelos Gaussiano e Best Fitting Incondicionais</i>	17
3.1.2	<i>Modelos Gaussiano e Best Fitting Condicionais</i>	18
3.2	Backtesting.....	20
3.3	Gráficos de Balzer.....	22
4	RESULTADOS.....	24
4.1	Base de dados e estatísticas descritivas.....	24
4.2	Modelos <i>Best Fitting</i>	28
4.3	Modelos ARMA-GARCH.....	31
4.4	Estimação do <i>Value-at-Risk</i> e <i>Backtesting</i>	35
4.5	Gráficos de Balzer.....	45
5	CONCLUSÕES.....	49
	REFERÊNCIAS.....	51

1 INTRODUÇÃO

A gestão de risco vem se aperfeiçoando ao longo dos anos, principalmente após a década de 70, com o aumento da volatilidade nos mercados financeiros globais (JORION, 2010). O investidor deve preocupar-se com a maximização dos ganhos, mas sempre procurando mecanismos que permitam controlar perdas e reduzir o risco de forma eficaz.

O risco de mercado advém dos movimentos de volatilidade verificados nos preços de mercado. A métrica *Value-at-Risk* (VaR) apresenta-se como uma importante ferramenta bastante utilizada pelos agentes financeiros para estimar esses riscos, permitindo uma avaliação das perdas potenciais de ativos.

O presente estudo analisa, através do VaR, o risco de mercado de seis índices setoriais da Bolsa de Valores de São Paulo (BM&FBovespa) durante o período de 01/2008 a 12/2011. O Índice de Energia Elétrica (IEE) foi o primeiro índice setorial da BOVESPA e mensura o desempenho do setor de energia elétrica. O Índice do Setor Industrial (INDX) foi desenvolvido com o objetivo de medir o desempenho das ações mais representativas do setor industrial, importante segmento da economia. O Índice de Consumo (ICON) analisa o comportamento das ações das empresas representativas dos setores de consumo cíclico e não cíclico. O Índice Imobiliário (IMOB) afere o comportamento das ações das empresas representativas dos setores da atividade imobiliária compreendidos por construção civil, intermediação imobiliária e exploração de imóveis. O Índice Financeiro (IFNC) mede o desempenho das ações das empresas representativas dos setores de intermediários financeiros, serviços financeiros diversos e previdência e seguros. Por fim, o Índice Setorial de Telecomunicações (ITEL), que mede a atuação das empresas do ramo de telecomunicações.

Para as séries diárias de retornos dos índices, foram estimados quatro tipos de VaR: os modelos aqui denominados de incondicionais e os condicionais. Essa nomenclatura refere-se ao comportamento da volatilidade, se fixa ou variável ao longo do tempo. Um segundo aspecto, também analisado nesse estudo, diz respeito à distribuição de probabilidades das séries de retornos. São estimados modelos Gaussianos e não Gaussianos, estes representados por distribuições teóricas de probabilidades que apresentem um bom ajuste para os dados. Têm-se,

então, quatro modelos de VaR, quais sejam: i) VaR Gaussiano Incondicional; ii) VaR Gaussiano Condicional, iii) VaR *Best Fitting* Incondicional e iv) VaR *Best Fitting* Condicional. A volatilidade condicional será modelada por modelos econométricos do tipo GARCH.

A adequação das estimativas das séries de VaR são avaliadas por meio de mecanismos de verificação denominados *backtestings*.

Este trabalho tem como objetivo principal o estudo de diferentes setores da economia através da análise do desempenho dos respectivos índices setoriais. A *performance* dos índices selecionados poderá ser examinada pelos gráficos de Balzer. Secundariamente, deseja-se encontrar o modelo de VaR com resultados satisfatórios nos testes de validação e fazer inferências acerca da aplicabilidade da distribuição normal para as séries temporais em observação.

Após essa introdução, a seção seguinte faz uma breve revisão da literatura sobre os principais temas aqui tratados. A seção 3 traz os aspectos metodológicos, e a seção 4 é reservada para exibição dos resultados. Por fim, são apresentadas as conclusões do estudo.

2 REVISÃO DA LITERATURA

2.1 Análise setorial no mercado de ações

Os índices setoriais são constituídos pelas empresas abertas mais significativas de ramos específicos da economia e visam oferecer um panorama do comportamento do mercado de ações de forma segmentada, facilitando o acompanhamento do desempenho de determinado setor.

Relacionam-se, a seguir, alguns trabalhos que analisaram o mercado de ações sob uma perspectiva setorial.

O estudo de Baca *et al.* (2000) constatou que os movimentos setoriais explicavam com maior precisão a volatilidade de sete importantes mercados de ações no mundo se comparado aos movimentos dos próprios países. De acordo com os autores, verificou-se que nos últimos 20 anos a influência dos componentes específicos de cada país na variação do retorno vem declinando, enquanto os componentes setoriais se mantêm relativamente constantes ou crescentes.

Para Ramos (2003), a atenção em relação aos movimentos setoriais também é verificada pelo crescente número de fundos de investimentos que concentram suas aplicações em setores específicos. Isso é resultado da percepção de que ações de um mesmo setor tendem a oscilar de forma parecida.

De forma intuitiva, é esperado que ações de empresas que atuam em um mesmo ramo de atividade econômica apresentem comportamentos similares no mercado de ações. Tal expectativa advém do fato de que empresas de um mesmo setor sofrem influências dos mesmos fatores em um ambiente competitivo e regem-se pela mesma legislação.

Nessa linha, conforme destacado por Jubert *et al.* (2008), para investidores voltados ao mercado brasileiro, o enfoque setorial contribui de forma relevante para a redução do risco de carteiras de ações. Em períodos de crise, quando a volatilidade do mercado aumenta, a diversificação representa uma alternativa válida para minimizar o risco da carteira. Acrescenta o autor que, nesse contexto, é intuitivo acreditar que existam setores mais imunes a crises.

Como trabalho relacionado, cita-se Medeiros (2012), cujo estudo refere-se ao comportamento de quatro índices setoriais da Bolsa de Valores de São Paulo no

que diz respeito aos seus padrões de volatilidade. Os índices selecionados foram o Índice de Energia Elétrica, o Índice Setorial de Telecomunicações, o Índice do Setor Industrial e o Índice Financeiro. O autor concluiu que os modelos que levaram em conta o efeito assimetria tiveram um desempenho melhor em relação àqueles que não consideraram esse efeito. Adicionalmente, constatou que o comportamento da variância condicional ao longo do tempo é extremamente parecido para os índices estudados.

Medeiros (2012) destaca, ainda, que há poucos trabalhos sobre volatilidade no mercado acionário brasileiro sob o ponto de vista dos índices setoriais.

2.2 A métrica *Value-at-Risk* e o *Backtesting*

Um marco histórico para a gestão de riscos foi a disponibilização para o público em geral de um documento técnico intitulado *Riskmetrics*. Elaborado pelo banco de investimentos americano J. P. Morgan, esse documento mostrava uma versão simplificada do modelo de gestão de riscos usado pelo banco, dando grande destaque à forma de estimação da métrica *Value-at-Risk* (VaR).

Com o passar dos anos e com a consolidação do conceito, o VaR tornou-se um instrumento amplamente difundido para a gestão de risco de mercado. Essa métrica é utilizada tanto para atender a requisitos legais quanto para fins gerenciais de avaliação de risco.

Kimura *et al.* (2008) destaca a popularização desse parâmetro de risco, que passou a ser empregado não apenas por instituições financeiras, que, pela regulamentação brasileira, são obrigadas a informar a exposição a riscos através do VaR. Empresas não financeiras de destaque no cenário nacional, como por exemplo a Petrobras e a Braskem, também têm utilizado essa métrica como medida de avaliação do risco de mercado. Ressalta, ainda o autor, que o órgão regulador do mercado de capitais americano (*Securities and Exchange Commission – SEC*) permite a utilização do VaR como estimativa para a exposição das empresas a riscos de mercado.

Passando a parte conceitual, conforme define Jorion (2010), o “VaR sintetiza a maior (ou pior) perda esperada dentro de determinados período de tempo

e intervalo de confiança.” A maior vantagem dessa métrica consiste em resumir em um único número a exposição total ao risco de mercado. Trata-se, portanto, de um indicador de fácil interpretação e entendimento. Essa facilidade traz preocupações quanto à confiabilidade dos modelos e as hipóteses que os guiam. Em razão disso, os *backtestings* se apresentam como métodos para validação desses modelos.

Torres *et al.* (2008) desenvolvem o cálculo do VaR para uma carteira composta por dez ativos individuais e o compara com o de um índice obtido a partir desses mesmos ativos. O VaR foi obtido conforme a metodologia apresentada pelo *Riskmetrics*. Já Alarcon (2005) apresenta e analisa empiricamente três modelos de estimação do *Value-at-Risk*: o de variância incondicional, o de variância condicional – GARCH (1,1) e o de Simulação Histórica. Essas três metodologias são testadas para as séries de retornos financeiros das ações da Petrobras e da Cia. Vale do Rio Doce. Os resultados obtidos com esses modelos são analisados à luz do teste para proporção de falhas proposto por Kupiec (1995).

O estudo de Lima (2010) avalia os modelos de valor em risco do fundo de aplicação em cotas da Petrobras, com a exploração de diversos métodos de *backtestings*. Trata-se de mecanismo para verificar a adequação da estimativa do VaR. De acordo com o autor, não há na literatura um critério que determine qual é a melhor técnica de avaliação dos modelos de VaR. Os resultados confirmaram a importância de avaliar os modelos de VaR utilizando diferentes técnicas de *backtestings*, visto que o mesmo modelo foi considerado apropriado utilizando um tipo de *backtesting* e inadequado utilizando outro.

Na mesma linha, citado por Kimura *et al.* (2008), a pesquisa de Hendricks, do *Federal Reserve Bank of New York*, avaliou o comportamento de diversos modelos de *Value-at-Risk*, considerando diferentes mecanismos de estimação. O autor concluiu que é extremamente difícil construir um modelo de VaR que seja o melhor em vários critérios de *performance*, não recomendando, assim, o uso de uma única abordagem VaR, sugerindo a necessidade de estudos que permitam combinar as melhores características de cada modelo.

Por fim, vale destacar a contribuição de Costa (1999), ressaltando que, para o cálculo do VaR para o mercado de ações, inicialmente optou-se pelo modelo Gaussiano tradicional. No entanto, apesar da simplicidade, logo se constatou que a distribuição normal não se ajusta muito bem à realidade empírica dos mercados,

uma vez que as distribuições estatísticas das realizações históricas apresentam-se geralmente como leptocúrticas. Adicionalmente, verificam-se importantes ocorrências em áreas significativamente afastadas da média, as conhecidas *fat tails*. Nesse sentido, tem-se o trabalho de Moralles e Sartoris Neto (2010), em que os autores calculam o VaR paramétrico do Ibovespa e de ativos da Bovespa após encontrar a distribuição teórica mais ajustada à distribuição empírica do ativo utilizando o teste de aderência de Kolmogorov-Smirnov.

Costa (1999) acrescenta que a má descrição da realidade pelo modelo Gaussiano clássico conduziu a duas vias diferentes de busca de soluções mais ajustadas à realidade. Primeiramente, buscando uma distribuição que se ajuste melhor ao comportamento dos mercados. Em seguida, procurando dar um caráter dinâmico aos modelos de forma que seus parâmetros se adaptem em cada instante à realidade do mercado. Essa segunda linha de pesquisa, continua o autor, conduziu ao desenvolvimento de modelos do tipo ARCH, dos quais são mais frequentemente usados os da família GARCH, desenvolvido por Bollerslev (1986).

2.3 Modelos ARCH-GARCH para volatilidade condicional

A análise da volatilidade de uma série de retorno é um ponto importante a ser tratado no presente estudo. No cálculo do *Value-at-Risk* essa medida será utilizada tanto como um parâmetro fixo, representada pelo desvio padrão das séries, como uma medida variável ao longo do tempo.

Segundo Furriel (2011), os instrumentos financeiros possuem geralmente comportamentos dinâmicos diferentes ao longo do tempo, apresentando períodos de tempo onde se verificam grandes variações em seu comportamento e outros períodos em que não se verifica qualquer variação. Essa variação de um ativo financeiro ao longo do tempo é conhecida como volatilidade. A autora destaca que:

Compreender e modelar a volatilidade de séries financeiras é importante na medida em que permite refinar a estimação dos parâmetros de um modelo que traduza o comportamento dos dados e consequentemente efetuar previsões com maior exatidão. (FURRIEL, 2011).

Os modelos estatísticos existentes para estudo da volatilidade desempenham um papel de grande destaque na análise de séries financeiras. Os

modelos que incorporam a possibilidade da variância do termo de erro não ser constante ao longo do tempo são denominados de modelos heterocedásticos.

Silva *et al.* (2010) aplica a métrica *Value-at-Risk* a índices de bolsas de valores de países latino-americanos utilizando modelos de previsão de volatilidade EWMA, EQMA e GARCH. Já Souza e Costa (2012) fizeram uma análise comparativa do desempenho de diversos índices de sustentabilidade em bolsa de valores em termos de retorno e risco. Nesse estudo, foram utilizados modelos de previsão de volatilidade e *Value-at-Risk* como medida de gestão de risco.

O trabalho de Souza Sobrinho (2001) estima a volatilidade do IBOVESPA a partir do Plano Real, através de modelos da família GARCH e de modelos de Volatilidade Estocástica. Os resultados apontaram que ambas as metodologias são bastante satisfatórias. Adicionalmente, a aplicação da métrica VaR sugeriu que os dois modelos são equivalentes.

Jubert *et al.* (2008) analisa o padrão de volatilidade dos principais índices financeiros da Bovespa por meio da aplicação de modelos ARCH, concluindo, para todos os índices analisados, que os modelos estimados evidenciaram a influência do movimento do mercado no dia anterior na volatilidade corrente. Constatou também que os modelos simétricos e assimétricos têm estimativas razoavelmente similares, indicando que o resultado empírico corroborou as expectativas teóricas.

Galdi e Pereira (2007) utilizam as ações preferenciais da Petrobras para cálculo do VaR aplicando modelos de previsão de volatilidade EWMA, GARCH e Volatilidade Estocástica. Destaca-se também a pesquisa de Gaio (2009), que propôs uma análise comparativa de modelos de volatilidade para estimativa do *Value-at-Risk* utilizando modelos de volatilidade condicional da família ARCH. Foram examinados os índices dos principais mercados de ações do mundo.

3 METODOLOGIA

No presente trabalho, serão construídas séries diárias de VaR para os modelos i) Gaussiano Incondicional, ii) *Best Fitting* Incondicional, iii) Gaussiano Condicional e iv) *Best Fitting* Condicional. Em seguida, através dos *backtestings*, identificam-se quais desses modelos apresentam resultados satisfatórios nos testes estatísticos. Por fim, para atender o objetivo principal da pesquisa, fazendo uso do gráfico de Balzer, será verificado qual setor, aqui representado por seu índice no mercado de ações, apresenta-se como mais arriscado sob o prisma do risco de mercado.

3.1 Value-at-Risk (VaR)

De acordo com Jorion (2010), em sua forma mais genérica, o VaR pode ser derivado da distribuição de probabilidade do valor futuro dos retornos, $f(r)$. A determinado nível de confiança, c , deseja-se descobrir a pior perda possível, R^* , tal que a probabilidade de se exceder esse valor seja c :

$$c = \int_{R^*}^{\infty} f(r) dr \quad (1)$$

Ou tal que a probabilidade de um valor menor que R^* , $p = P(r \leq R^*)$, seja $1 - c$:

$$1 - c = \int_{-\infty}^{R^*} f(r) dr = P(r \leq R^*) = p \quad (2)$$

O valor R^* é chamado de *quantil* da distribuição e corresponde a um valor de corte cuja probabilidade de ser excedida é fixa.

A fórmula do VaR é apresentada a seguir:

$$VaR = -W_0 R^* = W_0 (\alpha \sigma \sqrt{\Delta t} - \mu \Delta t) \quad (3)$$

$$R^* = -\alpha \sigma + \mu \quad (4)$$

onde: W_0 representa o valor do investimento inicial; R^* o retorno crítico (pior perda esperada); α a significância para o nível de confiança desejado; Δt o horizonte temporal escolhido; μ a média dos retornos e σ a volatilidade.

Neste estudo, será considerado que o valor de W_0 equivale a 1 (uma) unidade monetária. O cálculo do VaR será feito para o horizonte temporal de 1 (um) dia e para níveis de confiança de 95% e 99%. Conforme salienta Kimura *et. al.* (2008), a utilização do VaR para 1 dia tem se tornado padrão no mercado.

3.1.1 Modelos Gaussiano e Best Fitting Incondicionais

Para o cálculo dos modelos de *Value-at-Risk* incondicionais, admite-se que a volatilidade, medida pelo desvio padrão da série de retornos, mantém-se constante ao longo do tempo.

Fazendo uso da fórmula 3 e considerando que os retornos seguem uma distribuição normal, tem-se o modelo Gaussiano Incondicional. Para os níveis de confiança de 95 e 99%, os valores de α serão, respectivamente, de 1,65 e 2,33. Esses valores são obtidos a partir da distribuição normal padrão inversa para as referidas probabilidades. É importante ressaltar que, para o cálculo do VaR, interessa a análise dos valores posicionados na cauda esquerda das distribuições de probabilidades, representando as perdas.

Para o modelo *Best Fitting* Incondicional, não mais se utiliza a premissa de normalidade dos retornos. O teste Jarque-Bera confirma que os dados não seguem uma distribuição normal. Logo, deve-se, primeiramente, encontrar a distribuição de probabilidades que melhor se ajusta à série de retornos de cada índice setorial. Com o auxílio do *software EasyFit* e utilizando o teste Kolmogorov-Smirnov¹ como medida de classificação, chega-se a distribuição que melhor representa a série temporal (número 1 no *ranking* gerado pelo *software*).

¹ O teste de Kolmogorov-Smirnov avalia se os valores de uma amostra podem ser considerados como provenientes de uma população com determinada distribuição teórica. O teste é realizado calculando-se a distância euclidiana máxima (D) entre a função de distribuição empírica acumulada e a função de distribuição acumulada teórica que se deseja testar. A estatística do teste de Kolmogorov-Smirnov é definida por: $D_n = \text{Max}|F_e - F_o|$, em que: F_e é frequência relativa acumulada esperada e F_o é a frequência relativa acumulada observada. Se a estatística do teste for superior ao valor crítico, rejeita-se a hipótese nula de que os dados seguem a distribuição especificada (BRITO *et al.*, 2007).

Fazendo uso ainda do *EasyFit*, a partir da distribuição melhor classificada e para os níveis de confiança desejados, são fornecidos os retornos críticos (R^*), que representam os valores em risco para essa medida de VaR.

3.1.2 Modelos Gaussiano e Best Fitting Condicionais

Nos modelos condicionais, a volatilidade não mais permanece constante ao longo do tempo. O σ da fórmula 3 é substituído por um σ_t .

Para estimar a volatilidade condicional evoluindo no tempo, são apresentados, nesta subseção, os modelos ARCH (*Autoregressive Conditional Heterocedasticity*) introduzidos por Engle (1982) e GARCH (*Generalized Autoregressive Conditional Heterocedasticity*), modelo este apresentado por Bollerslev (1986) como extensão dos modelos ARCH. Esses modelos autoregressivos de heterocedasticidade condicional são não lineares no que se refere à variância. A heterocedasticidade das séries de retornos pôde ser confirmada através do teste ARCH-LM, apresentado oportunamente.

O modelo autoregressivo do tipo ARCH (m) pode ser representado por:

$$r_t = \sqrt{h_t} \varepsilon_t \quad (5)$$

$$h_t = \alpha_0 + \alpha_1 r_{t-1}^2 + \dots + \alpha_m r_{t-m}^2 \quad (6)$$

onde: ε_t i.i.d. com média zero, $\alpha_0 > 0$, $\alpha_i \geq 0$, $i = 1, \dots, m - 1$, $\alpha_m > 0$. Supõe-se que $\varepsilon_t \sim N(0,1)$.

O modelo generalizado, GARCH (m,n), pode ser assim definido:

$$r_t = \sqrt{h_t} \varepsilon_t \quad (7)$$

$$h_t = \alpha_0 + \sum_{i=1}^m \alpha_i r_{t-i}^2 + \sum_{j=1}^n \beta_j h_{t-j} \quad (8)$$

em que ε_t são v.a. i.i.d, com média zero, $\alpha_0 > 0$, $\alpha_i \geq 0$, $i = 1, \dots, m - 1$, $\beta_j \geq 0$, $j = 1, \dots, n - 1$, $\beta_n > 0$, $\sum_{i=1}^q (\alpha_i + \beta_i) < 1$, $q = \max(m, n)$. Supõe-se que os ε_t são

normais. Essas restrições ao modelo são necessárias para assegurar a estacionariedade e positividade da variância condicional.

Conforme salienta Mollica (1999), em geral, existe uma alta persistência na volatilidade das séries de retornos, o que faz com que o valor de m no modelo ARCH seja elevado, implicando a estimação de um grande número de parâmetros. O modelo GARCH, proposto por Bollerslev (1986), constitui-se numa 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.

Um outro ponto a ser ressaltado diz respeito à série de retornos ser, geralmente, não correlacionada, mas dependente. Nesse caso, a volatilidade é modelada por um modelo heterocedástico. Algumas séries de retornos ainda exibem a presença de autocorrelação, havendo a necessidade de eliminá-la por meio de um modelo linear (MORETTIN, 2011). O teste Ljung-Box será utilizado para se verificar a existência de autocorrelação nas séries.

Testada a estacionariedade das séries de retornos através do teste de raiz unitária (ADF) e confirmada a presença de autocorrelação, a média da série de retornos será modelada por um modelo autoregressivo e de médias móveis (ARMA)² e os resíduos desse modelo por um GARCH³, visto que foi detectada a presença de heterocedasticidade em todas as séries (teste ARCH-LM). Para um modelo ARMA(p,q)-GARCH(m,n), tem-se:

$$r_t = \varphi_0 + \sum_{i=1}^p \varphi_i r_{t-i} + \varepsilon_t - \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (9)$$

$$\varepsilon_t = \sigma_t v_t \quad v_t \sim N(0,1) \quad (10)$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^n \beta_j \sigma_{t-j}^2 \quad (11)$$

² Para maiores informações acerca dos modelos ARMA, verificar Gujarati (2006).

³ Conforme será visto na seção 4.3, para alguns índices setoriais a melhor especificação resultou em um modelo ARCH (m), equivalente a um modelo GARCH (m,0).

Utilizando-se o *software Eviews*, são feitas previsões um passo à frente para a média, $\hat{r}_t(1)$, e para a volatilidade, $\hat{\sigma}_t^2(1)$.

O VaR, calculado um passo à frente, será representado por:

$$VaR = \hat{r}_t(1) - \alpha \hat{\sigma}_t(1), \quad (12)$$

sendo $\hat{\sigma}_t(1)$ a raiz quadrada de $\hat{\sigma}_t^2(1)$ e α , para o VaR Gaussiano Condicional, obtido a partir do *p-quantil* da distribuição normal padrão inversa e, para o VaR *Best Fitting* Condicional, encontrado através da fórmula 4, considerando o retorno crítico (R^*) disponibilizado pelo *EasyFit*, a média e o desvio padrão incondicionais das séries de retornos. Neste trabalho, rememora-se, estão sendo utilizados níveis de confiança de 95 e 99%.

Vale destacar que, na busca da especificação mais adequada, foram estimados diversos modelos ARMA e GARCH, com todas as combinações possíveis até a defasagem 2, conforme recomendado em Morettin (2011). Os modelos utilizados nesta pesquisa foram selecionados a partir do menor critério de informação de Akaike (AIC), forma de seleção bastante usual na literatura. Adicionalmente, levou-se também em consideração as significâncias individuais dos coeficientes estimados. Após a escolha da melhor especificação, verificou-se ainda se esses modelos estimados apresentaram resíduos livres de heterocedasticidade.

3.2 Backtesting

O *backtesting* é uma ferramenta estatística para conferir a consistência entre as perdas observadas e as perdas previstas. A realização desse procedimento implica em comparar o histórico das perdas estimadas pelo VaR com os retornos observados dos índices.

Quando o modelo é perfeitamente ajustado, o número de observações que ultrapassa os limites do VaR deve estar em harmonia com o nível de confiança. Exemplificando, espera-se que o VaR seja excedido somente em 5% das observações para um nível de confiança de 95%.

O número de vezes em que a perda realizada excede o VaR é também conhecido como exceção. O modelo pode estar subestimando o risco quando são

verificadas muitas exceções. De outra forma, poucas exceções também representam um problema, pois pode levar a uma alocação de capital excessiva ou ineficiente.

A forma de *backtesting* mais simplificada consiste em registrar a taxa de exceções, correspondente à proporção (N) das vezes em que o resultado foi pior do que o VaR. Kupiec (1995) gerou regiões de confiança de aproximadamente 95% para esse tipo de teste. Essas regiões são definidas por uma razão de log-verossimilhança (*likelihood ratio*):

$$LR_{uc} = -2 \ln[(1 - p)^{T-N} p^N] + 2 \ln \{ [1 - (N/T)]^{T-N} (N/T)^N \}, \quad (13)$$

que possui distribuição assintótica qui-quadrada com 1 (um) grau de liberdade, sob a hipótese de que p é a verdadeira probabilidade (nível de significância do VaR). Portanto, rejeita-se a hipótese nula se $LR_{uc} > 3,84$. T representa o tamanho da amostra.

O teste de Kupiec representa um teste de cobertura incondicional. No entanto, as exceções podem estar “agrupadas” no tempo, o que pode também invalidar o modelo. De acordo com Jorion (2010), as exceções verificadas no modelo devem, teoricamente, ser distribuídas de maneira uniforme no tempo. Pode acontecer, no entanto, de as exceções se concentrarem em determinado intervalo de tempo. A volatilidade dos mercados pode estar aumentando sem que o VaR consiga capturar essa mudança, exemplifica o autor. Diante dessa limitação, Campbell (2005) adverte que o *backtesting* não deve depender unicamente dos testes de cobertura incondicional. Surgem então ferramentas de verificação capazes de medir a cobertura condicional correta, ou seja, condicional às condições de mercado vigentes.

Christoffersen (1998) foi quem desenvolveu esse tipo de teste, chamado de teste de cobertura condicional ou independência, estendendo a estatística LR_{uc} e especificando que os desvios devem ser serialmente independentes. A estatística do teste é definida como:

$$LR_{ind} = -2 \ln[(1 - \pi)^{(T_{00}+T_{10})} \pi^{(T_{01}+T_{11})}] + 2 \ln[1 - \pi_0]^{T_{00}} \pi_0^{T_{01}} (1 - \pi_1)^{T_{10}} \pi_1^{T_{11}} \quad (14)$$

O teste é desenvolvido de acordo com os seguintes passos: a cada dia, fixa-se um índice de desvio em 0 (zero), se o VaR for excedido, ou em 1 (um), caso contrário. Define-se T_{ij} como o número de dias em que o estado j ocorreu quando

o estado do dia anterior era i , e π_i como a probabilidade de observar uma exceção condicional ao estado i previamente registrado. A construção da tabela a seguir facilita o entendimento e a aplicação do teste.

Tabela 1 – Tabela de Exceções

Dia Atual	Condicional Dia Anterior		Incondicional
	Sem exceção	Com exceção	
Sem exceção	T_{00}	T_{10}	$T_{00} + T_{10}$
Com exceção	T_{01}	T_{11}	$T_{01} + T_{11}$
Total	$T_{00} + T_{01}$	$T_{10} + T_{11}$	T

Fonte: Adaptado de Niepolla (2009)

Tem-se que:

$$\pi_0 = \frac{T_{01}}{T_{00} + T_{01}} \quad \pi_1 = \frac{T_{11}}{T_{10} + T_{11}} \quad \pi = \frac{T_{01} + T_{11}}{T_{00} + T_{01} + T_{10} + T_{11}} \quad (15)$$

Para o modelo ser considerado válido, uma exceção verificada no dia atual deve ser independente do ocorrido no dia anterior.

Há ainda a estatística de teste agregada para a cobertura condicional que une as duas estatísticas anteriores, sendo representada por:

$$LR_{cc} = LR_{uc} + LR_{ind}, \quad (16)$$

distribuída assintoticamente de acordo com uma qui-quadrada com 2 (dois) graus de liberdade. Rejeita-se a hipótese nula, para um nível de confiança de 95%, se $LR_{cc} > 5,99$. De acordo com Jorion (2010), “esse enfoque é particularmente importante dada a forte evidência de que mercados atravessam períodos de turbulência seguidos por períodos de calma”.

Na literatura, podem ser encontrados outros tipos de *backtestings*, como a função de perda proposta por Lopez (1998) e a verificação através de regressão quantílica recomendada por Gaglianone (2007).

3.3 Gráficos de Balzer

Uma vez estimados e testados os modelos de *Value-at-Risk*, visando atingir o objetivo proposto no presente estudo, mostra-se oportuna e de grande valia a realização de uma análise comparativa entre os índices setoriais.

Conforme relembra Duarte Júnior (1997), um investidor está sempre procurando maximizar sua diferença de retorno em relação ao retorno de um *benchmark* e, ao mesmo tempo, minimizar seu risco em relação a esse *benchmark*. Nesse contexto, o gráfico de Balzer representa uma relação entre risco e retorno, reportando a evolução temporal do retorno e risco de um investimento.

Sabe-se que qualquer administrador ativo de recursos tem como objetivo superar a *performance* de algum *benchmark* em termos de retorno e risco. Isso implica em: i) a diferença entre o retorno obtido pelo administrador e seu *benchmark* deve ser preferencialmente positiva e ii) a diferença entre o risco corrido pelo administrador e seu *benchmark* deve ser preferencialmente negativa.

Nesse sentido, serão confrontados os seis índices setoriais dois a dois, gerando um total de 15 confrontos. Para cada dia do período amostral (01/2008 a 12/2011), toma-se o valor do retorno líquido nominal de um índice e dele se subtrai o valor do retorno do índice em confronto, obtendo-se, dessa forma, a série de diferenças diárias de retornos. O mesmo procedimento é feito para se conseguir as diferenças diárias de risco, neste trabalho representado pela métrica *Value-at-Risk*. Exemplificando, seleciona-se os retornos e riscos do índice 1 e subtrai-se dos do índice 2, gerando assim as séries de diferenças de retorno e risco em relação aos dois índices. Quanto maior as quantidades de diferenças negativas de risco e positivas de retorno, melhor a *performance* do índice 1 em relação ao índice 2.

4 RESULTADOS

4.1 Base de dados e estatísticas descritivas

A base de dados utilizada para elaboração do presente trabalho contém as cotações diárias de fechamento (*end-of-day*) de seis índices setoriais da Bolsa de Valores de São Paulo (BM&FBOVESPA), quais sejam: i) Índice Imobiliário (IMOB); ii) Índice de Energia Elétrica (IEE); iii) Índice de Consumo (ICON); iv) Índice do Setor Industrial (INDX); v) Índice Financeiro (IFNC); e vi) Índice Setorial de Telecomunicações (ITEL). As cotações referem-se ao período de 01/2008 a 12/2011, totalizando 991 observações. Doravante, serão usadas as respectivas siglas para referência aos índices.

Calculou-se, a partir das cotações, os retornos líquidos nominais diários para os índices setoriais em estudo, considerando que estes possuem propriedades estatísticas interessantes, como a estacionariedade. Assim, a série de retornos substituiu a série original de cotações dos índices.

Morettin (2011) relaciona os principais fatos estilizados relativos a retornos financeiros. São eles: i) retornos não são, em geral, autocorrelacionados; ii) os quadrados dos retornos são autocorrelacionados, apresentando uma correlação de *lag* um pequena e depois uma queda lenta das demais; iii) séries de retornos apresentam agrupamentos de volatilidade ao longo do tempo; iv) a distribuição (incondicional) dos retornos apresenta caudas mais pesadas do que uma distribuição normal; além disso, a distribuição, embora aproximadamente simétrica, é, em geral, leptocúrtica; e v) algumas séries de retornos são não lineares, ou seja, respondem de maneira diferente a choques grandes ou pequenos, ou ainda, a choques positivos ou negativos. Alguns desses pontos ficarão demonstrados através de testes estatísticos específicos ou pela análise visual de gráficos apresentados nesta seção.

A Tabela 2, a seguir, apresenta as principais estatísticas descritivas das séries temporais de retornos, possibilitando, ainda, a comparação com dois *benchmarks* de mercado: o índice IBOVESPA e a poupança.

A média dos retornos é próxima de zero, o que vai ao encontro da teoria financeira clássica. Observa-se no ganho acumulado, graficamente apresentado no

Gráfico 1, o excelente desempenho do IEE frente aos demais índices e aos *benchmarks* no período em análise, apresentado a melhor relação risco x retorno. O IFNC e o ITEL apresentaram desempenho próximo ao da poupança. O INDX e o IMOB tiveram retorno acumulado negativo, o último com perdas mais acentuadas.

Tabela 2 – Estatísticas descritivas dos retornos nominais diários dos índices setoriais vis-à-vis *benchmarks* de mercado ^a

		Índices Setoriais						Benchmarks de mercado	
		IMOB	IEE	ICON	INDX	IFNC	ITEL	IBOV	POUP
Ganho	Média	0,015%	0,075%	0,062%	0,019%	0,058%	0,049%	0,013%	0,028%
	Mínimo	-15,033%	-6,962%	-9,219%	-11,143%	-12,057%	-12,828%	-11,393%	0,022%
	Máximo	19,453%	12,301%	12,557%	12,544%	20,922%	14,140%	14,659%	0,039%
	Acumulado	-23,167%	91,789%	59,285%	-1,632%	31,669%	35,892%	-9,649%	32,480%
Risco	Desvio padrão	2,889%	1,366%	1,708%	2,042%	2,465%	1,911%	2,179%	0,003%
	Semivariância	2,005%	0,947%	1,198%	1,455%	1,640%	1,308%	1,524%	0,002%
	Downside risk (RMA=Ibovespa)	1,106%	0,960%	0,738%	0,448%	0,688%	0,960%	0,000%	1,548%
	Downside risk (RMA=Poupança)	2,012%	0,925%	1,182%	1,460%	1,625%	1,298%	1,531%	0,000%
	Drawdown	78,586%	27,030%	44,568%	55,524%	50,766%	37,509%	54,154%	0,000%
	Beta de Mercado	1,104	0,501	0,692	0,899	1,022	0,682	1,000	0,000
3º e 4º momentos	Assimetria	0,222	0,663	0,279	0,064	0,878	0,482	0,315	0,919
	Curtose	5,163	12,576	7,057	5,713	8,711	7,917	6,573	1,113
Performance	Sharpe	-0,005	0,034	0,019	-0,005	0,012	0,011	-0,007	0,000
	Sortino (Downside risk)	0,001	0,064	0,065	0,013	0,064	0,037	-	0,010
	Sortino (Semivariância)	0,001	0,065	0,040	0,004	0,027	0,027	0,000	7,065
	Treynor	0,000	0,001	0,000	0,000	0,000	0,000	0,000	-
	Calmar	0,000	0,002	0,001	0,000	0,001	0,001	0,000	-

Nota: ^a Séries temporais diárias dos retornos nominais líquidos no período de 01/2008 a 12/2011 (991 observações).

Fonte: Elaboração da autora

Dentre as métricas de risco apresentadas, ressalta-se o desvio padrão. Quanto maior essa medida, maior o risco associado ao ativo. A semivariância representa a variância das observações que apresentaram retornos inferiores ao retorno médio. Na mesma linha, o *downside risk* diz respeito ao risco de que o retorno proporcionado por um ativo esteja abaixo do retorno mínimo aceitável (RMA), sendo utilizado como medida do RMA os dois *benchmarks* de mercado. Essa métrica, portanto, preocupa-se apenas com a volatilidade indesejada, aquela que gera perdas ao investidor. O IMOB apresentou maior valor tanto para o RMA medido pelo IBOVESPA como pela poupança. Já o INDX apresentou menor valor tendo como RMA o IBOVESPA.

O *drawdown* traduz o declínio desde o valor máximo da série até o valor mínimo, representando a queda acumulada no período de análise.

O beta de mercado, por sua vez, mede a sensibilidade do ativo em relação a variações do mercado, utilizando-se como *proxy* da carteira de mercado o IBOVESPA.

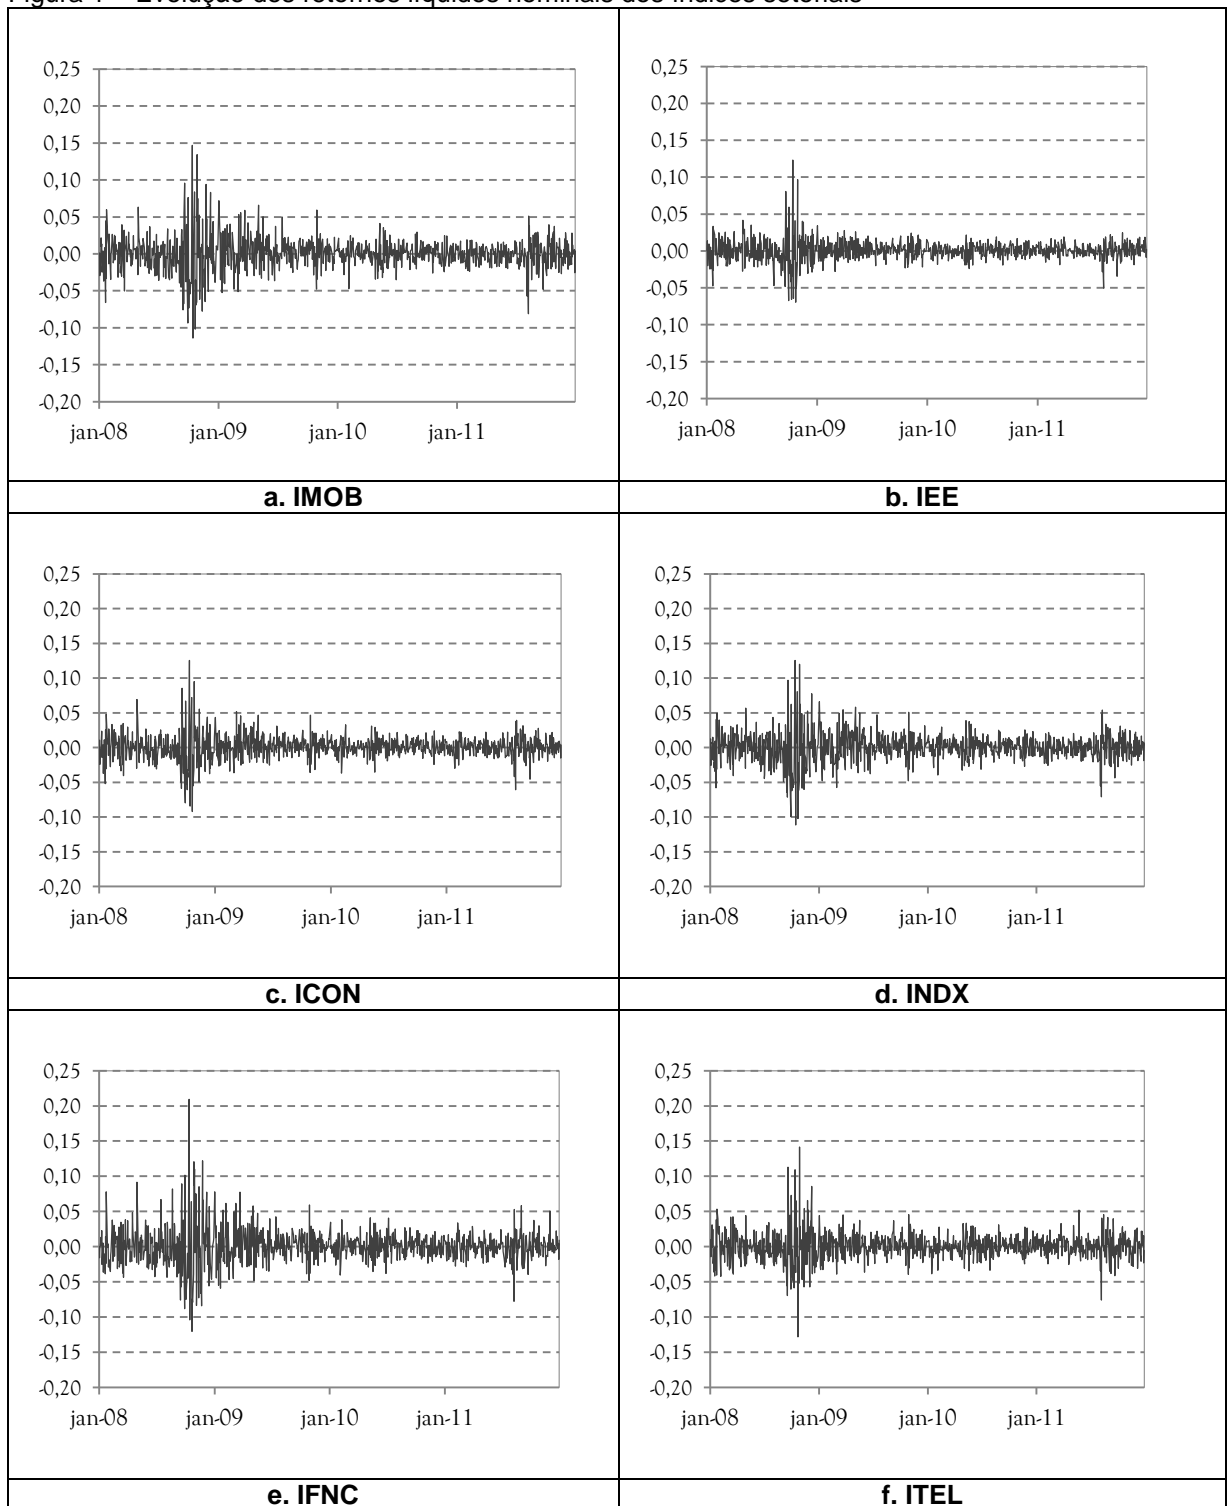
Em relação à curtose das séries, pode ser observado excesso em relação à distribuição normal para todos os índices, com destaque para o IEE.

No final da Tabela 2 são apresentados alguns índices de *performance*, permitindo uma análise do retorno ponderado pelo risco. O índice de Sharpe mensura o quanto de retorno excedente em relação a um ativo livre de risco é compensado através de seu nível de risco, medido pelo desvio padrão da série de retornos, enquanto o índice de Treynor não considera o risco total, mas apenas o risco sistemático (beta de mercado). Já o índice de Calmar considera o *drawdown* como métrica de risco. O índice de Sortino, por fim, analisa o desempenho em relação ao IBOVESPA. É calculado tendo como medida de risco a semivariância e o *downside risk*.

Destaca-se que, para todos os índices de *performance* analisados, o IEE exibe melhor desempenho, resultado já esperado considerando que esse índice setorial apresenta retorno médio maior e métricas de risco menores em relação aos demais.

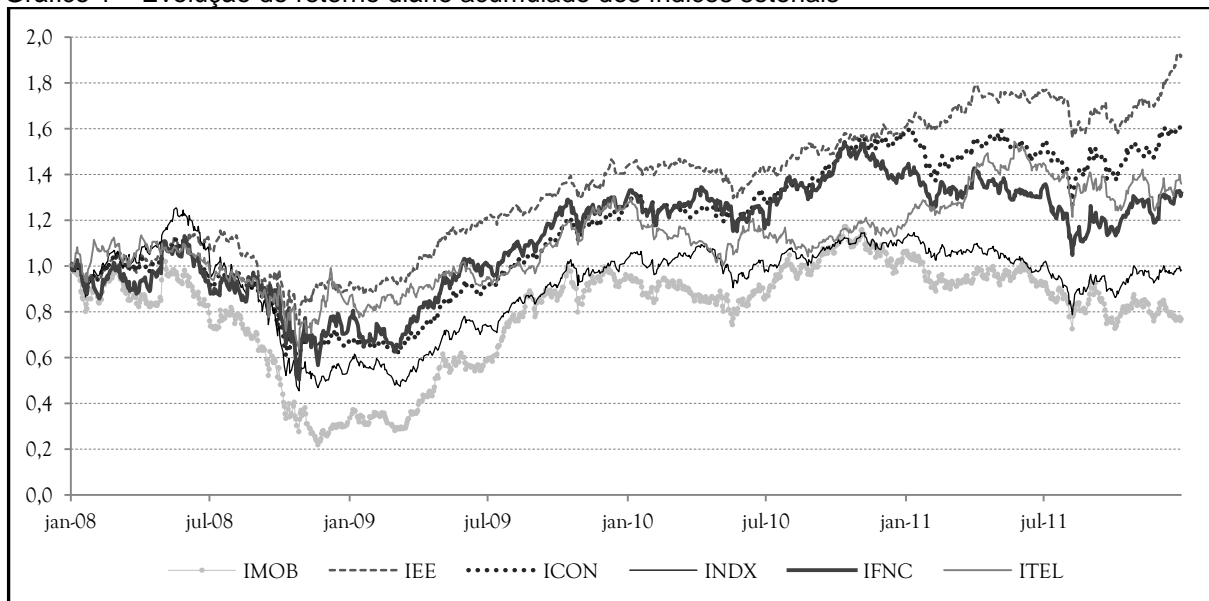
Na Figura 1, têm-se os gráficos dos retornos líquidos nominais, onde pode ser observado, para todos os índices, acentuados picos de volatilidade causados, sobretudo, pela crise internacional de 2008. Evidenciam-se, dessa forma, alterações na volatilidade ao longo da série.

Figura 1 – Evolução dos retornos líquidos nominais dos índices setoriais ^a



Nota: ^a Séries de retorno líquido nominal diário obtido a partir da série temporal de cotação de fechamento (*end-of-day*) dos índices setoriais durante o período de janeiro de 2008 a dezembro de 2011 (991 observações).

Fonte: Elaboração da autora

Gráfico 1 – Evolução do retorno diário acumulado dos índices setoriais ^a

Nota: ^a Retorno bruto nominal diário acumulado obtido a partir da série temporal de cotação de fechamento (*end-of-day*) dos índices setoriais durante o período de janeiro de 2008 a dezembro de 2011; 991 observações.

Fonte: Elaboração da autora

4.2 Modelos *Best Fitting*

As evidências sugerem que as distribuições de probabilidades para séries de retornos possuem caudas mais pesadas que as da distribuição normal, verificando-se com maior frequência a ocorrência de valores extremos (GOURIEROUX; JASIAK, 2001). Diante desse fato estilizado, a fim de se testar a hipótese de normalidade dos retornos, realizou-se o teste Jarque-Bera, cujo resultado está exposto na tabela a seguir.

Tabela 3 – Normalidade dos retornos dos índices setoriais ^{a,b}

Índices	Jarque-Bera	Prob.
IMOB	1095,081	0,0000
IEE	6531,388	0,0000
ICON	2045,259	0,0000
INDX	1332,028	0,0000
IFNC	3224,649	0,0000
ITEL	2596,536	0,0000

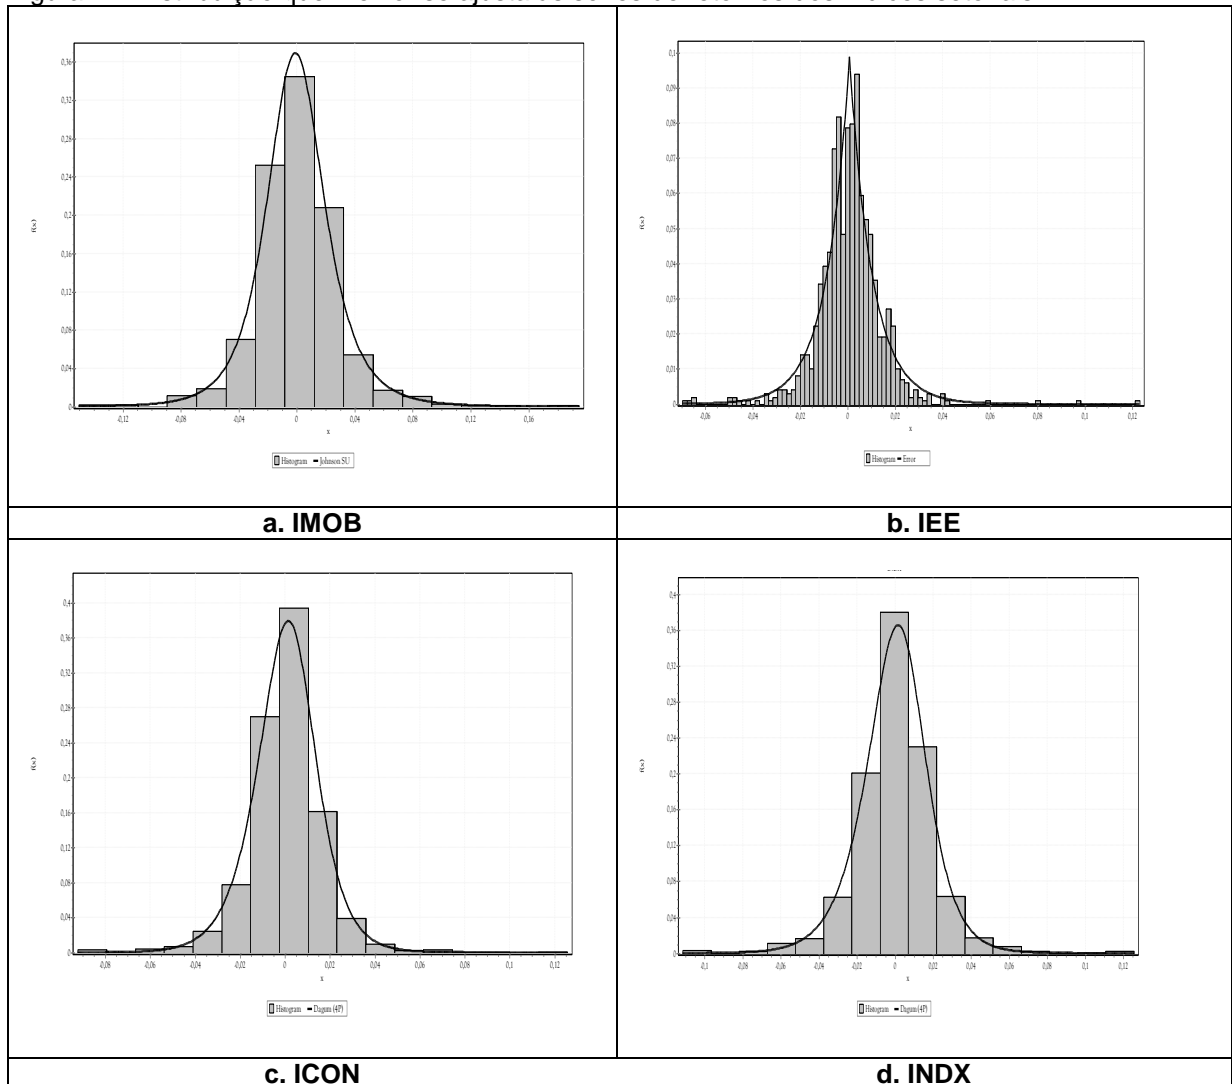
Nota: ^a Teste Jarque-Bera cuja estatística de teste mede a diferença de assimetria e curtose da série em relação à distribuição normal. A hipótese nula do teste é de que a série segue uma distribuição normal. / ^b Utilização do *software Eviews 5*.

Fonte: Elaboração da autora


Para os seis índices setoriais a hipótese nula do teste, de normalidade dos retornos, é rejeitada. O entendimento teórico é, portanto, confirmado empiricamente.

Constatada a não normalidade da série de retornos, passa-se então a buscar a distribuição de probabilidades que melhor se ajusta aos dados das séries estudadas, objetivando obter o VaR *Best Fitting* tanto incondicional, com a volatilidade fixa, como condicional, com a volatilidade variando ao longo do tempo. Com o auxílio do *software EasyFit*, encontrou-se a distribuição que melhor representa o conjunto de dados e ainda a posição da distribuição normal no *ranking* de aproximadamente 60 distribuições disponibilizado pelo programa. A Figura 2 traz as funções densidades de probabilidades das distribuições que ocuparam a melhor posição no *ranking*.

Figura 2 – Distribuição que melhor se ajusta às séries de retornos dos índices setoriais ^{a,b}



(continua)

Figura 2 – Distribuição que melhor se ajusta às séries de retornos dos índices setoriais ^{a,b} (continuação)

Nota: ^a Séries de retorno líquido nominal diário obtido a partir da série temporal de cotação de fechamento (*end-of-day*) dos índices setoriais durante o período de janeiro de 2008 a dezembro de 2011; 991 observações. / ^b Utilização do programa *Easyfit 5.5 Professional*; melhor distribuição obtida através do teste Kolmogorov-Smirnov.

Fonte: Elaboração da autora

Tabela 4 – Melhor distribuição para as séries de retornos dos índices setoriais ^a

Índice	Melhor Distribuição ^d	Parâmetros	R*(1%) ^b	$\alpha(1\%)^c$	R*(5%) ^b	$\alpha(5\%)^c$	Posição da Distribuição Normal no ranking ^d
IMOB	Johnson SU	$\gamma=0,08569$ $\delta=1,4023$ $\lambda=0,03068$ $\xi=0,00227$	-0,0750	2,60	-0,0439	1,52	16 ^a
IEE	Error	$k=1,0$ $\sigma=0,01366$ $\mu=7,5006E4$	-0,0370	2,77	-0,0211	1,60	11 ^a
ICON	Dagum (4P)	$k=0,71532$ $\alpha=38,427$ $\beta=0,29221$ $\gamma=-0,28774$	-0,0406	2,41	-0,0256	1,53	15 ^a
INDX	Dagum (4P)	$k=0,68494$ $\alpha=41,9$ $\beta=0,37604$ $\gamma=-0,37051$	-0,0502	2,47	-0,0316	1,56	13 ^a
IFNC	Laplace	$\lambda=57,369$ $\mu=5,7760E-4$	-0,0676	2,77	-0,0396	1,63	20 ^a
ITEL	Johnson SU	$\gamma=-0,14072$ $\delta=1,2829$ $\lambda=0,01742$ $\xi=-0,0021$	-0,0484	2,56	-0,0275	1,47	12 ^a

Nota: ^a Séries de retorno líquido nominal diário obtido a partir da série temporal de cotação de fechamento (*end-of-day*) dos índices setoriais, durante o período de janeiro de 2008 a dezembro de 2011; 991 observações. / ^b Valores dos retornos críticos disponibilizados pelo programa *Easyfit 5.5 Professional*. / ^c Calculados a partir da fórmula do retorno crítico (fórmula 4). / ^d Utilização do *Easyfit 5.5 Professional*; melhor distribuição obtida através do teste Kolmogorov-Smirnov; *ranking* de distribuições de probabilidades disponibilizado pelo programa.

Fonte: Elaboração da autora

Observa-se na Tabela 4 que a distribuição normal aparece, para todos os índices sob análise, acima da 10^a posição no *ranking*, não podendo ser considerada um bom ajuste para as séries de retornos em estudo. Uma vez encontrada a distribuição teórica, obtêm-se, ainda com o auxílio do *Easyfit*, os valores dos

retornos críticos para níveis de significância de 1 e 5%. Em seguida, são calculados os valores de $\alpha(1\%)$ e $\alpha(5\%)$. Esses valores serão utilizados para a construção das séries de VaR *Best Fitting*.

4.3 Modelos ARMA-GARCH

Considerando que a série de retornos é heterocedástica, conforme afirmado teoricamente, serão apresentados nesta seção os testes e modelos ARMA-GARCH, empregados para estimar a média e a volatilidade condicionais. Os resultados oriundos desses modelos serão úteis para a construção das duas séries de VaR condicionais (Gaussiano e *Best Fitting*), denominação essa criada para desenvolvimento do presente trabalho.

Procede-se, inicialmente, a realização do teste de estacionariedade, constatando-se que todas as séries são estacionárias.

Tabela 5 – Estacionariedade dos retornos dos índices setoriais ^{a,b}

Índices	Estatística t	Valor Crítico (5% de significância)	Prob.
IMOB	-28,04300	-2,864248	0,0000
IEE	-33,04497	-2,864248	0,0000
ICON	-32,83709	-2,864248	0,0000
INDX	-30,94235	-2,864248	0,0000
IFNC	-20,76366	-2,864248	0,0000
ITEL	-33,28212	-2,864248	0,0000

Nota: ^a Teste de raiz unitária de Dickey-Fuller em sua versão aumentada (ADF) cuja hipótese nula é de existência de raiz unitária. Realizado teste em nível, com intercepto. / ^b Utilização do *Eviews 5*.
Fonte: Elaboração da autora

Estimados os modelos ARMA, realiza-se, em seguida, o teste de autocorrelação dos resíduos (tabela 6). Segundo a teoria econométrica, a existência de autocorrelação entre os retornos quadráticos é um indicativo do efeito de heterocedasticidade dos dados, o que foi comprovado no teste ARCH-LM (tabela 7).

Tabela 6 – Modelos ARMA estimados para as séries de retornos dos índices setoriais ^a e testes de autocorrelação dos resíduos ^b

Índice	Modelo ARMA	Q ₁ (6)	Q ₁ (12)	Q ₁ (18)	Q ₂ (6)	Q ₂ (12)	Q ₂ (18)
IMOB	ARMA (2,2)	3,1416 (0,208)	9,4969 (0,302)	16,582 (0,279)	359,64 (0,000)	808,63 (0,000)	1053,0 (0,000)
IEE	ARMA (1,1)	5,2960 (0,258)	15,193 (0,125)	25,027 (0,069)	344,31 (0,000)	816,63 (0,000)	1029,0 (0,000)
ICON	ARMA (1,1)	5,3463 (0,254)	11,348 (0,331)	21,989 (0,144)	509,07 (0,000)	1038,5 (0,000)	1287,6 (0,000)

(continua)

Tabela 6 – Modelos ARMA estimados para as séries de retornos dos índices setoriais ^a e testes de autocorrelação dos resíduos ^b (continuação)

Índice	Modelo ARMA	Q ₁ (6)	Q ₁ (12)	Q ₁ (18)	Q ₂ (6)	Q ₂ (12)	Q ₂ (18)
INDX	ARMA (2,2)	3,2484 (0,197)	11,805 (0,160)	20,224 (0,123)	468,95 (0,000)	978,81 (0,000)	1257,8 (0,000)
IFNC	ARMA (2,1)	11,062 (0,011)	17,745 (0,038)	32,196 (0,006)	329,14 (0,000)	785,21 (0,000)	1130,2 (0,000)
ITEL	ARMA (2,1)	14,622 (0,002)	20,991 (0,013)	29,515 (0,014)	213,02 (0,000)	458,19 (0,000)	584,59 (0,000)

Nota: ^a Modelos ARMA estimados via Mínimos Quadrados Ordinários (MQO) através do *software Eviews 5*. / ^b Teste de Ljung-Box cuja hipótese nula é de que não há autocorrelação residual. Q₁(k) e Q₂(k) referem-se, respectivamente, às estatísticas para as defasagens de ordem k para os resíduos e para o quadrado dos resíduos do modelo ARMA. Os p-valores estão entre parênteses.

Fonte: Elaboração da autora

Tabela 7 – Heterocedasticidade nos modelos ARMA estimados para as séries de retornos dos índices setoriais ^a

Índice	F-statistic	Prob.	Obs *R-Squared	Prob.
IMOB	51,538	0,000	49,078	0,000
IEE	37,258	0,000	35,975	0,000
ICON	29,812	0,000	28,996	0,000
INDX	19,368	0,000	19,033	0,000
IFNC	42,289	0,000	40,632	0,000
ITEL	9,113	0,003	9,048	0,003

Nota: ^a Teste *ARCH LM* cuja hipótese nula é de que há efeito ARCH nos resíduos. Teste realizado através do *software Eviews 5* para uma defasagem.

Fonte: Elaboração da autora

A fim de modelar a volatilidade condicional das séries, estimaram-se modelos do tipo GARCH. Nota-se na Tabela 8 que, para o índice ICON, a melhor especificação encontrada foi um modelo GARCH (2,0), o que equivale a um modelo ARCH (2). Um ponto que indica o bom ajustamento do modelo pode ser observado pelos p-valores dos coeficientes estimados, apresentados entre parênteses na tabela. A estatística *t* dos parâmetros de regressão tem como hipótese nula os coeficientes do modelo serem iguais a zero. Os p-valores, em sua maioria, não são rejeitados ao nível de significância de 5 ou 10%. Também é mostrado o critério de informação de Akaike (AIC), importante critério para se escolher o modelo mais ajustado. Quanto menor o AIC, melhor o critério de ajuste.

A Figura 3 apresenta as volatilidades condicionais estimadas a partir dos modelos apresentados na Tabela 8. Pela análise visual, é possível verificar agrupamentos de volatilidade mais concentrados no período de setembro a dezembro de 2008, reflexo da crise internacional de 2008. Os índices imobiliário (IMOB) e financeiro (IFNC) foram os mais afetados, provavelmente por se tratarem de setores diretamente envolvidos na crise financeira de repercussão mundial.

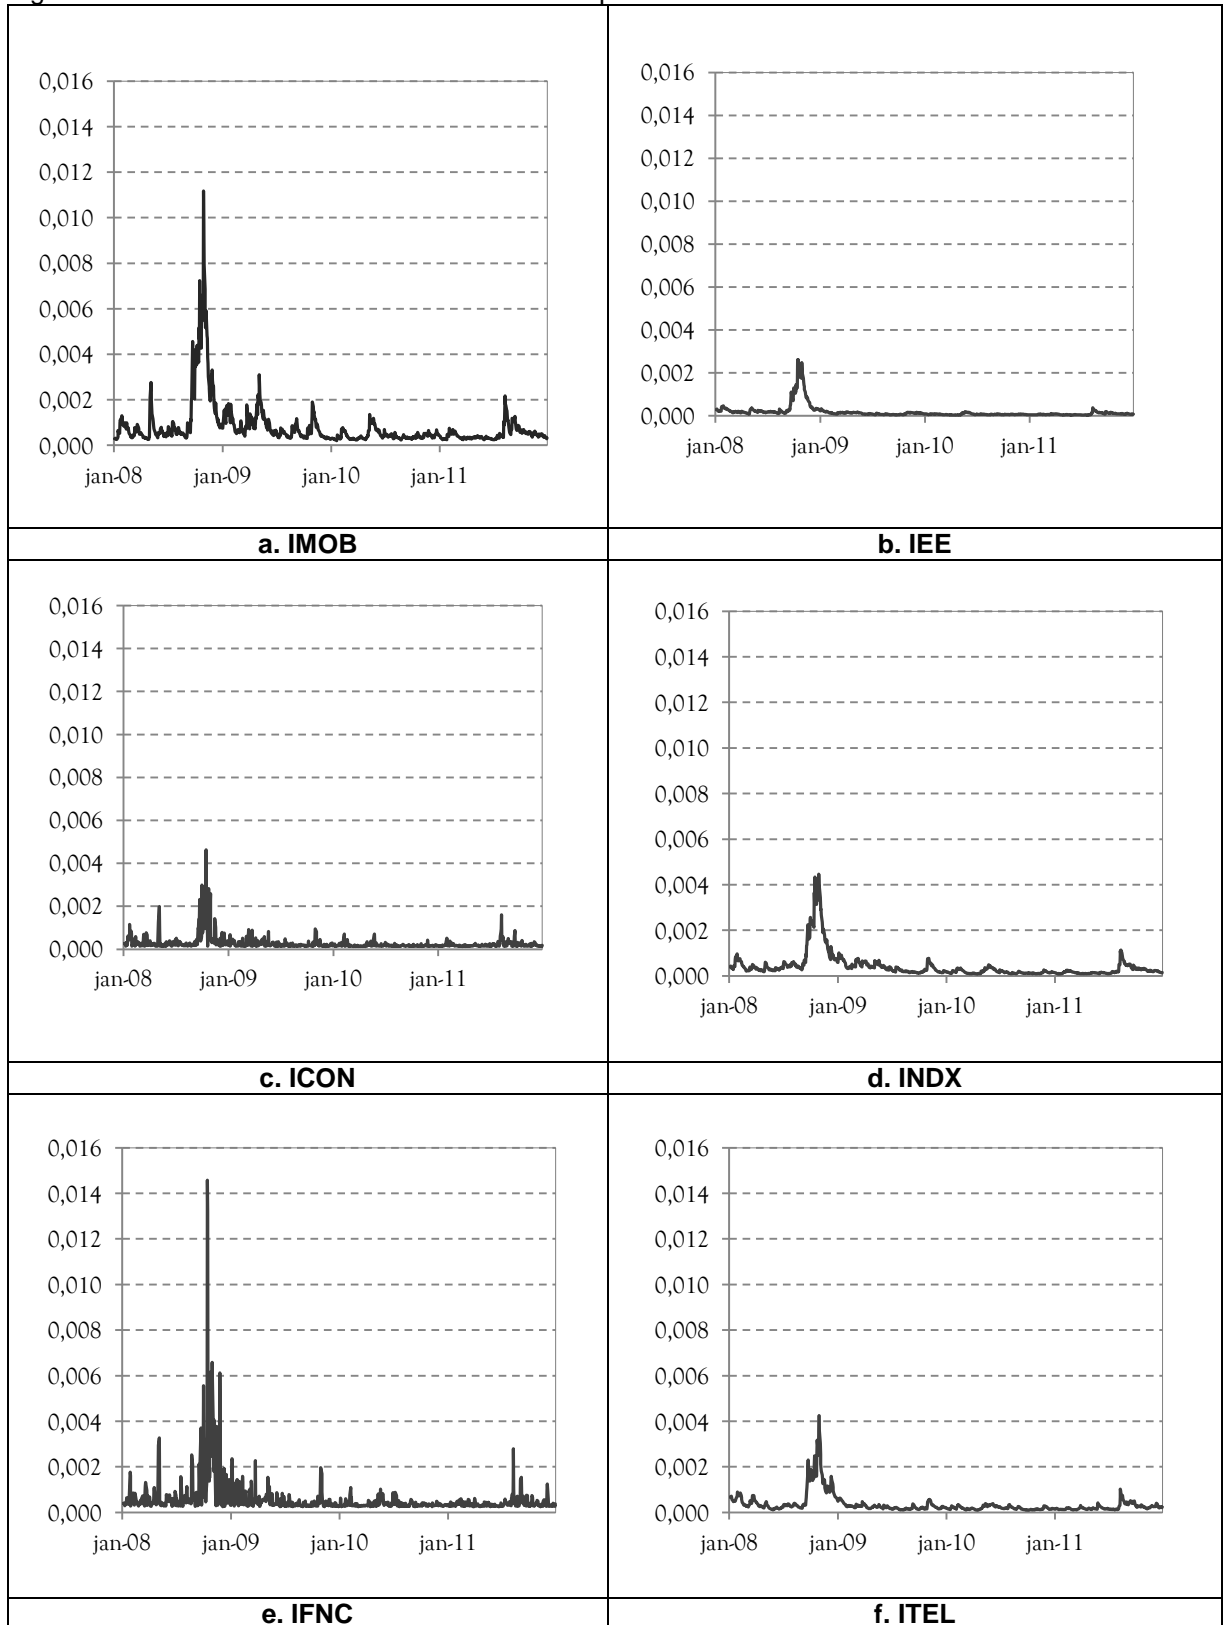
Tabela 8 – Modelos ARMA-GARCH estimados para os retornos dos índices setoriais ^{a,b}

Índice	Melhor Modelo	Modelo estimado (com prob. Est. t)	Critério de Informação de Akaike
IMOB	ARMA(2,2)-GARCH(1,1)	$r_t = 0,000203 - 0,178819 r_{t-1} - 0,744588 r_{t-2} - 0,255816 \varepsilon_{t-1} - 0,767501 \varepsilon_{t-2} + \varepsilon_t$ <p style="text-align: center;">(0,7613) (0,1758) (0,0000) (0,0449) (0,0000)</p> $\sigma_t^2 = 3,05E-05 + 0,153566 \varepsilon_{t-1}^2 + 0,805551 \sigma_{t-1}^2$ <p style="text-align: center;">(0,0174) (0,0000) (0,0000)</p>	-4,597105
IEE	ARMA(1,1)-GARCH(1,1)	$r_t = 0,000857 - 0,956941 r_{t-1} - 0,936647 \varepsilon_{t-1} + \varepsilon_t$ <p style="text-align: center;">(0,0035) (0,0000) (0,0000)</p> $\sigma_t^2 = 2,31E-06 + 0,099102 \varepsilon_{t-1}^2 + 0,885106 \sigma_{t-1}^2$ <p style="text-align: center;">(0,0071) (0,0030) (0,0000)</p>	-6,215071
ICON	ARMA(1,1)-GARCH(2,0)	$r_t = 0,000984 + 0,682909 r_{t-1} + 0,742077 \varepsilon_{t-1} + \varepsilon_t$ <p style="text-align: center;">(0,0040) (0,0007) (0,0001)</p> $\sigma_t^2 = 0,000131 + 0,191175 \varepsilon_{t-1}^2 + 0,317198 \varepsilon_{t-2}^2$ <p style="text-align: center;">(0,0000) (0,0008) (0,0000)</p>	-5,563535
INDX	ARMA(2,2)-GARCH(1,1)	$r_t = 0,000707 - 0,865353 r_{t-1} - 0,815773 r_{t-2} - 0,889059 \varepsilon_{t-1} - 0,857413 \varepsilon_{t-2} + \varepsilon_t$ <p style="text-align: center;">(0,1362) (0,0000) (0,0000) (0,0000) (0,0000)</p> $\sigma_t^2 = 4,66E-06 + 0,108192 \varepsilon_{t-1}^2 + 0,880441 \sigma_{t-1}^2$ <p style="text-align: center;">(0,0577) (0,0001) (0,0000)</p>	-5,339430
IFNC	ARMA(2,1)-GARCH(0,2)	$r_t = 0,000990 - 0,937901 r_{t-1} + 0,031376 r_{t-2} - 0,948167 \varepsilon_{t-1} + \varepsilon_t$ <p style="text-align: center;">(0,1384) (0,0000) (0,5421) (0,0000)</p> $\sigma_t^2 = 0,000253 + 0,303414 \varepsilon_{t-1}^2 + 0,284555 \varepsilon_{t-2}^2$ <p style="text-align: center;">(0,0000) (0,0007) (0,0004)</p>	-4,850270
ITEL	ARMA(2,1)-GARCH(2,1)	$r_t = 0,000588 - 0,975519 r_{t-1} - 0,017373 r_{t-2} - 0,944783 \varepsilon_{t-1} + \varepsilon_t$ <p style="text-align: center;">(0,1824) (0,0000) (0,6225) (0,0000)</p> $\sigma_t^2 = 1,20E-05 + 0,068066 \varepsilon_{t-1}^2 + 0,062554 \varepsilon_{t-2}^2 + 0,829649 \sigma_{t-1}^2$ <p style="text-align: center;">(0,0310) (0,0900) (0,3316) (0,0000)</p>	-5,407771

Nota: ^a Modelos estimados através do *software Eviews 5*. Para os modelos ARMA-GARCH foi utilizada a distribuição normal (gaussiana) para a distribuição dos erros./ ^b Valores entre parênteses representam as probabilidades das estatísticas t .

Fonte: Elaboração da autora

Figura 3 – Volatilidade condicional dos retornos líquidos nominais dos índices setoriais ^{a,b}



Nota: ^a Séries de retorno líquido nominal diário obtido a partir da série temporal de cotação de fechamento (*end-of-day*) dos índices setoriais durante o período de janeiro de 2008 a dezembro de 2011; 991 observações. / ^b Volatilidade condicional obtida através dos modelos ARMA-GARCH. Previsão um passo à frente realizada com o auxílio do *software Eviews 5* utilizando o método de previsão estática.

Fonte: Elaboração da autora

Finalizando a seção, apresenta-se, a seguir, a Tabela 9, contendo o teste ARCH-LM dos resíduos dos modelos ARMA-GARCH estimados, não mais se verificando a presença de heterocedasticidade, sugerindo, portanto, a correção do problema.

Tabela 9 – Heterocedasticidade nos modelos ARMA-GARCH estimados para as séries de retornos dos índices setoriais^a

Índice	F-statistic	Prob.	Obs *R-Squared	Prob.
IMOB	0,066	0,798	0,066	0,798
IEE	0,068	0,794	0,069	0,793
ICON	0,105	0,746	0,105	0,746
INDX	0,207	0,649	0,208	0,649
IFNC	0,276	0,599	0,276	0,599
ITEL	0,001	0,972	0,001	0,972

Nota: ^a Teste *ARCH LM* cuja hipótese nula é de que há efeito ARCH nos resíduos. Teste realizado através do *software Eviews 5* para uma defasagem.

Fonte: Elaboração da autora

4.4 Estimação do *Value-at-Risk* e *Backtesting*

Conhecidos os parâmetros necessários e estimada a volatilidade condicional das séries, têm-se todas as ferramentas para construção das séries diárias de VaR para todos os modelos trabalhados no presente estudo. Recapitulando, tem-se: i) VaR Gaussiano Incondicional; ii) VaR *Best Fitting* Incondicional, iii) VaR Gaussiano Condicional e iv) VaR *Best Fitting* Condicional.


As Figuras 4 e 5 trazem os gráficos das séries de retornos e das séries de VaR para os modelos Gaussianos e *Best Fitting*, condicionais e incondicionais, para o nível de confiança de 95%. As taxas de exceções verificadas para todos os modelos encontram-se inseridas na Tabela 10.

Atendo-se, em um primeiro momento, à Figura 4, verifica-se que a série de VaR Gaussiano Incondicional mostra-se bem conservadora para todos dos índices, concentrando os momentos de violações no final do ano de 2008, reflexo da crise do *subprime*, que trouxe bastante turbulência para o mercado de ações. As violações para esse modelo permaneceram dentro do limite esperado de 5%, sendo a maior violação verificada no INDX e a menor no IEE. Em comparação com a série Gaussiana Condicional, nota-se um aumento no número de violações para todos os índices, em especial para os índices ICON, INDX e ITEL, que ultrapassaram discretamente o limite de 5%.

Passando à Figura 5, verifica-se, por uma análise visual, que as séries de VaR *Best Fitting* Incondicional e Gaussiano Incondicional estão praticamente no mesmo nível para os seis índices, porém, calculando-se o número de violações, foi constatado um aumento considerável, na ordem de aproximadamente 30%, na série *Best Fitting* Incondicional para os índices IMOB e ITEL, chegando este último índice a um percentual de violações de 5,25%.

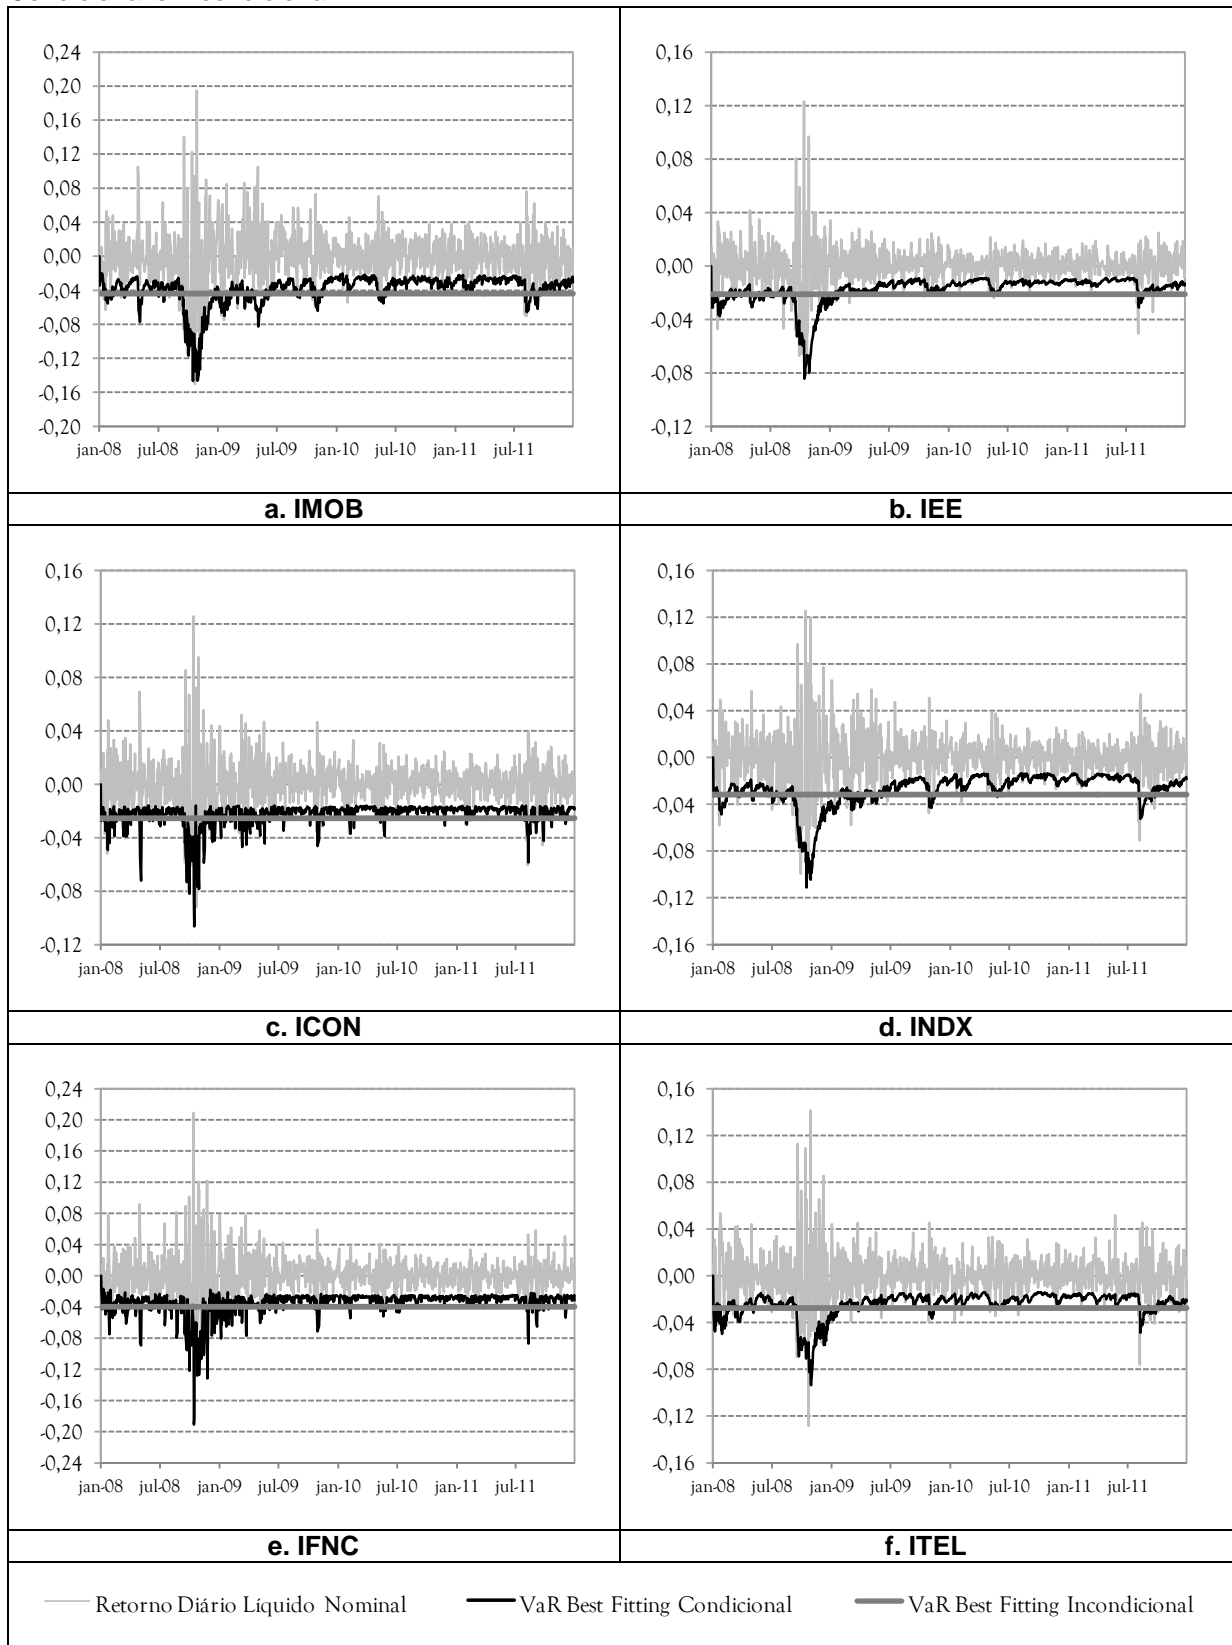
A série de VaR *Best Fitting* Condicional, ilustrada na Figura 5, apresenta maior quantidade de violações para todos os setores dentre os quatro modelos aqui analisados. Apenas o IFNC apresentou taxa de violação inferior a 5% para esse modelo. Já o ITEL apresentou taxa de 7,67%, que representa um aumento de 41% em relação às violações verificadas para esse índice no modelo Gaussiano Condicional. Constata-se, adicionalmente, que o ITEL, para os quatro modelos propostos, apresentou a maior quantidade de violações para três deles, se comparado aos demais índices.

Figura 4 – Séries estimadas de VaR para 01 dia, com 95% de confiança, para os Modelos Gaussiano Condicional e Incondicional ^a



(continua)

Figura 5 – Séries estimadas de VaR para 01 dia, com 95% de confiança, para os Modelos *Best Fitting* Condicional e Incondicional ^a



Nota: ^a Procedimento realizado através de previsões *in-sample* para toda a amostra (período de 01/2008 a 12/2011; 991 observações).

Fonte: Elaboração da autora

Considerando o nível de confiança de 99%, têm-se as Figuras 6 e 7, que trazem, respectivamente, as séries de VaR Gaussianos e *Best Fitting*.

Na Figura 6, para as exceções verificadas nos dois modelos Gaussianos, todos os índices apresentaram taxas de exceção superiores à esperada, de 1%, com destaque negativo para o INDX, cuja taxa resultou em 2,02% para o VaR incondicional. Três índices (IMOB, INDX e IFNC) apresentaram redução no número de violações em relação ao modelo incondicional, sendo a mais significativa encontrada no INDX, na ordem de 20%. Vale destacar que o efeito da crise financeira de 2008 nas violações do Gaussiano Incondicional é bastante significativo. Em média, considerando o período de 09/2008 a 12/2008 e os seis índices sob estudo, 78% das violações observadas ocorreram nesse período. No modelo condicional essa média é de 31%. Esse efeito já era esperado, uma vez que os modelos condicionais, por levarem em consideração informações passadas, conseguem fazer melhores previsões.

Para as duas séries de VaR *Best Fitting* a 99% de confiança, ao contrário do observado para o nível de 95%, houve uma redução considerável nas violações em relação aos modelos Gaussianos, demonstrando um certo conservadorismo dos modelos não Gaussianos. Para a série *Best Fitting* Incondicional, apenas o ITEL apresentou taxa de exceção em conformidade com o esperado. Já para o VaR *Best Fitting* Condicional, três índices apresentaram taxas iguais ou inferiores a 1%. Ressalta-se, uma vez mais, que, tanto taxas muito inferiores quanto taxas excessivamente superiores ao nível de exceções esperado pelo modelo, mostram-se insatisfatórias, indicando que o modelo está superestimando ou subestimando o risco.

Por fim, considerando as Figuras 6 e 7, o índice ITEL apresenta as menores taxas para três dos quatros modelos analisados, resultado contrário ao observado para o nível de confiança de 95%, tratado anteriormente.

Necessário se faz proceder uma verificação estatística que valide ou não os modelos de VaR. Conforme bem salientou Jorion (2010), “medidas de VaR são úteis quando conseguem prever o risco de forma razoável”. Isso posto, passa-se a examinar os resultados dos *backtestings* propostos neste trabalho.

A Tabela 10 exhibe, para todos os modelos de VaR e índices aqui tratados, com níveis de confiança de 95 e 99%, as quantidades e os respectivos percentuais

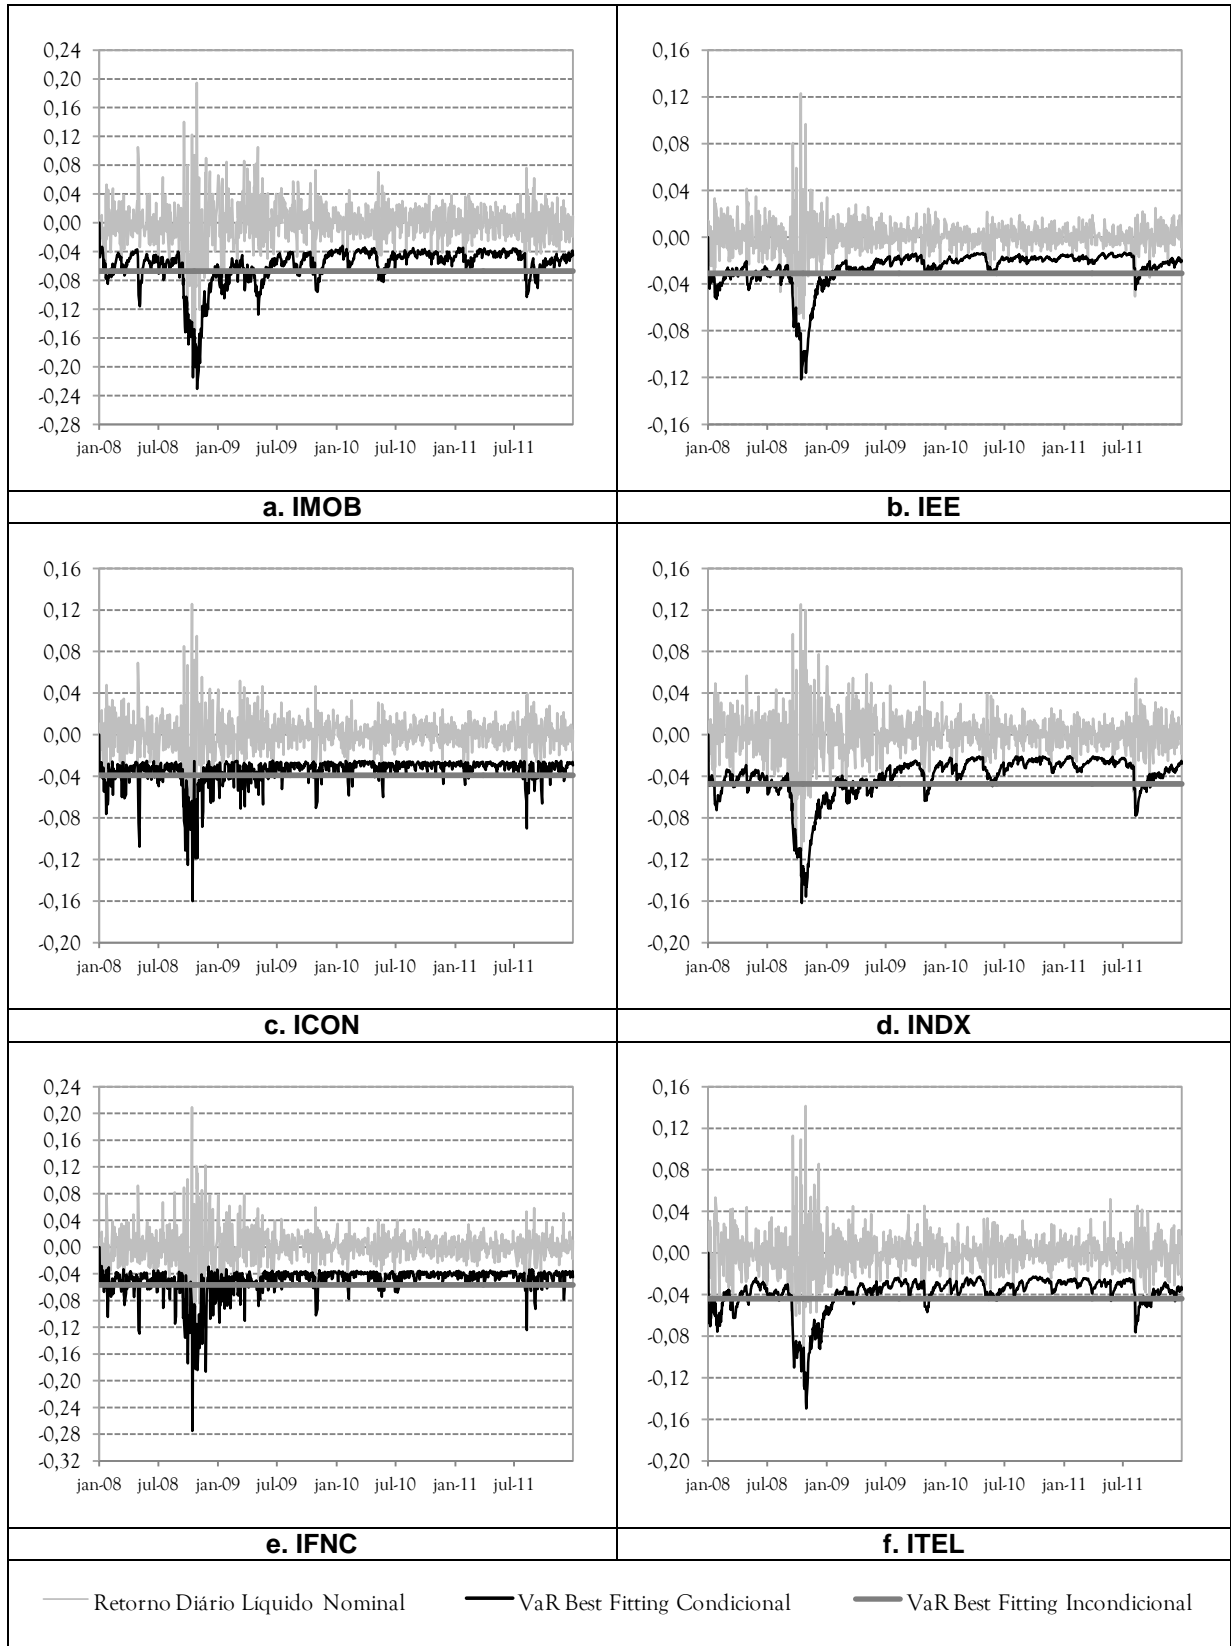
de exceções observados, os valores críticos e das estatísticas dos testes de Kupiec, Christoffersen e teste conjunto e, ainda, o consequente resultado de rejeição ou não da hipótese nula em questão. Os modelos não rejeitados nos três testes estão destacados.

Em uma análise conjunta dos testes estatísticos, percebe-se que os modelos condicionais obtiveram melhores resultados, não sendo rejeitados, para todos os índices, em pelo menos um nível de confiança (95%, 99% ou ambos). Por outro lado, analisando os modelos incondicionais, o VaR Gaussiano e o *Best Fitting* não foram rejeitados, para ambos os níveis de confiança, somente para o ITEL. A 99%, os modelos não são rejeitados também para o ICON.

Partindo para análises individuais, há menor rejeição dos modelos incondicionais no teste de Kupiec. O VaR Gaussiano, por exemplo, não é rejeitado, para ao menos um dos dois níveis de confiança, para os seis índices. Para o VaR *Best Fitting* ocorre uma única rejeição, a 95%, em relação ao índice de energia elétrica. O teste de independência de Christoffersen, por sua vez, rejeita grande parte dos modelos incondicionais. Os modelos condicionais apresentam maior aceitação nos dois testes estatísticos. Considerando Kupiec, o VaR *Best Fitting* é rejeitado a 99% para o IMOB e a 95% para o ITEL. O Gaussiano só é rejeitado para o ICON e somente a 99%. Considerando Christoffersen, apenas o VaR Gaussiano a 95% para o INFC foi rejeitado.

Constatou-se, por fim, que, apesar da prevalência dos modelos condicionais, não houve uma estimativa de *Value-at-Risk* não rejeitada para os seis índices setoriais.

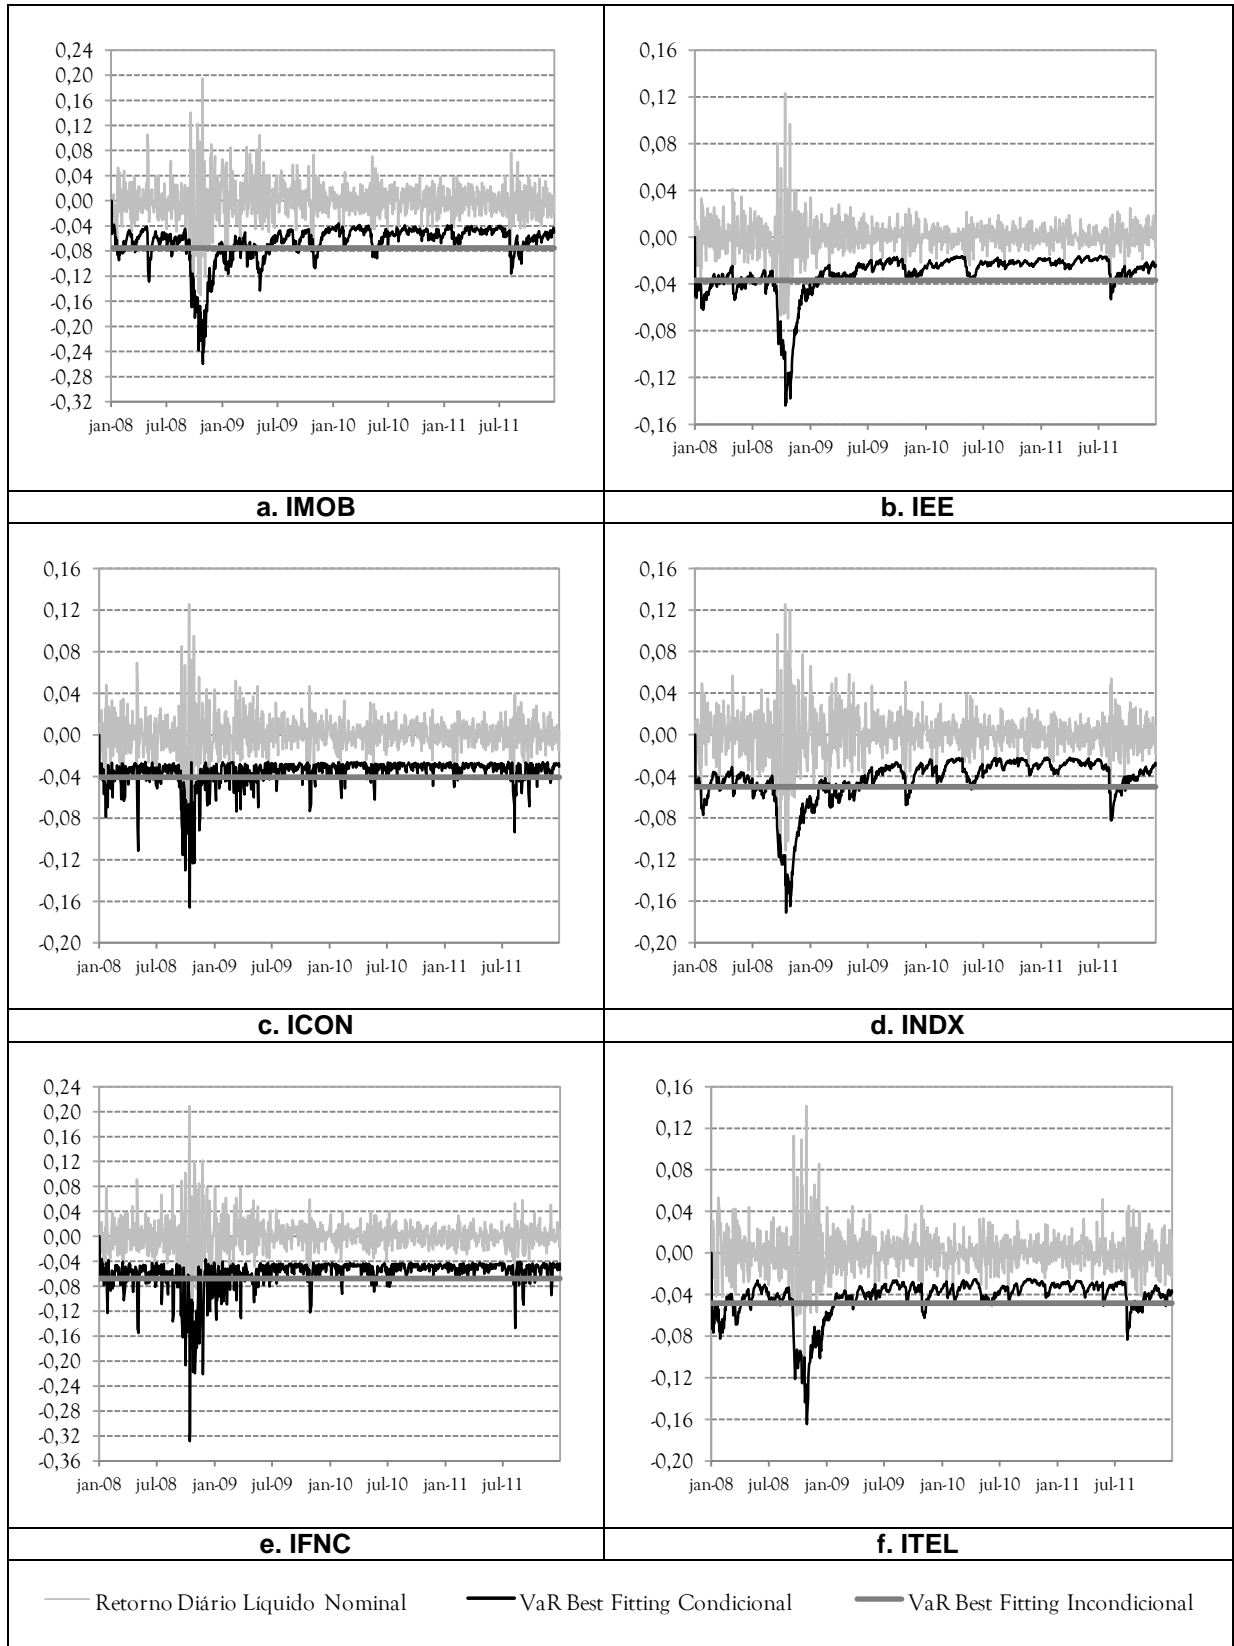
Figura 6 – Séries estimadas de VaR para 01 dia, com 99% de confiança, para os Modelos Gaussiano Condicional e Incondicional ^a



Nota: ^a Procedimento realizado através de previsões *in-sample* para toda a amostra (período de 01/2008 a 12/2011; 991 observações).

Fonte: Elaboração da autora

Figura 7 – Séries estimadas de VaR para 01 dia, com 99% de confiança, para os Modelos *Best Fitting* Condicional e Incondicional ^a



Nota: ^a Procedimento realizado através de previsões *in-sample* para toda a amostra (período de 01/2008 a 12/2011; 991 observações).

Fonte: Elaboração da autora

Tabela 10 – Resultados dos *Backtestings* das séries de *Value-at-Risk* estimadas para os retornos dos índices setoriais, com 95% e 99% de confiança ^a

Índices	VaR		Exceções em 991 obs. diárias		Teste de Kupiec			Teste de Christoffersen			Teste Conjunto de Kupiec e Christoffersen		
	Modelo	Nível Conf.	Nº	%	Estatística teste LR _{uc}	VL crítico $\chi^2(1)$	Resultado Teste ^b	Estatística teste LR _{ind}	VL crítico $\chi^2(1)$	Resultado Teste ^b	Estatística teste LR _{cc}	VL crítico $\chi^2(2)$	Resultado Teste ^b
IMOB	Gaussiano Incondicional	95%	37	3,73	3,65	3,84	Não Rejeitar	13,39	3,84	Rejeitar	17,04	5,99	Rejeitar
		99%	18	1,82	5,37	3,84	Rejeitar	8,81	3,84	Rejeitar	14,19	5,99	Rejeitar
	Best Fitting Incondicional	95%	47	4,74	0,14	3,84	Não Rejeitar	10,50	3,84	Rejeitar	10,48	5,99	Rejeitar
		99%	13	1,31	0,89	3,84	Não Rejeitar	6,74	3,84	Rejeitar	7,63	5,99	Rejeitar
	Gaussiano Condicional	95%	41	4,14	1,65	3,84	Não Rejeitar	0,90	3,84	Não Rejeitar	2,55	5,99	Não Rejeitar
		99%	15	1,51	2,28	3,84	Não Rejeitar	0,46	3,84	Não Rejeitar	2,74	5,99	Não Rejeitar
Best Fitting Condicional	95%	50	5,05	0,00	3,84	Não Rejeitar	0,83	3,84	Não Rejeitar	0,83	5,99	Não Rejeitar	
	99%	4	0,40	4,60	3,84	Rejeitar	0,03	3,84	Não Rejeitar	4,63	5,99	Não Rejeitar	
IEE	Gaussiano Incondicional	95%	33	3,33	6,56	3,84	Rejeitar	0,65	3,84	Não Rejeitar	7,21	5,99	Rejeitar
		99%	15	1,51	2,28	3,84	Não Rejeitar	5,60	3,84	Rejeitar	7,89	5,99	Rejeitar
	Best Fitting Incondicional	95%	35	3,53	4,99	3,84	Rejeitar	0,43	3,84	Não Rejeitar	5,42	5,99	Não Rejeitar
		99%	11	1,11	0,12	3,84	Não Rejeitar	8,12	3,84	Rejeitar	8,24	5,99	Rejeitar
	Gaussiano Condicional	95%	45	4,54	0,45	3,84	Não Rejeitar	0,43	3,84	Não Rejeitar	0,89	5,99	Não Rejeitar
		99%	16	1,61	3,19	3,84	Não Rejeitar	0,53	3,84	Não Rejeitar	3,71	5,99	Não Rejeitar
Best Fitting Condicional	95%	50	5,05	0,00	3,84	Não Rejeitar	0,09	3,84	Não Rejeitar	0,10	5,99	Não Rejeitar	
	99%	10	1,01	0,00	3,84	Não Rejeitar	0,20	3,84	Não Rejeitar	0,20	5,99	Não Rejeitar	
ICON	Gaussiano Incondicional	95%	41	4,14	1,65	3,84	Não Rejeitar	7,55	3,84	Rejeitar	9,20	5,99	Rejeitar
		99%	15	1,51	2,28	3,84	Não Rejeitar	0,46	3,84	Não Rejeitar	2,74	5,99	Não Rejeitar
	Best Fitting Incondicional	95%	45	4,54	0,45	3,84	Não Rejeitar	8,54	3,84	Rejeitar	9,00	5,99	Rejeitar
		99%	14	1,41	1,51	3,84	Não Rejeitar	0,40	3,84	Não Rejeitar	1,91	5,99	Não Rejeitar
	Gaussiano Condicional	95%	51	5,15	0,04	3,84	Não Rejeitar	0,18	3,84	Não Rejeitar	0,22	5,99	Não Rejeitar
		99%	17	1,72	4,22	3,84	Rejeitar	0,59	3,84	Não Rejeitar	4,81	5,99	Não Rejeitar
Best Fitting Condicional	95%	53	5,35	0,25	3,84	Não Rejeitar	0,30	3,84	Não Rejeitar	0,55	5,99	Não Rejeitar	
	99%	14	1,41	1,51	3,84	Não Rejeitar	0,40	3,84	Não Rejeitar	1,91	5,99	Não Rejeitar	

(continua)

Tabela 10 – Resultados dos *Backtestings* das séries de *Value-at-Risk* estimadas para os retornos dos índices setoriais, com 95% e 99% de confiança ^a (cont.)

Índices	VaR		Exceções em 991 obs. diárias		Teste de Kupiec			Teste de Christoffersen			Teste Conjunto de Kupiec e Christoffersen		
	Modelo	Nível Conf.	Nº	%	Estatística teste LR _{uc}	VL crítico $\chi^2(1)$	Resultado Teste ^b	Estatística teste LR _{ind}	VL crítico $\chi^2(1)$	Resultado Teste ^b	Estatística teste LR _{cc}	VL crítico $\chi^2(2)$	Resultado Teste ^b
INDX	Gaussiano Incondicional	95%	45	4,54	0,45	3,84	Não Rejeitar	15,21	3,84	Rejeitar	15,67	5,99	Rejeitar
		99%	20	2,02	8,01	3,84	Rejeitar	7,57	3,84	Rejeitar	15,58	5,99	Rejeitar
	Best Fitting Incondicional	95%	49	4,94	0,01	3,84	Não Rejeitar	12,47	3,84	Rejeitar	12,47	5,99	Rejeitar
		99%	16	1,61	3,19	3,84	Não Rejeitar	5,11	3,84	Rejeitar	8,29	5,99	Rejeitar
	Gaussiano Condicional	95%	51	5,15	0,04	3,84	Não Rejeitar	0,18	3,84	Não Rejeitar	0,22	5,99	Não Rejeitar
		99%	16	1,61	3,19	3,84	Não Rejeitar	0,53	3,84	Não Rejeitar	3,71	5,99	Não Rejeitar
Best Fitting Condicional	95%	55	5,55	0,61	3,84	Não Rejeitar	0,00	3,84	Não Rejeitar	0,61	5,99	Não Rejeitar	
	99%	13	1,31	0,89	3,84	Não Rejeitar	0,35	3,84	Não Rejeitar	1,23	5,99	Não Rejeitar	
IFNC	Gaussiano Incondicional	95%	36	3,63	4,29	3,84	Rejeitar	23,10	3,84	Rejeitar	27,39	5,99	Rejeitar
		99%	15	1,51	2,28	3,84	Não Rejeitar	11,06	3,84	Rejeitar	13,34	5,99	Rejeitar
	Best Fitting Incondicional	95%	37	3,73	3,65	3,84	Não Rejeitar	22,08	3,84	Rejeitar	25,73	5,99	Rejeitar
		99%	11	1,11	0,12	3,84	Não Rejeitar	8,12	3,84	Rejeitar	8,24	5,99	Rejeitar
	Gaussiano Condicional	95%	44	4,44	0,68	3,84	Não Rejeitar	4,09	3,84	Rejeitar	4,77	5,99	Não Rejeitar
		99%	14	1,41	1,51	3,84	Não Rejeitar	0,40	3,84	Não Rejeitar	1,91	5,99	Não Rejeitar
Best Fitting Condicional	95%	45	4,54	0,45	3,84	Não Rejeitar	0,71	3,84	Não Rejeitar	1,16	5,99	Não Rejeitar	
	99%	8	0,81	0,40	3,84	Não Rejeitar	0,13	3,84	Não Rejeitar	0,53	5,99	Não Rejeitar	
ITEL	Gaussiano Incondicional	95%	40	4,04	2,07	3,84	Não Rejeitar	0,29	3,84	Não Rejeitar	2,36	5,99	Não Rejeitar
		99%	11	1,11	0,12	3,84	Não Rejeitar	0,25	3,84	Não Rejeitar	0,36	5,99	Não Rejeitar
	Best Fitting Incondicional	95%	52	5,25	0,13	3,84	Não Rejeitar	0,24	3,84	Não Rejeitar	0,36	5,99	Não Rejeitar
		99%	10	1,01	0,00	3,84	Não Rejeitar	0,20	3,84	Não Rejeitar	0,20	5,99	Não Rejeitar
	Gaussiano Condicional	95%	54	5,45	0,41	3,84	Não Rejeitar	1,36	3,84	Não Rejeitar	1,77	5,99	Não Rejeitar
		99%	12	1,21	0,42	3,84	Não Rejeitar	0,29	3,84	Não Rejeitar	0,71	5,99	Não Rejeitar
Best Fitting Condicional	95%	76	7,67	12,87	3,84	Rejeitar	0,01	3,84	Não Rejeitar	12,87	5,99	Rejeitar	
	99%	11	1,11	0,12	3,84	Não Rejeitar	0,25	3,84	Não Rejeitar	0,36	5,99	Não Rejeitar	

Nota: ^a Procedimento executado após a realização das previsões *in-sample* utilizando-se toda a amostra (991 observações). / ^b Não se rejeita o modelo quando a estatística de teste é menor que o valor crítico, caso contrário, rejeita-se.

Fonte: Elaboração da autora

4.5 Gráficos de Balzer

Nesta seção serão apresentados os resultados relativos ao desempenho dos índices setoriais em relação aos seus riscos e retornos.

Fazendo uso dos gráficos de Balzer, foi possível comparar os índices entre si, identificando aqueles com melhor e pior desempenho. Foram feitas todas as combinações possíveis dos índices tomados dois a dois, totalizando 15 embates.

A Figura 8 traz os gráficos de Balzer, onde o eixo das abscissas contém as diferenças entre a medida de risco, aqui representada pela série de VaR *Best Fitting* Condicional com nível de confiança de 99%, e o eixo das coordenadas as diferenças entre os retornos diários líquidos nominais dos índices.

Para uma melhor compreensão dos resultados alcançados, apresenta-se a Tabela 11. Como dito anteriormente, o investidor está interessado em obter diferenças positivas entre retornos e diferenças negativas entre riscos em relação a um ativo alvo, buscando sempre maximizar os ganhos e minimizar os riscos.

Na Tabela 11, as diferenças negativas de VaR representam o percentual de vezes em que se verificaram valores negativos para as diferenças de risco entre os dois índices sob análise, para as 991 observações. Por sua vez, as diferenças positivas de retornos significam o percentual de vezes em que foram observados valores positivos para as diferenças de retorno dos índices. O vencedor do embate é o índice que apresenta maiores percentuais de diferenças negativas de risco e de diferenças positivas de retornos em relação ao seu concorrente.

O primeiro embate é entre o IMOB e o IEE. Note-se que interessa ao IMOB obter percentuais altos para as quantidades de diferenças negativas de risco e positivas de retorno, ou seja, objetiva ter maior retorno e menor risco. Observa-se, contudo, que em apenas 1% das observações verificou-se diferenças negativas de VaR e em 47%, menos da metade das observações, constatou-se diferenças positivas de retorno. Dessa forma, pode-se concluir que o IEE venceu o confronto. Salienta-se, desde logo, que o IMOB perde todos os confrontos realizados com os demais índices.

Diferentemente da constatação para o índice imobiliário, o IEE vence todos os embates, apresentando um nível de risco bem inferior ao de seus

concorrentes. Quanto ao retorno, os percentuais ficaram próximos a 50%, demonstrando uma relação mais equilibrada.

Já o ICON perde apenas para o IEE. Chama atenção o embate com o IFNC, onde as diferenças negativas de risco atingem um percentual de 99%, evidenciando o quão arriscado apresenta-se o setor financeiro no período analisado em comparação com o setor de consumo.


Partindo para o setor industrial, verifica-se um empate com o ITEL em relação ao nível de risco e de retorno. O INDX vence o confronto com o IFNC e com o IMOB, perdendo para o ICON e para o IEE. Analisando o confronto IEE versus INDX, as diferenças negativas de risco estão na ordem de 96%, ou seja, em 947 das 991 observações, o valor em risco do INDX superou o do IEE.

O índice financeiro, IFNC, é vencedor apenas no embate com o IMOB. As avaliações de risco são bem negativas se comparadas com o INDX, ICON e IEE. Sob a ótica do retorno, os percentuais ficam próximos.

Para o ITEL, por fim, percebem-se duas vitórias, duas derrotas e um empate. Nas vitórias para o IMOB e para o INFC constatam-se altos percentuais de diferenças positivas de risco, 97 e 92%, respectivamente, o que demonstra serem os seus concorrentes bem mais arriscados.

Ao final, o saldo dos 15 embates é: cinco vitórias para o IEE, evidenciando ser o setor de energia elétrica o menos arriscado, sob a ótica de Balzer e para os setores analisados; quatro vitórias para o índice de consumo, duas vitórias e um empate para os índices industrial e de telecomunicações, uma vitória para o índice financeiro e cinco derrotas para o índice imobiliário, sendo este, portanto, o setor que apresentou pior *performance*.

Figura 8 – Gráficos de Balzer para os índices setoriais tomados dois a dois ^{a,b}



Nota: ^a Eixo das ordenadas: Diferença de Retorno (%) e eixo das abscissas: Diferença de VaR (%). / ^b Diferença de VaR: VaR *Best Fitting* Condicional a 99% de confiança.
 Fonte: Elaboração da autora

Tabela 11 – Embates entre os índices setoriais ^a

		IMOB	IEE	ICON	INDX	IFNC	ITEL
IMOB	Dif. Negativas de VaR	-	1%	1%	1%	40%	3%
	Dif. Positivas de Retornos	-	47%	47%	48%	50%	47%
	Vencedor	-	IEE	ICON	INDX	IFNC	ITEL
IEE	Dif. Negativas de VaR	-	-	76%	96%	98%	94%
	Dif. Positivas de Retornos	-	-	52%	51%	53%	51%
	Vencedor	-	-	IEE	IEE	IEE	IEE
ICON	Dif. Negativas de VaR	-	-	-	63%	99%	72%
	Dif. Positivas de Retornos	-	-	-	54%	53%	51%
	Vencedor	-	-	-	ICON	ICON	ICON
INDX	Dif. Negativas de VaR	-	-	-	-	89%	50%
	Dif. Positivas de Retornos	-	-	-	-	51%	50%
	Vencedor	-	-	-	-	INDX	EMPATE
IFNC	Dif. Negativas de VaR	-	-	-	-	-	8%
	Dif. Positivas de Retornos	-	-	-	-	-	48%
	Vencedor	-	-	-	-	-	ITEL

Nota: ^a Diferenças negativas de VaR representam o percentual de vezes em que os valores em risco do índice 1 são inferiores aos do índice 2. Diferenças positivas de retorno representam o percentual de vezes em que os retornos do índice 1 são superiores aos do índice 2. Período de 01/2008 a 12/2011; 991 observações.

Fonte: Elaboração da autora

5 CONCLUSÕES

Esta pesquisa procurou, primeiramente, mensurar os riscos de mercado de seis índices setoriais da Bovespa fazendo uso da métrica *Value-at-Risk* (VaR), mundialmente difundida.

Foram estimados modelos de VaR em que se alteraram dois parâmetros: a volatilidade e a distribuição de probabilidades. A não normalidade dos retornos foi constatada, conforme previsto na teoria. Nesse sentido, a utilização do VaR *Best Fitting* apresenta-se, portanto, como uma alternativa. Para o nível de confiança de 99%, foram verificadas menores taxas de violações em comparação com o VaR Gaussiano Condicional.

Cabe registrar, contudo, que os modelos VaR *Best Fitting* não são muito explorados no meio acadêmico, necessitando, por isso, de maior cautela na análise de seus resultados.

No que tange à volatilidade das séries de retornos, os modelos que admitem variação ao longo do tempo obtiveram ótimos resultados nos testes de validação. O VaR Gaussiano Condicional com nível de confiança de 95% só foi rejeitado, para os três tipos de *backtestings* aplicados, para o IFNC e, a 99%, para o ICON. Já o VaR *Best Fitting* Condicional, a 95%, não apresentou bom ajuste para o ITEL e, com 99% de confiança, para o IMOB.

Conforme apontado no estudo de Lima (2010), os resultados dos testes de validação do *Value-at-Risk* confirmaram a importância de avaliar os modelos de VaR por diferentes técnicas de *backtesting*, pois o mesmo modelo de VaR foi considerado apropriado utilizando um teste e inadequado utilizando outro.

Na análise de *performance* realizada com o auxílio dos gráficos de Balzer, promoveu-se embates entre os índices setoriais. Dois a dois, foram feitos um total de 15 confrontos em que se constatou o excelente desempenho do índice de energia elétrica no período examinado. O IEE venceu os cinco embates a que foi submetido, enquanto o IMOB perdeu em todos eles. Desempenho ruim também foi verificado para o índice financeiro, que venceu apenas o confronto com o IMOB. Houve empate no confronto entre o INDX e ITEL. Ambos apresentaram mesmo nível de risco e de retorno. O índice de consumo foi o segundo colocado em termos de desempenho, perdendo apenas para o IEE. O setor energético revelou-se, portanto,

ser o setor menos arriscado quando comparado aos demais setores econômicos estudados.

Para trabalhos futuros, sugere-se a utilização de modelos assimétricos para estimar a volatilidade condicional, uma vez que tanto os modelos ARCH como os generalizados (GARCH) não assimilam o fato de que notícias boas e ruins advindas do mercado possuem diferentes impactos nos retornos das séries financeiras. Um outro ponto merecedor de melhor investigação refere-se ao grau de interferência da crise financeira de 2008 nos resultados obtidos, sugerindo-se, por conseguinte, a utilização de subamostras, pré e pós-crise, para confronto dos resultados.

REFERÊNCIAS

- ALARCON, C. **Avaliação de Modelos de Value-At-Risk para ações**. 2005. Dissertação (Mestrado em Economia) - Instituto de Economia, Universidade Estadual de Campinas, Campinas-SP, 2005. Disponível em: <<http://www.bibliotecadigital.unicamp.br/document/?code=vtls000360044>>. Acesso em: 04 dez. 2012.
- BACA, S.; GARBE, B.; WEISS, R. The rise of sector effects in major equity markets. **Financial Analysts Journal**, Association for Investment Management and Research, p. 34-40, set./out. 2000.
- BM&FBOVESPA - Bolsa de Valores, Mercadorias e Futuros de São Paulo. **Informações sobre índices setoriais**. Disponível em: <<http://www.bmfbovespa.com.br/indices/BuscarIndices.aspx?idioma=pt-br>>. Acesso em: 07 jan. 2013.
- BOLLERSLEV, T. Generalised autoregressive conditional heteroscedasticity. **Journal of Econometrics**, v. 31, p. 307-327, 1986.
- BRITO, G.; CORRAR, L.; BATISTELLA, F. Fatores determinantes da estrutura de capital das maiores empresas que atuam no Brasil. **Rev. Cont. Fin. USP**, São Paulo, n. 43, p. 9-19, 2007.
- CAMPBELL, S. A Review of Backtesting and Backtesting Procedure. Finance and Economics Discussion Series. **Divisions of Research & Statistics and Monetary Affairs**, Federal Reserve Board, Washington D.C, 2005.
- CHRISTOFFERSEN, P. Evaluating Interval Forecasts. **International Economic Review**, v. 39, p. 841-862, 1998.
- COSTA, J. **Distribuição Hiperbólica das Rentabilidades Acionárias**. 1999. Disponível em: <<http://fesrvsd.fe.unl.pt/WPFEUNL/Wp1999/wp353.pdf>>. Acesso em: 10 dez. 2012.
- DUARTE JÚNIOR, A. Análise da Performance de Investimentos. **Resenha BM&F**, São Paulo, p. 65-78, 1997. Disponível em: <http://www2.bmf.com.br/cimConteudo/W_ArtigosPeriodicos/01888402.pdf>. Acesso em: 17 dez. 2012.
- ENGLE, R. Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. **Econometrica**, v. 50, p. 987-1007, 1982.
- FURRIEL, A. **Modelos Heterocedásticos – ARCH e GARCH**. 2011. 69f. Dissertação (Mestrado em Métodos Quantitativos para Economia e Gestão) - Faculdade de Economia, Universidade do Porto, Porto, 2011. Disponível em: <<http://repositorioaberto.up.pt/bitstream/10216/57365/2/TeseMestradoMargaridaSepulveda.pdf>>. Acesso em: 21 nov. 2012.

GAGLIANONE, W. Evaluating Value-at-Risk models via quantile regressions. *In: Ensaios em Macroeconometria e Finanças*. Tese (Doutorado em Economia) - Escola de Pós-Graduação em Economia – EPGE, Fundação Getúlio Vargas, Rio de Janeiro, 2007. Disponível em: <<http://virtualbib.fgv.br/dspace/handle/10438/1066>>. Acesso em: 18 dez. 2012.

GAIO, L. **Gestão de riscos no mercado financeiro internacional**: uma análise comparativa entre modelos de volatilidade para estimação do Value-at-Risk. Dissertação (Mestrado em Economia) - Departamento de Administração, Universidade de São Paulo. Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto, 2009. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/96/96132/tde-03052010-173001/pt-br.php>>. Acesso em: 10 dez. 2012.

GALDI, F; PEREIRA, L. Valor em risco (VaR) utilizando modelos de previsão de volatilidade: EWMA, GARCH e volatilidade estocástica. **Brazilian Business Review**, Vitória, Espírito Santo, v. 4, n. 1, p. 74-95, 2007.

GOURIEROUX, C.; JASIAK, J. **Financial econometrics**: problems, models and methods. Princeton, New Jersey: Princeton University Press, 2001.

GUJARATI, D. Econometria básica. Rio de Janeiro: Elsevier, 2006.

JORION, P. **Value at risk: a nova fonte de referência para a gestão do risco financeiro**. Trad. Thierry Barbe. São Paulo: BM&FBOVESPA: Bolsa de Valores, Mercadorias e Futuros, 2010.

JUBERT, R.; PAIXÃO, M.; MONTE, P.; LIMA, W. Um estudo do padrão de volatilidade dos principais índices financeiros da Bovespa: uma aplicação de modelos ARCH. **Revista UnB Contábil**, Universidade de Brasília, Departamento de Ciências Contábeis e Atuariais, v. 11, n. 1-2, p. 221-239, 2008.

KIMURA, H.; SUEN, A.; PERERA, L.; BASSO, L. **Value-at-risk – Como entender e calcular o risco pelo VaR**: uma contribuição para a gestão no Brasil. Ribeirão Preto-SP: Inside Books, 2008.

KUPIEC, P. Techniques for Verifying the Accuracy of Risk Management Models. **Journal of Derivatives**, v. 3, p. 73-84, 1995.

LIMA, W. **Avaliação dos Modelos de Valor em Risco do fundo de Aplicação em cotas da Petrobras**. 2010. 97f. Dissertação (Mestrado Profissionalizante em Economia) - Programa de Pós-Graduação e Pesquisa em Administração e Economia, Faculdade de Economia e Finanças IBMEC, Rio de Janeiro, 2010. Disponível em: <<http://www.ibmecrj.br/sub/RJ/search.php?page=3&q=wi>>. Acesso em: 05 nov. 2012.

LOPEZ, J. Methods for evaluating Value-at-Risk models. **Economic Review**, Federal Reserve Bank of San Francisco, San Francisco, 1998.

MEDEIROS, L. **Análise quantitativa da volatilidade dos índices setoriais da Bovespa através de modelos GARCH univariados**. 2012. Trabalho de conclusão do Curso de Ciências Econômicas - Departamento de Ciências Econômicas, Faculdade de Ciências Econômicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2012. Disponível em: <<http://www.lume.ufrgs.br/handle/10183/56103>>. Acesso em: 29 dez. 2012.

MOLLICA, M. **Uma avaliação de modelos de Value-at-Risk: comparação entre métodos tradicionais e modelos de variância condicional**. 1999. Dissertação (Mestrado em Economia) - Departamento de Economia, Faculdade de Economia Administração e Contabilidade, Universidade de São Paulo, São Paulo, 1999. Disponível em: <<http://risktech.com.br/PDFs/mollica.pdf>>. Acesso em: 08 dez. 2012.

MORALLES, H.; SARTORIS NETO, A. Distribuição de Probabilidade e Value-At-Risk (VaR) Paramétrico: examinando a suposição de normalidade para grandes carteiras e ativos individuais num contexto de estabilidade econômica. *In*: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 30., 2010, São Carlos-SP. **Anais...** São Carlos: ABEPRO, 2010.

MORETTIN, P. **Econometria Financeira – Um Curso em Séries Temporais Financeiras**. 2. ed. São Paulo: Blucher, 2011.

NIEPPOLA, O. **Backtesting Value-At-Risk Models**. Helsinki School of Economics. Department of Economics. 2009. Disponível em: <https://aaltodoc.aalto.fi/bitstream/handle/123456789/181/hse_thesis_12049.pdf?sequence=1>. Acesso em: 20 dez. 2012.

RAMOS, M. **A volatilidade do mercado e a instabilidade das correlações entre ações**. 2003. 53f. Dissertação (Mestrado em Administração de Empresas) – Programa de Pós-Graduação em Administração de Empresas, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2003. Disponível em: <http://www.maxwell.lambda.ele.puc-rio.br/Busca_etds.php?strSecao=resultado&nrSeq=4440@1>. Acesso em: 05 nov. 2012.

SILVA, W.; TARDELLI, M.; ROCHA, D.; MAIA, M. Aplicação da métrica Value at Risk a índices de bolsas de valores de países latino-americanos: um estudo utilizando os modelos de previsão de volatilidade EWMA, EQMA e GARCH. **Revista Perspectiva**, ano 34, n. 126, p. 19-32, jun. 2010.

SOUZA, J.; COSTA, T. Retorno e Risco de Índices de Sustentabilidade em Bolsas de Valores: uma Análise Comparativa em Âmbitos Regionais. **Revista de Administração e Negócios da Amazônia**, v. 4, n. 1, p. 33-52, 2012.

SOUZA SOBRINHO, N. Extração da Volatilidade do Ibovespa. **Resenha BM&F**, n. 144, p. 17-39, 2001.

TORRES, A.; SILVA, A.; COSENZA, H. Modelagens do VAR no Contexto Brasileiro: O Problema da Sensibilidade à Definição de Parâmetros. **Revista Brasileira de Risco e Seguro**, Rio de Janeiro, v. 4, n. 7, p. 65-86, 2008.